



UNIVERSIDAD
DE PIURA

FACULTAD DE INGENIERÍA

**Propuesta de una plataforma de agricultura inteligente
basada en IoT para el monitoreo de las condiciones
climáticas del cultivo de banano**

Tesis para optar el Grado de
Doctor en Ingeniería con mención en: Automatización, Control y Optimización de
Procesos

César Iván Belupú Amaya

Asesor(es):
Dr. William Ipanaqué Alama

Piura, julio de 2022

Declaración Jurada de Originalidad del Trabajo Final

Yo, César Iván Belupú Amaya., egresado del Programa Académico/ programa de posgrado de Doctorado en Ingeniería con mención en: Automatización, Control y Optimización de Procesos de la Facultad de Ingeniería de la Universidad de Piura, identificado(a) con DNI 43757915

Declaro bajo juramento que:

1. Soy autor del trabajo final titulado:
"Propuesta de una plataforma de agricultura inteligente basada en IoT para el monitoreo de las condiciones climáticas del cultivo de banano"
El mismo que presento bajo la modalidad de **Tesis**.¹ para optar el (Título profesional/Grado Académico²) de Grado de Doctor.
2. Que el trabajo se realizó en coautoría con los siguientes alumnos de la Universidad de Piura.
 - Haga clic o pulse aquí para escribir texto. _____, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto. _____, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto. _____, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto. _____, identificado con DNI N° Escribir número
 - Haga clic o pulse aquí para escribir texto. _____, identificado con DNI N° Escribir número
3. La asesoría del trabajo estuvo a cargo de:
 - William Ipanaqué Alama _____, identificado con DNI N° 06422494
 - Haga clic o pulse aquí para escribir texto. _____, identificado con DNI N° Escribir número
4. El texto de mi trabajo final respeta y no vulnera los derechos de terceros o de ser el caso derechos de los coautores, incluidos los derechos de propiedad intelectual, datos personales, entre otros. En tal sentido, el texto de mi trabajo final no ha sido plagiado total ni parcialmente, para la cual he respetado las normas internacionales de citas y referencias de las fuentes consultadas.
5. El texto del trabajo final que presento no ha sido publicado ni presentado antes en cualquier medio electrónico o físico.
6. La investigación, los resultados, datos, conclusiones y demás información presentada que atribuyo a mi autoría son veraces.
7. Declaro que mi trabajo final cumple con todas las normas de la Universidad de Piura.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad de Piura y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Fecha: 21/07/2023



.....
Firma del autor optante³

¹ Indicar si es tesis, trabajo de investigación, trabajo académico o trabajo de suficiencia profesional.

² Grado de Bachiller, Título de profesional, Grado de Maestro o Grado de Doctor.

³ Idéntica a DNI, no se admite digital salvo certificado.




Dedicatoria:

*Dedico este trabajo principalmente a Dios,
por su guía y providencia; a mis padres
por su soporte incondicional, a mi abuelo
que está en el cielo, a mi novia por
acompañarme en este proceso y a mis
asesores por su confianza y aliento
de superación personal.*



Agradecimientos

El autor reconoce el apoyo financiero del Proyecto Concytec – Banco Mundial “Mejoramiento y Ampliación de los Servicios del Sistema Nacional de Ciencia Tecnología e Innovación Tecnológica” 8682-PE, a través de su unidad ejecutora ProCiencia [Contrato no. 06-2018-FONDECYT/BM], para la presente investigación ejecutada como parte del programa de Doctorado en Ingeniería con mención en Automatización, Control, y Optimización de Procesos, desarrollada en el Laboratorio de Sistemas Automáticos de Control de la Universidad de Piura, Perú.





Resumen

Las prácticas agrícolas inteligentes están inspiradas en tecnologías de detección, las principales variables a medir son clima y el suelo. La recopilación y el procesamiento de estos datos de diferentes cultivos conduce a mejores decisiones que pueden beneficiar a toda la cadena de valor de la siembra y cosecha de productos. Para el cultivo de banano, ámbito de esta investigación, se propone una arquitectura para recolectar y transmitir datos referentes a las variables de clima y suelo de mayor impacto en el crecimiento, mantenimiento, cosecha del cultivo. Esta arquitectura fue planeada tomando en cuenta los principales obstáculos energéticos y de comunicación que existen en las zonas rurales de la región de Piura en el norte del Perú. Los datos climáticos se recolectaron de diferentes fuentes locales para lograr proyecciones de crecimiento como el cálculo de los grados día de desarrollo para estimar los períodos de floración y cosecha, la tasa potencial de emisión de hojas y la tasa potencial de crecimiento del racimo. Estos datos se almacenan en diferentes bases de datos optimizadas para trabajar con grandes volúmenes de información. Con esto se logró un sistema de soporte de decisiones (*Decision Support Systems, DSS*) desarrollado con herramientas de código abierto. El DSS incluye adquisición remota de datos de diferentes estaciones meteorológicas a través de APIS o conexión inalámbrica con nuevos protocolos para IoT como LoRaWAN. La información climática también se relacionó con el comportamiento de plagas que afectan al cultivo de banano. Se sabe que la aparición de plagas en la agricultura es un grave problema y su contención es un gran reto, sobre todo cuando los agricultores no pueden responder rápidamente y evitar su propagación en el campo. Las plagas que más afectan al

cultivo de banano en Piura son los Trips de la mancha roja (*Chaetanaphothrips signipennis*). Este trabajo presenta una propuesta de modelo basado Machine Learning para relacionar la información climática con el crecimiento de la población de trips en una parcela de banano. Para esto se desarrolló un sistema de adquisición de datos meteorológicos y una aplicación web para el registro y control de la plaga. Con estos datos se construyó un conjunto de datos de entrada para el modelo, al que se aplicaron técnicas de preprocesamiento como el PCA (Análisis de Componentes Principales) para reducir la dimensionalidad de la matriz y preservar la mayor información posible. Finalmente, se probaron diferentes algoritmos de aprendizaje automático tomando los componentes PCA resultantes como entrada para predecir la evolución poblacional de los trips en la parcela. Una red neuronal multicapa fue el modelo que obtuvo los mejores resultados con una puntuación F1 del 82,3%.



Tabla de contenido

Introducción	19
Capítulo 1 Aspectos generales	23
1.1 Problemática	23
1.2 Justificación	25
1.3 Motivación	26
1.4 Objetivos de la investigación	27
1.4.1 Objetivo general	27
1.4.2 Objetivos específicos	27
Capítulo 2 Antecedentes	29
2.1 Estado del arte: Importancia del IoT en la agricultura inteligente	29
2.2 Estado del arte: Aplicaciones IoT y WSN en la agricultura inteligente	32
2.3 Estado del arte: Monitoreo de plantaciones de banano	43
2.4 Requerimientos de las plantaciones de banano	45
2.4.1 Requerimientos de riego	46
2.4.2 Requerimientos de nutrientes en el suelo	47
Capítulo 3 Marco teórico	49
3.1 Internet de las cosas (IoT)	49
3.2 Agricultura inteligente	53
3.2.1 Tipos de sensores en la agricultura inteligente	55
3.2.2 Aplicaciones del Machine Learning en la agricultura	57
3.2.3 Aplicaciones del Deep Learning en la agricultura	62
3.3 Facilitadores técnicos para IoT	64
3.3.1 Computación ubicua y sistemas embebidos	64

3.3.2	Tecnologías de la comunicación	66
3.3.3	Tecnologías de la WWW para IoT	68
3.3.4	Tecnologías de baja potencia y área extendida (LPWA)	70
3.4	Long Range (LoRa)	73
3.4.1	Modulación LoRa en la capa física	73
3.4.2	LoRaWAN	74
3.4.3	Clases LoRaWAN	75
3.5	Redes de sensores inalámbricos	77
3.5.1	Disposición de las WSN	79
3.5.2	Técnicas de muestreo	84
3.6	Protocolos de comunicación IoT	87
3.6.1	MQTT	88
3.6.2	CoAP	89
3.6.3	XMPP	89
3.6.4	SOAP	89
3.6.5	REST	90
3.7	Plataformas IoT	90
3.8	Herramientas software para el IoT	91
3.8.1	Flask	91
3.8.2	Node.js	92
3.8.3	Bases de datos	92
3.8.4	NOSQL	94
3.9	Topologías de nube y niebla	97
3.9.1	Modelo de servicios en la nube	98
3.9.2	Nube pública, privada e híbrida	100
3.9.3	Restricciones de las arquitecturas en la nube para IoT	105
3.9.4	Capa de computación en niebla (Fog Computing)	106
3.9.5	Arquitectura OpenFog	107

Capítulo 4	Solución IoT para el monitoreo de plantaciones de banano	109
4.1	Factores importantes para la adopción de la tecnología en países en desarrollo	109
4.1.1	Características de las organizaciones agrícolas en Piura	110
4.1.2	Investigación sobre la adopción de tecnologías de la información	111
4.1.3	Datos insuficientes en las organizaciones agrícolas	114
4.2	Implementación de la solución IoT	116
4.2.1	Arquitectura de software	116
4.2.2	Desarrollo del sistema en el contexto Piurano	121
4.2.3	Diagramas UML de la arquitectura de software	122
4.2.4	Requisitos de sensado	124
4.2.5	Estructura de la arquitectura y diseño del sistema	129
Capítulo 5	Funcionalidades de la plataforma para apoyar la producción bananera	135
5.1	Importancia de los datos meteorológicos	136
5.2	Metodologías	137
5.3	Indicadores mostrados en la plataforma	138
5.3.1	Cálculo de la tasa potencial de emisión de hojas	138
5.3.2	Cálculo del período de floración a cosecha	139
5.3.3	Cálculo del peso potencial de racimo	140
5.4	Predicción de población de trips en base a condiciones climáticas usando PCA, redes neuronales y series de tiempo	142
5.4.1	Metodología	146
5.4.2	Dataset	147
5.4.3	Análisis de datos	148
5.4.4	Red neuronal para predecir valores de trips futuros en el tiempo	149
5.4.5	Análisis de Componentes Principales PCA	151
5.4.6	Aumento de datos SMOTE	154
5.4.7	Predicción de una serie temporal	154
5.5	Resultados	156

Conclusiones	163
Referencias bibliográficas	165



Lista de figuras

Figura 1	Tecnologías de comunicación IoT	30
Figura 2	IoT en la agricultura	30
Figura 3	Arquitectura general de una plataforma para Agricultura Inteligente . . .	33
Figura 4	Esquema del monitoreo IoT de plantas	34
Figura 5	La arquitectura de control de un sistema de riego	35
Figura 6	Arquitectura del sistema de alerta para el control de estrés hídrico . . .	36
Figura 7	Dispositivos IoT desplegados en un huerto de melocotones	37
Figura 8	Interfaz de monitoreo para la enfermedad de tizón tardío	38
Figura 9	Arquitectura IoT de un sistema de telemetría	39
Figura 10	Diagrama general sistema de control de riego basado en IoT	40
Figura 11	Módulo gateway LoRa	41
Figura 12	Prototipo IoT instalado en sala de fermentación	43
Figura 13	Producción mundial de banano	44
Figura 14	Evolución de la internet desde pre- internet hasta IoT	50
Figura 15	Arquitectura básica para IoT	52
Figura 16	Organización de los protocolos IP para IoT	70
Figura 17	Tecnologías LPWA	71
Figura 18	Elementos LoRaWAN	75
Figura 19	Clases de dispositivos LoRaWAN	76
Figura 20	Disposición de WSN en mosaicos	81
Figura 21	Disposición de WSN capa de mosaicos	81
Figura 22	Consumo en un nodo WSN	85
Figura 23	Funcionamiento del protocolo MQTT	88

Figura 24	Código de inicialización de flask	91
Figura 25	Modelos de arquitectura en la nube	99
Figura 26	Izquierda: nube pública. Medio: nube privada versus pública. Derecha: nube híbrida.	100
Figura 27	Diagrama de la arquitectura OpenStack	103
Figura 28	Efectos de latencia en la nube	105
Figura 29	Relación entre la nube, el borde, la niebla y el mist computing	107
Figura 30	Arquitectura OpenFog	108
Figura 31	Índice de desarrollo en Tic 2015	110
Figura 32	Sistema de pesaje instalado	113
Figura 33	Arquitectura Agri-IoT	117
Figura 34	Arquitectura de una plataforma de soporte de decisiones para el IoT	118
Figura 35	Arquitectura desarrollada para la agricultura inteligente	119
Figura 36	Arquitectura IoT de la solución a implementar	120
Figura 37	Enfoque sistemático de la solución	121
Figura 38	Sistema en el contexto piurano	122
Figura 39	Casos de uso	123
Figura 40	Diagrama de bloques	123
Figura 41	Diagrama de componentes	124
Figura 42	Diagrama de instalación de sensores	125
Figura 43	Modelo DLTRS12	126
Figura 44	Modelo DLH35	127
Figura 45	Estación meteorológica μ METOS	128
Figura 46	Gateway para la transmisión de datos modelo iStation	128
Figura 47	Interfaz de comunicación entre la capa física de sensado y los sistemas de red	130
Figura 48	Arquitectura LoRaWAN llevada al sistema planteado	131
Figura 49	Monitoreo de los parámetros del suelo del nodo 1	132
Figura 50	Monitoreo de las variables climáticas de la estación	133

Figura 51	Monitoreo de las variables climáticas de la estación	133
Figura 52	Formulario para el cálculo de número de hojas	139
Figura 53	Resultados para el cálculo de número de hojas	140
Figura 54	Formulario para el cálculo del período de floración a cosecha	141
Figura 55	Resultados del cálculo del período de floración a cosecha	142
Figura 56	Formulario para el cálculo del peso potencial de racimo	143
Figura 57	Formulario para el cálculo del peso potencial de racimo	143
Figura 58	Cantidad de datos por grupo	151
Figura 59	Comportamiento de las variables con respecto a los individuos	153
Figura 60	Comparativa de resultados para las series temporales	155
Figura 61	Esquema de la metodología	156
Figura 62	Arquitectura MLP	157
Figura 63	Matriz de confusión del modelo Random Forest	158
Figura 64	F1-score para diferentes modelos	159
Figura 65	Curva de la función de costo del modelo sin capa Dropout	160
Figura 66	Curva de la función de costo del modelo añadiendo la capa Dropout	161
Figura 67	Matriz de confusión del modelo MLP	162
Figura 68	Diagrama de barras por grupos	162



Lista de tablas

Tabla 1	Indicadores propuestos para la plataforma	138
Tabla 2	Correlación entre datos de entrada y salida	149
Tabla 3	Resultados del primer modelo de red neuronal	150
Tabla 4	Resultados luego de clasificar los datos en tres grupos	151
Tabla 5	Prueba realizada usando todas las variables meteorológicas y acumulativas	152
Tabla 6	Resultados usando PCA para el entrenamiento	153





Introducción

El auge de Internet en las últimas décadas trajo innumerables beneficios a la población mundial, se ha comprobado que el mayor beneficio fue la capacidad de producir y consumir datos y servicios en tiempo real. En los últimos años se ha desarrollado una nueva tecnología que promete brindar los mismos beneficios a los objetos de la vida cotidiana. El Internet de las Cosas (*Internet of Things*, IoT) es una familia de tecnologías muy prometedoras, capaz de brindarnos una forma de extender nuestra percepción y nuestra capacidad de modificar el entorno que nos rodea (Talavera et al., 2017).

En este contexto, los campos agrícolas son candidatos ideales para el despliegue de soluciones IoT porque necesitan ser monitoreados y controlados continuamente. Los paradigmas de la computación en la nube, la utilización de redes de sensores inalámbricos (*Wireless Sensor Network*, WSN) de largo alcance y actuadores, sistemas de geoposicionamiento, el Big Data, Machine Learning, vehículos aéreos no tripulados o drones, robots, etc. representan un potencial real para un incremento en la eficiencia agrícola (Čolaković & Hadžialić, 2018).

Estos rápidos desarrollos en IoT y la computación en la nube están impulsando el fenómeno de lo que se llama “agricultura inteligente”, este concepto se centra en el acceso a datos, que se pueden utilizar para alimentar algoritmos de Inteligencia Artificial y proporcionar información que ayude a la planificación de decisiones a los agricultores o productores (Wolfert, Ge, Verdouw, & Bogaardt, 2017). El IoT se puede utilizar a lo largo de la cadena de producción agroindustrial, por ejemplo, para ayudar a la evaluación de variables de campo como el estado

del suelo, las condiciones climáticas como la temperatura y humedad, el estado de los cultivos analizando plagas y enfermedades, activar alertas o enviar mensajes de recomendación, etc (Muangprathub et al., 2019).

El objetivo de la agricultura inteligente es el incremento de la sostenibilidad y la productividad agrícola, basada en un uso más eficiente de los recursos. Si bien en algunos países desarrollados como Estados Unidos entre el 20% y 80% de su comunidad agrícola utiliza este tipo de soluciones IoT, en América Latina se utilizan muy poco debido a que su uso suele limitarse a escenarios específicos de alto costo, y no están adaptados a condiciones específicas (Karim, Karim, & frihida, 2017).


Para el Perú, la agricultura es un sector muy importante en la economía ya que el 26% del empleo a nivel nacional proviene de este campo (Banco Mundial, CIAT, & CATIE, 2014). La demanda de los mercados especializados ha llevado a algunos agricultores a evolucionar a buenas prácticas agrícolas para lograr una gestión más sostenible. Sin embargo, las tasas de adopción de estas tecnologías todavía son bajas porque estos servicios dependen casi invariablemente del acceso continuo a Internet. Este acceso es ante todo un problema global y social (M. O'Grady, Langton, & O'Hare, 2019). En el Perú los pequeños agricultores no son ajenos al problema, son particularmente vulnerables debido a su situación rural y remota. En general algunos no tienen acceso a Internet y otros tienen una conexión intermitente de mala calidad por lo tanto no pueden aprovechar la disponibilidad de estos servicios.

En Piura, la agricultura también constituye una de las actividades económicas de mayor potencial productivo y exportador, los pequeños agricultores vienen aprovechando la buena calidad de cultivos no tradicionales como el banano, cacao, mango para exportar al mercado internacional. Sin embargo, la pequeña agricultura en esta región presenta limitaciones, el poco acceso a la tecnología del proceso productivo, la falta de capacitación a los productores, los grandes requerimientos del mercado extranjero, complican la competencia de este sector y la mejora de sus prácticas agrícolas. En esta línea, uno de los cultivos que está creciendo en competencia en Piura es el cultivo de banano, las condiciones climáticas de la región son ideales para las plantaciones de este fruto, sin embargo, constantemente presentan pérdidas por ataques de diferentes plagas y enfermedades que afectan al cultivo o el poco control sobre

el rendimiento del cultivo.

El objetivo de esta tesis es investigar estas nuevas tecnologías de IoT, usar sensores remotos para tomar datos climáticos importantes en el monitoreo de una plantación de banano, transmitirlos a través de redes inalámbricas de largo alcance diseñadas para grandes áreas de cultivo y complementarlos con modelos matemáticos y algoritmos de Inteligencia Artificial para evaluar su comportamiento, se plantea que el estudio contribuya a una solución integrada de Internet de las Cosas para mejorar la gestión y supervisión de este cultivo.

Este documento está organizado de la siguiente manera: el capítulo 1 presenta los aspectos generales de la tesis, detallando la problemática, justificación motivación y objetivos. El capítulo 2 muestra el estado del arte con los trabajos relacionados, la sección III muestra los métodos, herramientas software y hardware utilizados, la sección IV muestra los resultados y finalmente la sección V las conclusiones.





Capítulo 1

Aspectos generales

1.1. Problemática

La sostenibilidad en la agricultura, en definitiva, está relacionada con la capacidad de que, en el agroecosistema, se pueda mantener la producción a través del tiempo de una manera constante. Esto en países en desarrollo es difícil de conseguir, sobre todo para los pequeños agricultores y productores donde todavía no pueden permitirse tecnologías agrícolas modernas (Kellengere Shankarnarayan & Ramakrishna, 2020). Para abordar los desafíos de la agricultura, es necesario comprender los complejos ecosistemas agrícolas (Sharma, Kamble, & Gunasekaran, 2018). Esto se puede lograr mediante tecnologías digitales que monitorean el entorno físico produciendo grandes cantidades de datos a un ritmo sin precedentes. El análisis de estos datos permitirá a los agricultores y empresas extraer valor de ellos mejorando su productividad (Kamilaris, Kartakoullis, & Prenafeta-Boldú, 2017).

Los métodos tradicionales utilizados por los agricultores no son suficientes para satisfacer la demanda del mercado, los cultivos hoy en día tienen diferentes problemas como: plagas y enfermedades, manejo de malezas, obligando algunas veces a usar en exceso fertilizantes y pesticidas que dañan el suelo, afectando la práctica agrícola y dejando la tierra estéril (Jha, Doshi, Patel, & Shah, 2019), esto crea la necesidad de un nivel satisfactorio de producción de cultivos a pesar de la disminución de la cantidad de tierras agrícolas (Rehman, Mahmud, Chang, Jin, & Shin, 2019). Otro de los grandes problemas en los pequeños

agricultores es el control de riego. Se sabe que la demanda de agua está aumentando debido al rápido crecimiento de la población mundial, y el problema del cambio climático. Esta escasez de agua plantea grandes amenazas para la seguridad alimentaria y el desarrollo sostenible en algunas partes del mundo, por lo tanto, se necesita un uso eficiente del recurso hídrico. Las lluvias y el riego son fuentes importantes de agua para la agricultura, sin embargo, las lluvias no son fiables y además su exceso pueden causar efectos no deseados como la erosión, y la escasez puede ocasionar sequías (Abioye et al., 2020).

La implementación exitosa de sistemas agrícolas productivos y sostenibles en todo el mundo forma las bases para superar estos desafíos. Sin embargo, el despliegue y la adopción de estos sistemas inteligentes siguen estando distantes de los pequeños agricultores debido a la confluencia de factores tecnológicos, sociales y económicos (M. O'Grady et al., 2019). Dentro de los factores tecnológicos está la brecha rural-digital del acceso a Internet y banda ancha; este es un tema recurrente en todo el mundo ya que siempre habrá una diferencia en la calidad de servicios (QoS) entre las zonas urbanas y rurales; no obstante, cerrar esta brecha o minimizarla es esencial desde una perspectiva social y económica. En promedio, el 50% del mundo está en línea; sin embargo, el otro 50% probablemente esté repartido entre la población que vive en regiones relativamente aisladas (M. O'Grady et al., 2019), por lo que se puede suponer que, en el caso de los pequeños agricultores la conexión a Internet es deficiente.

Uno de los procesos agrícolas importantes en la región Piura y en el Perú, es el del cultivo de banano. En las últimas décadas la exportación de banano ha venido incrementándose, esto debido al desarrollo de un nicho de mercado sólido para el banano orgánico como lo es la Unión Europea. La mayor parte de la exportación de bananos en el país es orgánica, y representan alrededor del 3% de la producción mundial (Gehring, Dorneanu, Silupú, Alama, & Arellano-Garcia, 2020). Este cultivo tiene un alto potencial adaptativo a diferentes condiciones agroecológicas, pero también viene siendo afectado por el cambio climático (Turner, Fortescue, & Thomas, 2007) ya que ciertos tipos de eventos extremos dañan y destruyen plantaciones, mientras eventos moderados retrasan o adelantan el ritmo productivo.

Sin embargo, muchos productores y técnicos de campo siguen rutinas de prácticas de manejo sin considerar las condiciones climáticas (Calberto, Blake, Staver, Carvajal, & Brown,

2018). Agregado a esto, los productores orgánicos en Perú enfrentan otros desafíos, dentro de los cuales se destacan: mitigar la afectación de plagas y enfermedades que atacan al cultivo, asegurar el suministro de agua para el riego, ya que este recurso es limitado en algunas áreas donde se produce banano, asegurar un nivel apropiado de nutrientes y empezar a cerrar la brecha del acceso a la tecnología que existe en este proceso productivo para lograr mantener un rendimiento sostenible. Por eso la implementación de nuevas tecnologías se vuelve esencial para lograr estos objetivos, la combinación de equipos electrónicos para sensado, las WSN, las aplicaciones de Inteligencia Artificial, están cambiando de forma radicalmente la forma de controlar y manejar los cultivos. De este contexto, la importancia de centrarse en el estudio de estas nuevas tecnologías de la agricultura inteligente para poder ayudar a los pequeños productores a acercarse a buenas prácticas agrícolas, logrando una productividad sostenible de sus cultivos.

1.2. Justificación

Las prácticas agrícolas en el mundo están evolucionando, apoyadas por la biotecnología y las tecnologías digitales emergentes como el IoT, la computación en la nube y la Inteligencia Artificial. El despliegue de estas nuevas Tecnologías de la Comunicación e Información (TICs) para el manejo de cultivos han ampliado el concepto de Agricultura Inteligente, mejorando las tareas existentes de manejo y toma de decisiones (Kamilaris et al., 2017). Debido a esto, expertos han comenzado a incorporar distintos métodos tecnológicos para mejorar la operación y manejo de las prácticas agrícolas (Caicedo-Ortiz et al., 2018), (Divakar & Sushma, 2018), (Alreshidi, 2019). Se plantea que una adecuada aplicación de la tecnología en la agricultura haría que esta sea sostenible en el futuro, regulando esta práctica vital para el desarrollo de la vida humana.

La tecnología que más ayuda a este desarrollo es el IoT, porque está contribuyendo significativamente a sentar las bases de una agricultura moderna e inteligente. Los agricultores pueden controlar sus cultivos de forma remota y gestionar actividades de una manera eficaz, esto se puede lograr debido a que los datos generados por diversos sensores son procesados con modelos matemáticos o con modelos de Machine Learning (M. J. O'Grady & O'Hare, 2017)

con el objetivo básico de interactuar, controlar y tomar mejores decisiones (Khanna & Kaur, 2019) mediante algunas aplicaciones como pronóstico del tiempo, pronóstico del rendimiento, el monitoreo de plagas de cultivos y enfermedades, etc.

Uno de los cultivos que puede tomar impulso si se le aplicaran estas tecnologías es el cultivo de banano. En el Perú en las últimas décadas la exportación de banano ha venido incrementándose, en el 2015 se alcanzaron a exportar casi 200 000 toneladas siendo las regiones con mayor producción Piura, Tumbes y Lambayeque (FAO, 2017). En ese sentido, mantener el crecimiento de estas exportaciones es importante para la región, ya que Piura concentra más del 80% del banano orgánico nacional para exportación. Sin embargo, la falta de industrialización, la inadecuada gestión del cultivo, la inexactitud de la información y la ineficiencia para detectar enfermedades y plagas son los problemas más importantes de estas zonas productoras de banano. Las soluciones propuestas para superar estos retos no sólo deben tener en cuenta la forma en que se produce el fruto, sino también las preocupaciones medioambientales y económicas. El IoT, las WSN y las grandes tecnologías de datos son potenciales facilitadores para afrontar estos desafíos (Kamble, Gunasekaran, & Gawankar, 2020).

En este marco, esta investigación profundiza en las nuevas tecnologías de la agricultura inteligente para ayudar a mejorar este sector agroindustrial y puedan así mantener un crecimiento y sostenibilidad. Se plantea que un eficaz monitoreo local y remoto en tiempo real de las variables climatológicas críticas en el cultivo del banano orgánico ayudaría a mejorar su calidad, para eso una solución de IoT con una red de sensores inalámbricos (WSN) será un gran aporte para este sector de la agricultura.

1.3. Motivación

Actualmente una agricultura sin tecnología es inviable, sobre todo si se piensa en el desarrollo de un país, la agricultura inteligente está orientada al acceso a los datos y a identificar cómo se puede utilizar la información recopilada de una manera “inteligente” (Mohd Kassim, Mat, & Harun, 2014). Los agricultores pueden usar dispositivos móviles inteligentes, para acceder a datos agrícolas en tiempo real (estado del suelo y de las plantas, riego, fertilización,

malezas, clima, situación de plagas, etc.). Como resultado, podrán actuar sobre la base de datos sólidos e intervenir cuando sea necesario, en lugar de su intuición tradicional, por eso con esta tesis se busca plantear soluciones ante las dificultades de algunos métodos agrícolas tradicionales y de esta manera facilitar, controlar, digitalizar, divulgar aspectos fundamentales de la Agricultura Inteligente como son estas tecnologías emergentes.

1.4. Objetivos de la investigación

1.4.1. Objetivo general

Proponer una nueva plataforma de agricultura inteligente para soporte de decisiones (DSS) basada en tecnologías IoT de largo alcance para la recolección de la información climática de diferentes fuentes y el análisis de los datos mediante Machine Learning y modelos matemáticos para el monitoreo de una plantación de banano.

1.4.2. Objetivos específicos

- Estudio de las nuevas tecnologías de IoT y su aplicación en la agricultura inteligente.
- Diseño de una nueva arquitectura para la recolección y organización de información climática de diferentes fuentes usando protocolos IoT implementando una red de comunicaciones de bajo consumo integrada con sensores de largo alcance para aplicarse en una plantación de banano en Piura.
- Diseño y desarrollo de un sistema de soporte de decisiones (DSS) para el análisis de la información climática mediante algoritmos de Machine Learning para la evaluación de plagas de y modelos matemáticos para lograr proyecciones de crecimiento en una plantación de banano.



Capítulo 2

Antecedentes

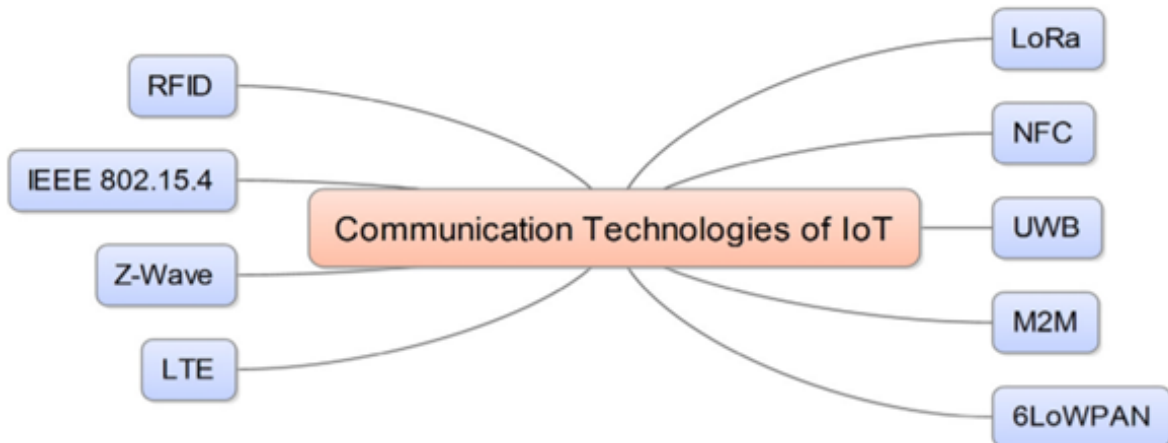
2.1. Estado del arte: Importancia del IoT en la agricultura inteligente

Con la llegada de la Industria 4.0, la transformación global mediante la integración digital y la ingeniería inteligente ha dado un salto de gigante hacia las aplicaciones con tecnología futurista. La automatización se ha convertido en una prioridad y, por lo tanto, se está gestando una nueva revolución industrial (Muhuri, Shukla, & Abraham, 2019). En (Alcácer & Cruz-Machado, 2019) explican que los rápidos avances en los métodos de industrialización e informatización han estimulado un enorme progreso en el desarrollo de la próxima generación de tecnología.

Específicamente en el ámbito de la agricultura inteligente, en (Khanna & Kaur, 2019) han llevado a cabo una revisión exhaustiva de las tecnologías de comunicación aplicadas a este campo (figura 1). Este artículo evalúa las contribuciones realizadas por diferentes investigadores y académicos en los últimos años. Además, detalla los retos a los que se enfrentan actualmente las actividades agrícolas, también explican que se han producido enormes cambios en las técnicas y metodologías de realización de las actividades agropecuarias. El agricultor de la nueva era ha pasado de la agricultura tradicional a los conceptos modernizados. Los investigadores que trabajan en este campo han elaborado teorías y prácticas que incorporan a dispositivos inteligentes para evaluar los parámetros que contribuyen al crecimiento de las plantas, además muestran que la mayoría de los temas de interés de la tecnología IoT está

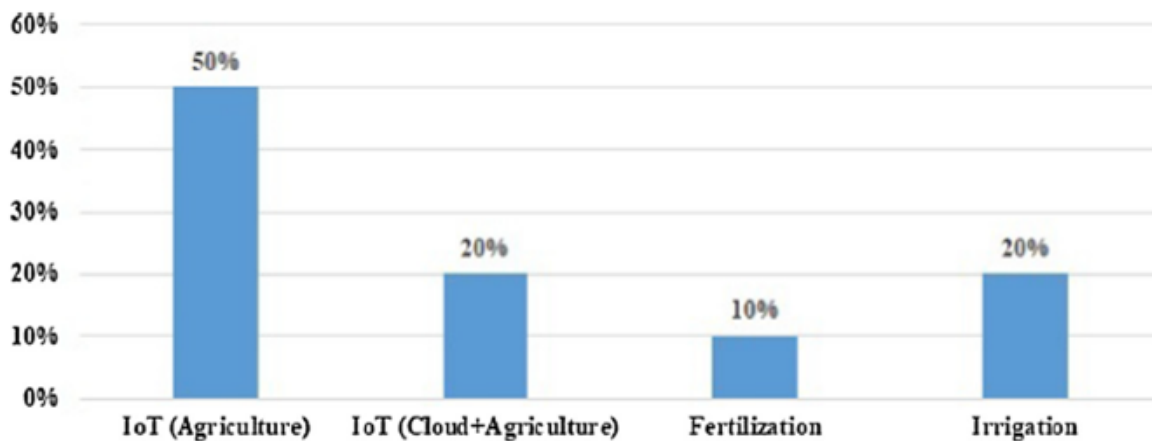
relacionada con el campo agrícola (figura 2).

Figura 1.
Tecnologías de comunicación IoT



Nota. Extraído de (Khanna & Kaur, 2019)

Figura 2.
IoT en la agricultura



Nota. Extraído de (Khanna & Kaur, 2019)

Por otro lado, en (Abioye et al., 2020) explican que el advenimiento y los rápidos éxitos del IoT y las estrategias de control avanzadas se están aprovechando para lograr un mejor seguimiento y control en la gestión agrícola. Esta investigación se enfoca en el riego,

esto debido a que la demanda de agua dulce está aumentando por el rápido crecimiento de la población mundial. A esto se le suma el efecto del calentamiento global y el cambio climático que provocan una grave amenaza para el recurso hídrico y por consiguiente para seguridad alimentaria. Explican que para lograr un riego eficiente, es necesario la integración de IoT para la adquisición de datos, así como el monitoreo, la teoría de control y las tecnologías de apoyo a las decisiones esto permite entregar nutrientes y agua directamente a las raíces de cada planta y mantener la humedad del suelo en niveles óptimos.

En (Torky & Hassanein, 2020) señalan que en la agricultura inteligente, los sistemas de software de predicción y análisis predictivo pueden utilizar datos climáticos para proporcionar a los agricultores orientación sobre el manejo del suelo, la madurez de los cultivos, los tiempos de siembra óptimos y de cosecha, etc. Explican que los sistemas de soporte de decisiones basados en la Web pueden ayudar a cumplir muchos de estos requisitos de la agricultura inteligente. Este estudio hace una revisión de la literatura, seleccionó 72 investigaciones, encontrando que la mayor parte se centra en el monitoreo de las aplicaciones (62%), sin embargo, existe un interés creciente en cerrar el ciclo haciendo control (25%), y existen algunas soluciones preliminares en logística y predicción (13%) para aplicaciones agroindustriales y ambientales que utilizan IoT. También confirma que la temperatura, humedad del aire, así como la humedad del suelo y la radiación solar pueden reconocerse como variables universales medidas en aplicaciones agrícolas. Además, observó que las nuevas fuentes de energía y el almacenamiento en la nube no se han adoptado ampliamente, lo que demuestra que existen oportunidades para la investigación y el desarrollo en estas áreas.

En (Talaviya, Shah, Patel, Yagnik, & Shah, 2020) explican que la automatización en la agricultura es la principal preocupación y un tema emergente en todo el mundo, para esto la Inteligencia Artificial ha traído una revolución, el uso de esta tecnología puede proteger el rendimiento de los cultivos de diversos factores como los cambios climáticos y los problemas de la seguridad alimentaria. Declaran que los equipos y máquinas basados en Inteligencia Artificial han llevado el sistema agrícola actual a un nivel diferente. Estas tecnologías han mejorado la producción de cultivos, mejorando la cosecha, el procesamiento y la comercialización en tiempo real. El trabajo de (Jha et al., 2019), también da cuenta de las relaciones entre los

diversos sistemas embebidos usados en IoT y la Inteligencia Artificial coherente con el campo agrícola, esta investigación estudió las diversas aplicaciones de las redes neuronales y Machine Learning en este sector para la agricultura inteligente.

2.2. Estado del arte: Aplicaciones IoT y WSN en la agricultura inteligente


La agricultura inteligente es parte de la Industria 4.0, es un nuevo paradigma que utiliza las tecnologías de la información y comunicación para mejorar la gestión de la agricultura. En la actualidad con la ayuda del creciente conocimiento científico sobre el papel que juegan los factores climatológicos en el crecimiento de algún cultivo, la aplicación de redes de estaciones meteorológicas, sensores inteligentes y redes con sensores inalámbricos que ofrecen capacidad de captación de datos e intercambio de información en tiempo real se pueden desarrollar nuevas opciones para el monitoreo y la gestión del cultivo.

En (Zamora-Izquierdo, Santa, Martínez, Martínez, & Skarmeta, 2019) explican que la Agricultura Inteligente crece día a día junto con el IoT y los paradigmas de la computación en la nube. En esta investigación proponen una plataforma flexible (figura 3) capaz de hacer frente a las necesidades de cultivos sin suelos. Esta plataforma está basada en hardware intercambiable de bajo costo, software de código abierto y usa protocolos de comunicación IoT como MQTT, CoAP.

En (Mohanraj, Ashokumar, & Naren, 2016) exponen que, para tomar decisiones rentables, los agricultores necesitan información a lo largo de todo el ciclo agrícola. La información requerida se encuentra dispersa en diversos lugares, lo que incluye información en tiempo real, como los precios de mercado y las estadísticas de los niveles de producción actuales, junto con los conocimientos disponibles sobre los cultivos primarios. Por ellos es importante contar con las TIC en el sector agrícola, muestran el camino para que los agricultores rurales reemplacen algunas de las técnicas convencionales. El módulo que proponen contiene el monitoreo del crecimiento de la planta en varias etapas, planificador de riego, calculadora de rendimiento del cultivo, y verificación de enfermedades (figura 4).

En (Habib et al., 2019) también utilizan redes WSN, proponen desarrollar un sistema de riego óptimo de cultivos agrícolas basado en una red de sensores inalámbricos.


Figura 3.
Arquitectura general de una plataforma para Agricultura Inteligente



Nota. Extraído de (Zamora-Izquierdo et al., 2019)

El objetivo de este trabajo fue diseñar y desarrollar un sistema de control mediante nodos sensores en el campo de cultivo con gestión de datos a través de un smartphone y una aplicación web. Los tres componentes son el hardware, la aplicación web y la aplicación móvil (figura 5). El primer componente fue diseñado e implementado en una caja de control para recolectar datos sobre los cultivos. Los sensores de humedad del suelo se utilizan para monitorear el campo, conectándose a la caja de control. El segundo componente es una aplicación basada en la web que fue diseñada para manipular los datos de cultivos e información de campo. Este componente aplicó la minería de datos con el fin de predecir la temperatura, y humedad del suelo para un manejo óptimo del crecimiento de los cultivos.

Figura 4.
Esquema del monitoreo IoT de plantas




Nota. Extraído de (Mohanraj et al., 2016)

El componente final se utiliza para controlar el riego de los cultivos a través de una aplicación móvil en un smartphone. Esto permite un control manual por parte del usuario, el control automático utiliza datos de los sensores de humedad del suelo para el riego.

En (Karim et al., 2017) se enfocan en un sistema de apoyo para la toma de decisiones (DSS), el trabajo evalúa el suministro de agua para el sector agrícola, explican que este recurso se está volviendo escaso debido al cambio climático, y existe una necesidad urgente de irrigar de manera más eficiente para optimizar el uso del agua. En ese contexto es inevitable que los agricultores utilicen un DSS. De hecho, la supervisión en tiempo real de las condiciones micro climáticas es la única manera de conocer las necesidades de agua de un cultivo. Explican también, que las redes de sensores inalámbricos (WSN) están jugando un papel importante con el crecimiento del IoT haciendo posible la supervisión a través de servicios Web.

Figura 5.
La arquitectura de control de un sistema de riego



Nota. Extraído de (Habib et al., 2019)

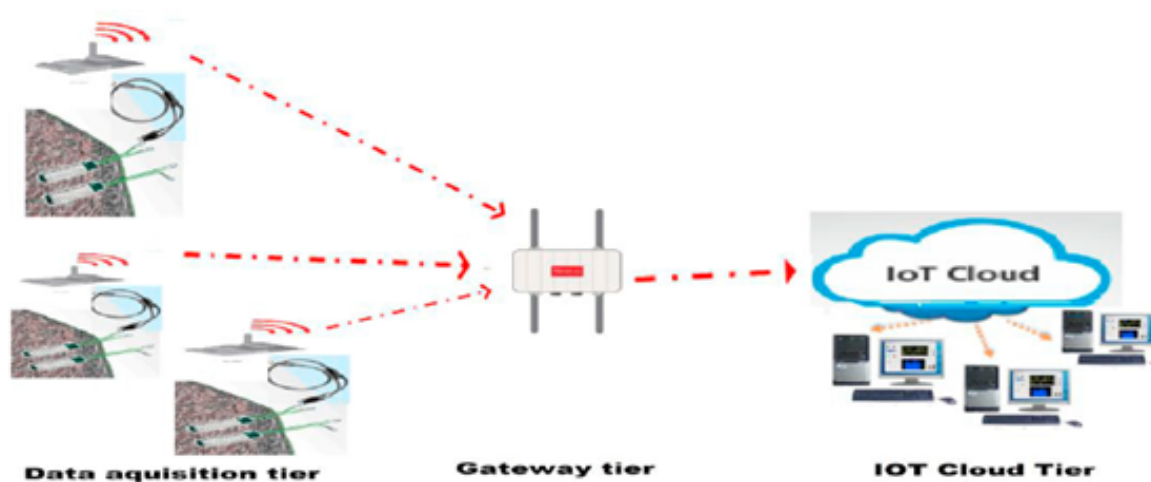
Esta investigación propone un sistema de alerta para el control de estrés hídrico de las plantas con tecnología IoT, este sistema estima las cantidades de agua requeridas por el cultivo. Para esta gestión de riego, el agricultor tiene un software para monitorear en tiempo real las variaciones de las condiciones del suelo, y por otro lado se le transmite un SMS a través de la aplicación cuando se alcance un nivel crítico para evitar el estrés hídrico (figura 6).

En (Brun-Laguna et al., 2018) se ocupan del monitoreo, aplicando redes inalámbricas de baja potencia (figura 7) para la supervisión de un huerto de melocotones. Las redes utilizan la tecnología SmartMesh IP para recopilar los datos de los sensores. Esta tecnología consiste en una malla de múltiples saltos y de autoformación, conocida como motas, que recogen y transmiten datos y un administrador de red que controla y gestiona el funcionamiento de red y seguridad e intercambia datos con una aplicación de host.

En (Foughali, Fathallah, & Frihida, 2018) también presentan un sistema de monitoreo para la toma de decisiones, en este caso para la enfermedad de tizón tardío, logrando implementar un tratamiento. Esta enfermedad, afecta a las plantas de papa y tomate pudiéndose pudrir en un plazo de dos semanas.

Figura 6.

Arquitectura del sistema de alerta para el control de estrés hídrico



Nota. Extraído de (Karim et al., 2017)

La aplicación está basada en una red de sensores y un servidor en la nube para almacenar la información sobre temperatura y humedad (figura 8). El sistema le notifica al agricultor por SMS cuando se puede producir el primer ataque de la enfermedad, esta predicción está basada en las condiciones meteorológicas y permite estimar la cantidad de fungicida necesaria a aplicar.

(Hernández-Rojas, 2018) orienta su tesis doctoral en el estudio de una amplia variedad de tecnologías heterogéneas de IoT y dispositivos con recursos limitados que interactúan entre sí. Debido a tales restricciones, los dispositivos de IoT generalmente requieren protocolos livianos que optimicen el uso de los recursos y el consumo de energía. Explica, que entre los diferentes dispositivos comerciales de IoT, los Beacons, dispositivos basados en Bluetooth y BLE (Bluetooth Low Energy), y que transmiten paquetes de datos para notificar su presencia, han experimentado un notable crecimiento. El objetivo de esta tesis fue aportar una arquitectura general de telemetría (figura 9), usando sensores inteligentes con BLE. La aplicación desarrollada muestra un Gateway IoT sobre un smartphone con sistema operativo Android.

Figura 7.

Dispositivos IoT desplegados en un huerto de melocotones



Nota. Extraído de (Brun-Laguna et al., 2018)

Este Gateway integra un cliente MQTT y dispone de las funcionalidades necesarias para empaquetar los datos de los sensores y enviarlos hacia el brocker MQTT residente en una cloud computing, también desarrolló una interfaz para que un usuario local pueda monitorear y controlar la WSN creada. En su tesis también se explica el diseño de un proyecto de agricultura inteligente, para controlar el riego de una plantación de banano de forma automatizada (figura 10).

En (Chlingaryan, Sukkarieh, & Whelan, 2018) estudian un sistema de monitoreo para realizar una estimación del rendimiento y una gestión optimizada del nitrógeno, que es esencial en la agricultura. En este estudio indican que los sistemas de teledetección se están utilizando para la construcción de herramientas de apoyo a la toma de decisiones para los sistemas agrícolas de la actualidad, con el fin de mejorar el rendimiento y la gestión del nitrógeno.

Figura 8.
Interfaz de monitoreo para la enfermedad de tizón tardío




Nota. Extraído de (Foughali et al., 2018)

Sin embargo, las tecnologías basadas en teledetección requieren el procesamiento de enormes cantidades de datos, difíciles de tratar, por lo que se está prestando mayor atención a los métodos de Machine Learning, esto es debido a la capacidad de los sistemas basados en aprendizaje automático para procesar un gran número de entradas y manejar datos no lineales.


En (Sabarina & Priya, 2015) también enfocan los análisis predictivos que se pueden utilizar para tomar decisiones más inteligentes en la agricultura mediante la recopilación de datos en tiempo real sobre la calidad del suelo, clima, la madurez de los cultivos e incluso los costes y la disponibilidad de equipos y mano de obra. En la agricultura inteligente es importante la eficiencia y el rendimiento del análisis de datos, lo que tiene que ver con el BigData. Se deben extraer los datos básicos, pequeños pero capaces de representar todo el contenido para realizar el análisis. Esta investigación explica cómo reducir sistemáticamente el tamaño de grandes datos mediante la aplicación de reducción de características basado en tensores.

Figura 9.
Arquitectura IoT de un sistema de telemetría



Nota. Extraído de (Hernández-Rojas, 2018)

Figura 10.
Diagrama general sistema de control de riego basado en IoT




Nota. Extraído de (Hernández-Rojas, 2018)

En (Kamilaris et al., 2017) también hacen énfasis a las grandes cantidades de datos que se generan a un ritmo sin precedentes. El análisis de estos datos permitiría a los agricultores y a las empresas extraer valor de ellos, mejorando su productividad. Sin embargo, aunque el análisis de grandes cantidades de datos está conduciendo a avances en varias industrias, llegan a la conclusión que todavía no se ha aplicado ampliamente en la agricultura.

En (Dos Santos, Pessin, Da Costa, & Da Rosa Righi, 2019) ya combinan las redes de sensores inalámbricos con las predicciones, presentan un modelo llamado “AgriPrediction” que combina un sistema de red inalámbrica de corto y medio alcance con un motor de predicción para anticiparse a los posibles problemas del cultivo de forma proactiva, notificando al agricultor rural las medidas correctoras lo antes posible. Para ello, se basan tanto en la tecnología LoRa IoT como en el modelo de predicción ARIMA. Ellos muestran la viabilidad de utilizar LoRa en zonas rurales, además de proporcionar las ventajas de contar con un sistema de predicción para observar los problemas relacionados con la humedad y la temperatura del suelo (figura 11).

Figura 11.
Módulo gateway LoRa



Nota. Extraído de (Dos Santos et al., 2019)

En (Queralt, Gia, Zou, Tenhunen, & Westerlund, 2019) también le dan relevancia a las redes LPWAN (*Low Power Wide Area Network*) sobre otras tecnologías como Wi-Fi o Bluetooth en la agricultura. Explican que si bien el alcance en áreas urbanas es mucho mejor, es en áreas rurales abiertas donde el alcance de un sólo gateway se puede extender más allá de los 10 km con LoRa y más de 30 Km con Sigfox. Esto sumado a la baja interferencia presentada hacen que sean tecnologías ideales para aplicaciones agrícolas como mediciones de humedad y temperatura del suelo, niveles de agua, etc.

En (Miles, Bourennane, Boucherkha, & Chikhi, 2020) también resaltan la importancia de utilizar redes LPWAN en el desarrollo de aplicaciones de IoT que requieren un bajo consumo de energía y bajas tasas de transmisión de datos. La investigación considera a LoRaWAN la red de comunicación más adecuada para aplicaciones IoT en la agricultura inteligente. Presentan un estudio del desempeño de la red de comunicación LoRaWAN en el contexto de una aplicación de IoT para una granja piloto, finalmente proponen un modelo matemático que predice la tasa de entrega exitosa de los paquetes para este tipo de redes considerando el número de nodos y la duración del intervalo de transmisión.

En (Roukh, Fote, Mahmoudi, & Mahmoudi, 2020) trabajan con estaciones meteorológicas, los datos entrantes pueden estar en varios formatos, como XML, JSON o archivos XLS recibidos de diferentes formas, como servicio web, archivo adjunto de correo electrónico o servidor MQTT, que dependen del fabricante del sensor que se utilice. Estos datos son transmitidos a la nube a través de diferentes protocolos de red, como Wi-Fi, 3G/4G o LoRa. Usan también la herramienta Apache Kafka para la transmisión de datos, esta herramienta permite manejar millones de mensajes por segundo. Después de procesar los datos, estos son guardados en PostgreSQL para NoSQL.

En el Perú, también, en los últimos años se están evidenciando estudios de estas tecnologías aplicadas a la agricultura, En (Ipanaqué, Belupú, Castillo, & Salazar, 2017), se desarrolló el monitoreo remoto de cajas de fermentación de cacao. Se diseñó un prototipo construido con sensores de temperatura que registran los datos en diferentes niveles de la caja de madera usada para fermentar y se envía la información a Internet (figura 12), también se desarrolló un sistema Web que recibe la información para que el usuario final pueda visualizarla

a través de gráficos permitiendo analizar el comportamiento en tiempo real.

Figura 12.
Prototipo IoT instalado en sala de fermentación



Nota. Extraído de (Ipanaqué et al., 2017)


2.3. Estado del arte: Monitoreo de plantaciones de banano

En (Jeger, Waller, Johanson, & Gowen, 1996) explican que el monitoreo en el manejo de plagas del banano es una actividad importante para la producción bananera comercial y/o en pequeña escala. Esta investigación es de 1996 y muestra que desde siempre se ha necesitado detectar la presencia de especies de plagas para brindar una alerta temprana de los problemas que puedan surgir. La información del monitoreo también puede servir para propósitos de política pública, como la necesidad de programas de erradicación.

En (Panigrahi, Thompson, Zubezcu, & Knox, 2021) afirman que el banano es uno de los productos agrícolas más valiosos en el mundo (figura 13). El trabajo se enfoca en el estrés hídrico, que debido a la creciente variabilidad de las precipitaciones y la competencia por los recursos hídricos se están constituyendo en importantes limitaciones de producción, tanto

como la producción comercial como para los pequeños agricultores. Por lo tanto, se están promoviendo ampliamente las inversiones en sistemas de riego más eficientes y tecnologías de ahorro de agua para aumentar la productividad del agua a través de una programación mejorada para reducir las pérdidas.

Figura 13.
Producción mundial de banano



Nota. Extraído de (Panigrahi et al., 2021)

En (Ray, Gerber, Macdonald, & West, 2015) abordan el tema de la relación entre el rendimiento y el clima. Esto para lograr las bases para pronosticar la cosecha de un cultivo y proyectar el impacto del cambio climático futuro. Según esta investigación aproximadamente un tercio de la variabilidad global del rendimiento de los cultivos se debe a la variabilidad climática.

En (Cabas, Weersink, & Olale, 2010) explican que la relación rendimiento-clima se puede derivar utilizando modelos empíricos y/o estadísticos. El uso de modelos biofísicos para evaluar el efecto del clima en el rendimiento de los cultivos requiere una gran cantidad de datos

para la parametrización y validación del modelo, entre ellos están el estado de los nutrientes y el agua del suelo, la fecha de siembra y de cosecha, y los datos meteorológicos (precipitaciones, temperatura y radiación solar). También hace falta incorporar a estos modelos biofísicos los efectos de las plagas y enfermedades de los cultivos porque algunos no los consideran (White & Hoogenboom, 2010).

En cuanto al trabajo con Inteligencia Artificial, también hay estudios como en (De Souza et al., 2019) donde se investigan la relación de las variables climáticas en el período de gestación del racimo de banano para predecir el tiempo de producción. Para eso, usan redes neuronales artificiales y estiman el período de cosecha de banano en regiones subtropicales de Brasil. Los datos climatológicos se midieron mediante estaciones automáticas. Según el análisis de resultados, con estos datos climáticos la estimación de la cosecha presentó un error de 0.3% y coeficiente de determinación R^2 de 89%. Se pudo verificar que las redes neuronales artificiales presentan un alto porcentaje de acierto en la recolección de la cosecha, esto se confirma por el bajo error cuadrático de los resultados. De esta manera, consiguieron un modelo como herramienta de gestión para que los productores de banano puedan pronosticar su producción y cumplir con la demanda del mercado.

2.4. Requerimientos de las plantaciones de banano

La producción de banano depende de varios factores, tales como el tipo de cultivo, las condiciones agroclimáticas, el tipo de suelo, el nivel de riego, las plagas y enfermedades que le afectan. En términos generales, los sistemas para el cultivo y manejo del banano se clasifican según el clima (tropical o subtropical) y el tipo de banano (si es para postre o para cocina) (Panigrahi et al., 2021).

Los bananos tropicales de exportación son principalmente para postre y se cultivan en América del Sur, el Caribe, África Occidental y Filipinas. Estos pertenecen al subgrupo Cavendish (Grupo Triploide AAA) y forman la base de la mayor parte del consumo comercializado (15%) en todo el mundo (Ploetz, Kema, & Ma, 2015). La producción de banano se divide en dos sistemas distintos: fincas de plantaciones orientadas a la agroexportación comercial a gran escala, y fincas de pequeños agricultores que suelen actuar subcontratados para las fincas más

grandes. Estos agricultores suelen tener áreas de 10 a 50 ha, tienen dificultades para cumplir con los criterios del mercado de exportación debido a su baja producción y técnicas de manejo tradicionales (Wunder, 2001).

La producción de banano de calidad para la exportación del mercado depende de cinco factores principales:

- Suelos y nutrición vegetal.
- Riego y drenaje.
- Tipos de variedades cultivadas.
- Densidades de siembra y manejo de los retoños.
- Manejo de enfermedades.

Una deficiencia en cualquiera de estos factores puede afectar negativamente la calidad y el rendimiento de la plantación (Panigrahi et al., 2021).

2.4.1. Requerimientos de riego

La escasez de agua es una amenaza importante para la agricultura mundial, cuando las raíces de la planta no absorben suficiente agua da como resultado la reducción del rendimiento de los cultivos (Salekdeh, Reynolds, Bennett, & Boyer, 2009). En los últimos años se prevé que los eventos relacionados con el cambio climático global, como el clima extremo, aumenten: las precipitaciones serán más intensas y los períodos secos serán más prolongados (X. Wang, Jiang, & Lang, 2017). Esto pondrá en peligro la sostenibilidad de muchos sistemas agrícolas y amenazará la productividad y la seguridad alimentaria a largo plazo (Jarraud & Steiner, 2014).

Se ha proyectado un crecimiento de los períodos secos por lo que aumentarán las tasas de evapotranspiración del cultivo, esto combinado con lluvias muy irregulares, van a reducir la humedad del suelo y conducirán al estrés hídrico de las plantaciones. El cultivo de banano necesita de gran cantidad de agua para maximizar su rendimiento (Pawar, Dingre, & Bhoi, 2017). Por eso, el riego se ha vuelto inevitablemente importante para amortiguar la variabilidad climática más extrema y la incertidumbre de las precipitaciones.

A diferencia de muchos otros cultivos, el banano tiene un ciclo de desarrollo desde el trasplante hasta la cosecha de alrededor de 10 a 14 meses en condiciones óptimas, pero esto puede retrasarse cuando el suministro de agua del cultivo no es confiable (Vosselen, 2005). Según (Van Asten, Fermont, & Taulya, 2011), un déficit de 100 mm de lluvia mensual durante el ciclo del cultivo del banano puede reducir el peso del racimo hasta en un 9 %. También se ha informado de que las regiones con menos de 1100 mm anuales de lluvia pueden sufrir pérdidas de rendimiento de entre el 20 y el 65%.

(Varma & Bebber, 2019) explica que los cambios globales en el rendimiento del banano están impulsados por un aumento de la temperatura en el pasado reciente. Estos aumentos de temperatura aumentan los riesgos de plagas y enfermedades y por consecuencia un aumento de la demanda de agua.

2.4.2. Requerimientos de nutrientes en el suelo


Un buen crecimiento de la plantación de banano depende de las propiedades del suelo (Orozco-Santos et al., 2008). La calidad del suelo es la capacidad que tiene un tipo de suelo específico para funcionar eficientemente y sostener la productividad de las plantas apoyando en su salud. La baja fertilidad del suelo es una limitación importante común en la producción de banano (Nyombi et al., 2010). Los suelos altamente degradados se caracterizan por un bajo contenido de materia orgánica, alta acidez, estructura deficiente y capacidad limitada para suministrar cationes básicos, incluidos el calcio y el magnesio (Zhu et al., 2010).

Para lograr un mejor control de las plagas y enfermedades se deben mejorar las condiciones de desarrollo y la fertilidad del suelo. Es así que un aporte adecuado de calcio, potasio, magnesio y nitrógeno permiten desarrollar plantas más fuertes y más resistentes a las enfermedades que se puedan presentar (Romero, 1998).

Está demostrado que el uso de fertilizantes químicos en cantidades razonables ha aumentado la disponibilidad de nutrientes del suelo, las concentraciones de nutrientes foliares y la producción de banano sin embargo, el exceso de su aplicación puede causar grandes daños (Smithson, McIntyre, Gold, Ssali, & Kashaija, 2001). En (Orozco-Santos et al., 2008) concluyeron que cuando las cantidades de nitrógeno están alrededor de 300 kg/Ha/año tienen

mayor tolerancia a la plaga de Sigatoka negra que es una de las que más afecta a la producción mundial de banano. En Uganda lograron reducir la incidencia de la Sigatoka negra aumentando la fertilización con calcio, magnesio y el contenido de materia orgánica en el suelo (J. Zhang, Li, Zhang, Christie, & Li, 2020). Por otro lado, el desequilibrio de nutrientes, y en particular el uso excesivo de nitrógeno fertilizante, a menudo conduce a la acidificación del suelo (Guo et al., 2010), y esto acelera la pérdida de cationes básicos como el calcio y el magnesio del perfil del suelo, lo que conduce a una mala calidad del banano.

El calcio hace una contribución importante a la calidad de la fruta, la literatura indica que las frutas de las plantas de banano deficientes en calcio son de menor calidad, además la cáscara de la fruta se rompe fácilmente cuando el banano llega a su maduración (Shor & Weldon, 2018). Otro nutriente importante es el potasio, ya que juega un papel importante en la fotosíntesis de la planta. Otra forma de mantener el rendimiento y calidad e los cultivos en suelos ácidos es la aplicación de la cal, sin embargo una aplicación excesiva puede disminuir las concentraciones de calcio en el suelo (Holland et al., 2018). También están los abonos orgánicos, eficaces para mejorar la acidez y calidad el suelo aumentando su pH.



Capítulo 3

Marco teórico


3.1. Internet de las cosas (IoT)

La comunicación tecnológica ha ido evolucionando a lo largo del tiempo, a mediados de los 80 ocurría la fase previa a Internet, la comunicación se limitaba a llamadas por voz a través de las líneas telefónicas fijas y mediante el servicio de mensajes de texto (SMS), después las comunicaciones mejoraron con el uso de dispositivos móviles. Con el paso del tiempo, el término Internet surgió y se convirtió en una nueva plataforma de comunicación, apareciendo también, la posibilidad de transmitir voz a través del protocolo de Internet VoIP. En esta etapa ya se podían enviar mensajes de gran tamaño, es decir, un correo electrónico capaz de asociar archivos adjuntos, información, entretenimiento, esta fue la fase de Internet de contenido.

La siguiente fase fue la de Internet de Servicios, que se centró en aplicaciones software para la productividad electrónica y el comercio electrónico, etc. La cuarta fase, es decir, la Internet de las personas fue la fase en la que las personas se asociaron entre sí a través de las redes sociales como Facebook, Skype, Youtube, etc. En la actualidad este concepto de Internet ha quedado muy atrás evolucionando al paradigma de IoT (figura 14). Esta tecnología que combina los recursos existentes en Internet para obtener el control de dispositivos (cosas), fue propuesta en los laboratorios de identificación automática del Instituto Tecnológico de Massachusetts (MIT) a principios de los 90. Sin embargo, no fue hasta 1999 cuando se desarrolló la primera “cosa” conectada a Internet, una cafetera (Jia, Feng, Fan, & Lei, 2012).

Más tarde, ese mismo año, se desarrolló el primer dispositivo controlado por Internet del mundo, una tostadora que se podía encender y apagar remotamente (Welbourne et al., 2009) (M. Zhang, Sun, & Cheng, 2012).

Figura 14.
Evolución de la internet desde pre- internet hasta IoT



Nota. Extraído de (Khanna & Kaur, 2019)

La era actual es la de IoT. Funcionalmente tiene la capacidad de conectar dispositivos a través de Internet. Por lo tanto, estos dispositivos pueden comunicarse entre sí y realizar una serie de actividades según las indicaciones programadas. Sin embargo, la era actual podría no considerarse como el final del camino del concepto. Últimas investigaciones (Khanna & Kaur, 2019) están tratando de incorporar los conceptos de Inteligencia Artificial a los dispositivos interconectados para que puedan tomar las decisiones necesarias y actuar sin la intervención humana. Entonces se puede denominar la próxima fase como la Internet de las cosas impulsadas por la Inteligencia Artificial. En la era moderna de la computación, la IoT ha atraído cada vez más la atención para la implementación de un ecosistema de alta calidad basado en la automatización, servicios innovadores y fiables, y una mayor productividad. Por este motivo, esta tecnología abarca actualmente una amplia gama de aplicaciones en los


ámbitos de la educación, la sanidad, la agricultura, seguridad gubernamental, la industria, etc. Los recursos que necesita las aplicaciones de IoT son de naturaleza heterogénea, por ejemplo, almacenamiento, procesador, red, nodos de sensores, energía, etc. El reto obvio es cómo gestionar estos recursos limitados de manera eficiente. Recientemente se han hecho varios intentos para lograr una gestión óptima de los recursos utilizando diversos esquemas de programación (Chowdhury & Raut, 2018). Si bien el término IoT se utiliza ampliamente en la actualidad, en (Nord, Koohang, & Paliszkiewicz, 2019) sostienen que no existe una definición común de lo que abarca la Internet de las Cosas. El objetivo del IoT es similar en un sentido amplio, independientemente de las variaciones en la definición. En general, la IoT se refiere a una red de redes de puntos finales o “cosas” identificables de manera única que capturan y comparten datos. El aspecto funcional de la IoT es unir todos los objetos del mundo de tal manera que los seres humanos tengan la capacidad de controlarlos a través de Internet.

El ámbito mundial el uso del IoT es masivo y está creciendo exponencialmente. El mundo digital emergente ha sido testigo recientemente de la proliferación y el impacto de los dispositivos habilitados para el IoT. Esta tecnología, aunque ha proporcionado nuevas oportunidades también a ha planteado varios retos a un nivel de preocupación cada vez mayor (Nord et al., 2019). Con el IoT, también llega una gran producción de datos, ya que es evidente el despliegue masivo de sensores y dispositivos. Sin embargo, el procesamiento de grandes volúmenes de datos supone un reto debido a la limitación de los recursos computacionales, de red y de almacenamiento en el mismo dispositivo de IoT (Habib et al., 2019). También cada vez es más necesario contar con una infraestructura de IoT que garantice un tiempo de respuesta reducido para proporcionar aplicaciones en tiempo real sensibles a la latencia, como la vigilancia de la salud, la gestión de desastres y los hogares inteligentes. La computación en la nube ofrece un medio para proporcionar tales requisitos, a través de una capa intermedia virtualizada para proporcionar servicios de datos, almacenamiento y redes entre los centros de datos en nube y los usuarios finales (Gill, Garraghan, & Buyya, 2019).

Aunque hay ligeras diferencias en los modelos arquitectónicos para IoT, un sistema de esta tecnología contiene básicamente tres capas (figura 15), una capa física que percibe el entorno físico y la vida humana tan importante; una capa de red que transforma y procesa los

datos del entorno percibido; y una capa de aplicación que ofrece servicios inteligentes según el contexto (Čolaković & Hadžialić, 2018). En (Muangprathub et al., 2019) describen tres capas básicas también, la capa de cosa o dispositivo, que es la infraestructura básica de IoT, donde están los sensores y pueden utilizar tecnologías como la identificación por radiofrecuencia (RFID), las Wireless Sensor Network (Redes de Sensores Inalámbricos, WSN) y la inteligencia incorporada; la capa de conectividad, que incluye los Gateway y Core Network y la capa de nube, esta capa es muy importante, ya que el IoT no funciona sin aplicaciones basadas en nube para interpretar y transmitir los datos que vienen de múltiples sensores.

Figura 15.
Arquitectura básica para IoT



Nota. Extraído de (Nord et al., 2019)

La IoT también enfrenta riesgos de seguridad, por eso en la actualidad se está utilizando la tecnología blockchain, debido a su enfoque descentralizado y distribuido que garantiza los requisitos de seguridad necesario para continuar con el desarrollo de estas aplicaciones. La combinación del blockchain y el IoT allana el camino a nuevos y novedosos modelos de negocio y aplicaciones distribuidas para las industrias, renovando operaciones como la gestión de la logística alimentaria, por ejemplo, aunque, todavía hay algunas limitaciones que deben ser resueltas en el futuro (Q. Wang, Zhu, Ni, Gu, & Zhu, 2020). El IoT debe permitir una

conectividad sin fisuras en cualquier momento y en cualquier lugar, por parte de cualquier persona y hacia cualquier lugar, a fin de proporcionar servicios inteligentes (Čolaković & Hadžialić, 2018).

3.2. Agricultura inteligente

La Agricultura Inteligente está basada en sistemas integrados para la gestión de los cultivos que combinan las tecnologías de información y comunicación (TIC) con industrias agrícolas para brindar información basada en las necesidades reales del cultivo (Tohidyan Far & Rezaei-Moghaddam, 2017). Esta información se utiliza para determinar, analizar y gestionar los cambios dentro de una plantación para analizar la rentabilidad, sostenibilidad y la conservación óptima de las plantaciones (Maes & Steppe, 2018).

La Agricultura Inteligente se refiere al uso de tecnología que ayuda a los agricultores en la gestión sus campos de una manera eficaz. Hoy en día, las innovaciones tecnológicas están reformando las prácticas agrícolas tradicionales. La agricultura inteligente no está orientada a realizar mediciones precisas, sino a acceder a los datos y la aplicación de estos datos (Divakar & Sushma, 2018). El objetivo principal es identificar cómo se puede utilizar la información recopilada de una manera "inteligente" (Mohd Kassim et al., 2014). Los agricultores pueden usar dispositivos móviles inteligentes, como teléfonos inteligentes y tabletas, para acceder a datos agrícolas en tiempo real (estado del suelo y de las plantas, riego, fertilización, malezas, clima, etc.). Como resultado, los agricultores pueden actuar sobre la base de datos sólidos e intervenir cuando sea necesario, en lugar de su intuición tradicional.

Las tecnologías de la Agricultura Inteligente incluyen (Khanna & Kaur, 2019):

- Predecir y monitorear los rendimientos de los cultivos.
- Usar sensores remotos para medir una variedad de parámetros de campo.
- Herramientas de software de soporte de decisión.
- Aplicación de precisión de insumos, como fertilizantes, pesticidas y semillas usando la robótica.

El objetivo básico de la Agricultura Inteligente es proporcionar métodos para que los agricultores puedan recopilar datos con el fin de identificar variables que tienen efecto sobre el rendimiento del cultivo (Tzounis, Katsoulas, Bartzanas, & Kittas, 2017), esto conlleva, por ejemplo, a usar el insumo correcto, en el lugar correcto y en la cantidad correcta (Chlingaryan et al., 2018). Los sensores actuales ofrecen valores muy precisos del estado de los cultivos, y los actuadores son capaces de gestionar el riego, amortiguar los factores climáticos o enriquecer el suelo con los nutrientes necesarios (Barbedo, 2019). Cuando es apropiado, las técnicas de inteligencia artificial también se ponen en juego para mejorar aún más la producción en la Agricultura Inteligente, reduciendo las enfermedades y la necesidad de intervención humana en las actividades regulares. Esto es indispensable en casos extremos donde se deben realizar acciones de control aún más precisas. Por lo tanto, la automatización es, sin duda, el futuro de la agricultura, pero se necesitan nuevas arquitecturas para unificar el hardware y software, que aseguren el manejo de los cultivos de manera eficiente (Zamora-Izquierdo et al., 2019).

Resumiendo, se puede decir que la agricultura inteligente es una teoría de supervisión agrícola que requiere detectar, calcular y reaccionar ante inconsistencias dentro del mismo campo y otros rendimientos del cultivo.

El objetivo principal es proporcionar un sistema de apoyo para administrar todo el campo de cultivo con el objetivo de optimizar las ganancias junto con la preservación de los recursos. La predicción del clima y el efecto de diferentes fertilizantes con la ayuda de sensores remotos y sensores para la salud de los cultivos son los pasos iniciales de una agricultura inteligente (Suprem, Mahalik, & Kim, 2013).

En segundo lugar, la agroindustria es el término profesional usado con todo lo relacionado a los rendimientos agrícolas. Es un híbrido de negocios en la agricultura que consiste en mejoramiento, producción de rendimiento, agroquímicos, aparatos agrícolas y suministro de semillas y también la estrategia de comercialización y distribución. Los representantes y organizaciones que afectan la cadena de alimentos y fibras son parte de esta estructura de agronegocios (N. Wang, Zhang, & Wang, 2006).

Otro aspecto de gran importancia en la agricultura moderna es el manejo de los problemas en términos de rendimiento, impacto atmosférico, seguridad alimentaria y

sostenibilidad en las circunstancias imperantes. Dado que el requerimiento mundial de cultivos aumenta rápidamente, la producción de cultivos debe incrementarse junto con su disponibilidad oportuna y alta calidad nutricional. Esto se puede lograr protegiendo el ecosistema natural mediante prácticas agrícolas sostenibles aquí es donde aparece el concepto de gestión agrícola que se basa en observar, medir y responder a los incrementos de variabilidad entre campos e intracampo.

Además de estos aspectos de la industria agrícola actual, el campo de la agricultura se enfrenta a diversos problemas, por ejemplo, tratamiento inadecuado de los cultivos, infección por plagas, riego irregular, etc. bajo rendimiento resultado de la incorporación de demasiados productos químicos. Sin embargo, no es posible dar una solución generalizada a todos los problemas. Para abordar estos problemas, deben tratarse mediante la observación e investigación instantáneas de todos los aspectos y ocurrencias. Una solución a esta condición es posible utilizando la inteligencia artificial en general y el aprendizaje automático en particular. El aprendizaje automático puede facilitar a los agricultores información para aumentar la producción de cultivos y disminuir el costo inicial, así como para equilibrar las pérdidas que ocurren durante condiciones extremas naturales.

3.2.1. Tipos de sensores en la agricultura inteligente

Existen varios tipos de sensores que se pueden usar para medir y calcular los parámetros de un campo agrícola. Los principios básicos de estos sensores y sus especificaciones relacionadas se describen a continuación.

- **Sensor de temperatura:** En la agricultura, la temperatura del suelo especifica el tipo de cultivo que se puede cultivar en un campo. La temperatura controla los procesos de desarrollo de la planta, como la fotosíntesis, la transpiración, la absorción, etc. Cada cultivo tiene un rango de temperatura diferente en el que puede crecer. Fuera de este rango, las enzimas esenciales para el crecimiento se vuelven inactivas. El sensor de temperatura proporciona alertas si la temperatura sube o baja de cierto umbral (Futagawa, Takao, Ishida, Sawada, & Iwasaki, 2009).
- **Sensor de velocidad del viento:** En un campo, generalmente es necesario observar

fenómenos, como modificaciones en la velocidad y dirección del viento. El sensor de velocidad del viento debe montarse a una altura adecuada, dependiendo del cultivo.

- Sensor de contenido de agua del suelo: Se utiliza en una amplia gama de áreas científicas. El contenido de agua del suelo es la relación entre la cantidad de agua presente en el suelo y la cantidad total del suelo. Se expresa por el cambio en el valor de capacitancia, que depende de la constante dieléctrica del suelo. Puede variar de 0 (completamente seco) al valor de la porosidad de los materiales en la saturación (Tarendra et al., 2009). Las medidas dependen del tipo de suelo; por lo tanto, el sensor debe calibrarse para cada ubicación.
- Sensor de potencial hídrico del suelo: Este sensor evalúa la tensión o succión del agua del suelo, que es una denotación del esfuerzo del sistema de raíces de la planta mientras se extrae el agua del suelo. Se puede usar para estimar la cantidad de agua almacenada en el suelo o la cantidad de riego que se requiere para alcanzar la cantidad deseada de agua en el suelo.
- Sensor de conductividad eléctrica del suelo: La conductividad eléctrica (CE) del suelo se utiliza para medir la concentración de solutos del suelo para evaluar el peligro de salinidad del suelo. El agua de riego contiene al menos un poco de sal. Si las sales se acumulan alrededor de la zona de la raíz de un cultivo, dañan las plantas, reducen los rendimientos y pueden causar daños a largo plazo en la tierra misma. El contenido de sal de un suelo se mide utilizando un sensor de conductividad eléctrica del suelo, que se basa en la ley de Faradays.
- Sensor de pH: El pH es una medida de acidez y alcalinidad en una solución dada. En la agricultura, el valor del pH del suelo entre 5.5, 6.5 se considera no óptimo, ya que indica falta de disponibilidad de nutrientes para el suelo. Los agricultores deben regular el valor del pH mediante la utilización de fertilizantes alcalinos o ácidos, lo que también mejora la producción agrícola (Goulding, 2016). Si consideramos que el valor del pH del suelo varía dentro del campo, una de las mejores prácticas es aplicar espacialmente el fertilizante de acuerdo con la variación del pH del suelo.

- **Sensor de buscador de malezas:** El buscador de malezas es una unidad autónoma, que generalmente está equipada con componentes ópticos y electrónicos para la detección y pulverización de malezas. La unidad consta de una fuente de luz activa y un sensor de rociado. El sistema óptico permite que la unidad detecte y rocíe solo malezas en el campo. El uso sistemático del sistema puede reducir significativamente el uso de herbicidas.

3.2.2. Aplicaciones del Machine Learning en la agricultura

Las tecnologías inalámbricas combinadas con la computación avanzada están cambiando las comunicaciones. Las redes inalámbricas industriales pueden mejorar la supervisión y el control de todo el sistema mediante la explotación conjunta de paradigmas de computación distribuida y comunicación de interacción masiva (Ascorti et al., 2017). Algunas de las aplicaciones utilizadas en los sectores agrícolas son:

- Predicción de rendimiento
- Detección de plagas y enfermedades
- Detección de malezas
- Manejo del suelo
- Cómo reconocer una planta
- Cómo gestionar la calidad del cultivo
- Manejo de riego

Predicción de rendimiento

Hay muchos factores a través de los cuales un agricultor puede obtener resultados óptimos en la agricultura. Uno de estos factores es predecir el rendimiento del cultivo. Este factor incluye la fertilidad del suelo, el proceso de riego, las condiciones climáticas y el control de plagas. Si el agricultor no sigue estos cuatro factores correctamente durante la agricultura, existe un gran riesgo de dañar el cultivo (RAI, DAS, & SINGH, 1967).

Por ejemplo, en (Ramos, Prieto, Montoya, & Oliveros, 2017) mostraron cómo contar los frutos de café automáticamente utilizando un sistema de visión artificial y machine learning. (Amatya, Karkee, Gongal, Zhang, & Whiting, 2015) desarrolló otro sistema de visión artificial que automáticamente sacude los árboles y captura los frutos de la cereza durante la etapa de cosecha y también detecta las ramas ocluidas y las cerezas que no son claramente visibles. En contraste, durante la cosecha de cerezas se requiere más mano de obra, que toma alrededor del 50 por ciento de su costo de producción anual. Para reducir este costo, se han utilizado tecnologías de cosecha mecanizada como actuadores de ramas que hacen vibrar los frutos de la cereza para que puedan ser liberados.

Detección de plagas y enfermedades

El control de plagas y enfermedades es uno de los principales problemas de la agricultura actual. Uno de los métodos para controlar enfermedades y plagas es rociar uniformemente los plaguicidas sobre los cultivos, lo que requiere una alta eficiencia pero no es económico, y también presenta el riesgo de efectos secundarios como la contaminación del agua subterránea y el impacto adverso en la vida silvestre y el ecosistema.

En (Ebrahimi, 2017) desarrollaron una máquina que ayuda a identificar parásitos en el entorno del invernadero a través del procesamiento de imágenes. El método de visión artificial se puede utilizar para la clasificación y el direccionamiento de parásitos. La metodología de procesamiento de imágenes junto con el Support Vector Machine utilizando el índice de color demostraron ser exitosos para la detección de estos objetivos con alta eficiencia. En Moshou (Moshou et al., 2004) desarrollaron un dispositivo óptico económico para la exposición remota de enfermedades, basado en la reflectancia en numerosas bandas de ondas. Investigaron la diferencia entre plantas sanas y enfermas en las primeras etapas de la enfermedad de la roya amarilla, las imágenes de campo se obtuvieron colocando un espectrógrafo. El modelo de discriminación cuadrática basado en la reflectancia de estas bandas de ondas clasifica los espectros de salud y enfermedad con un alto grado de éxito.

DetECCIÓN DE MALEZAS

Para obtener un buen rendimiento, la prevención de malezas es una de las principales tareas. La detección y prevención de malezas es difícil de diferenciar de los cultivos, por lo que se utiliza el aprendizaje automático mediante sensores. Esta técnica conduce a la detección y prevención precisas de malezas con un menor gasto y además no daña el medio ambiente.

En Pantazi (Pantazi et al., 2017) utilizaron sensores remotos para la discriminación de especies y para el mapeo de malezas. Se utilizó una cámara multispectral (verde-rojo-NIR) montada en un sistema de aeronaves no tripuladas (UAS) de ala fija para la adquisición de imágenes de alta resolución. La Red de Kohonen Supervisada (SKN), la Red Neural Artificial de Contrapropagación (CP-ANN) y la Red de Fusión XY (XY-F) se utilizaron para identificar *S. marianum* entre otra vegetación en un campo. Como características de entrada a los clasificadores, utilizaron las tres bandas espectrales de rojo, verde, infrarrojo cercano (NIR) y la capa de textura. Las tasas de precisión alcanzaron el 98.64 %.

MANEJO DEL SUELO

El manejo del suelo juega un papel clave en la eficiencia del rendimiento, la estabilidad ecológica y la salud humana, tanto directa como indirectamente. El suelo es un recurso natural diverso que tiene procesos complejos. La temperatura del suelo también juega un papel importante en las variaciones climáticas de un área y su comportamiento ecológico.

Los algoritmos de aprendizaje automático desempeñan un papel importante en la medición de la temperatura y la humedad del suelo para comprender la dinámica de los ecosistemas y su impacto en la agricultura. Por ejemplo, (Koley, 2014) utilizaron la técnica de back propagation para encontrar las propiedades del suelo en lugar de utilizar el método tradicional del modelo de regresión multivariante.

El objetivo de este trabajo fue analizar las principales propiedades del suelo como la materia orgánica, los nutrientes esenciales para las plantas, los micronutrientes que afectan el crecimiento de los cultivos y conocer el porcentaje de relación adecuado entre esas propiedades utilizando Machine Learning y redes neuronales. Aunque estos parámetros se

pueden medir directamente, su medición es difícil y costosa.

Reconocimiento de plantas

En comparación con el enfoque convencional para la clasificación de plantas mediante la comparación de la forma y el color de las hojas, el aprendizaje automático puede dar resultados exactos y más rápidos al analizar la morfología de las nervaduras de las hojas, lo que proporciona información adicional sobre las características de la hoja.

El objetivo principal es el reconocimiento automático y la categorización de diferentes variedades de plantas para evitar la intervención humana y también para minimizar el tiempo de categorización.

En (Grinblat, Uzal, Larese, & Granitto, 2016) utilizaron una red neuronal convolucional profunda (CNN) para identificar plantas a partir de patrones de venas foliares. Consideraron clasificar tres especies de legumbres diferentes: frijol blanco, frijol rojo y soja. La introducción de una CNN evita el uso de extractores hechos a mano. Además, este enfoque de aprendizaje profundo mejora significativamente la precisión de la canalización referida. También se demuestra que la precisión informada se alcanza aumentando la profundidad del modelo.

También en (Weiss, Biber, Laible, Bohlmann, & Zell, 2010) trabajaron en distinguir automáticamente entre especies de plantas, las cuales algunas especies se ven muy similares. Un enfoque para resolver este problema fue clasificar las especies mediante el uso de un conjunto de plantas de ejemplo y métodos de aprendizaje automático. Utilizaron un sensor LIDAR 3D y aprendizaje supervisado. Desarrollaron un conjunto de características invariantes de tamaño y rotación y determinaron cuáles fueron las más descriptivas. Además de estas características, también compararon diferentes métodos de aprendizaje. Resultó que los mejores métodos para la aplicación son funciones de regresión logística simple, máquinas de vectores de soporte y redes neuronales. Finalmente pudieron identificar correctamente más del 98 % de plantas.

Manejo de la calidad del cultivo

Para incrementar el valor del cultivo y reducir el desperdicio, es necesario clasificar la calidad del cultivo con un mínimo de error. Por eso es necesaria la identificación de características asociadas con la clase de cultivo.

Por ejemplo en (M. Zhang, Li, & Yang, 2017) trabajaron con el algodón, que es una fuente importante de fibra natural en todo el mundo. Sin embargo, la pelusa de algodón puede contaminarse con varios tipos de materias extrañas durante la cosecha y el procesamiento, lo que podría reducir su calidad e incluso producir productos textiles defectuosos. Los métodos de detección actuales detectan la presencia de materias extrañas en la superficie de la pelusa de algodón, pero no pueden detectar y clasificar de manera eficiente las materias extrañas que están mezcladas o incrustadas dentro de la pelusa. Este estudio se centró en la detección y clasificación de tipos comunes de materia extraña escondida dentro de la pelusa de algodón mediante un sistema de imágenes hiperespectrales de infrarrojo cercano de onda corta. Se empleó el análisis discriminante lineal (LDA) y SVM para clasificar la materia extraña a nivel espectral y de píxeles, respectivamente. Este estudio indicó que era factible detectar tipos de materia extraña botánica (por ejemplo, cubierta de semilla, semilla, tallo y hoja) y no botánica (por ejemplo, papel y paquete de plástico) que estaban incrustados dentro de la pelusa de algodón utilizando imágenes hiperespectrales.

Manejo del riego

El riego es una parte importante de la agricultura. Desempeña un papel importante en la productividad del rendimiento. El riego debe ser equilibrado, no se debe hacer en exceso y mucho menos que hay escasez de este. Para mantener estas condiciones, es necesario considerar ciertos factores, como son el tipo de suelo, la topografía de la tierra, el clima, el tipo de cultivo, la calidad del agua, etc.

En el trabajo de (Gu, Yin, Huang, Guo, & Chen, 2017) se desarrolló un modelo de agua de riego y rendimiento de cultivos, basado en un algoritmo genético mejorado (GA) y el algoritmo de Back Propagation (BP) como algoritmo de predicción de red neuronal. Con esto se pudo

predecir el rendimiento de maíz para diferentes sistemas de riego por goteo subterráneo. El modelo con el algoritmo GA-BP proporciona predicciones más precisas del rendimiento. El error medio es de solo 0,71%. El algoritmo GA-BP también acelera la convergencia de la red, mejora la precisión de la predicción y describe la relación entre el rendimiento y el agua de riego.

3.2.3. Aplicaciones del Deep Learning en la agricultura

El Deep Learning (Aprendizaje Profundo) ha transformado el sector agrícola a un nuevo nivel. Utiliza diferentes técnicas como la red neuronal convolucional, RNN y GAN. Esto da mejores resultados y fomenta el dominio de la agricultura. El aprendizaje profundo utiliza el procesamiento de imágenes y el estudio de la información con resultados eficientes. El intenso crecimiento de este campo ha mostrado buenos resultados en general, pero está emergiendo con mayor énfasis en el campo de la agricultura. Al comparar el aprendizaje profundo con un procedimiento común predominante, se puede decir que este método está superando la técnica de procesamiento de imágenes de uso común existente y además tiene una mayor precisión. Las redes neuronales y el back propagation son la base del aprendizaje profundo.

Redes neuronales convolucionales (CNN)

Las CNN se utilizan ampliamente en la agricultura ya que tiene una gran capacidad para el procesamiento de imágenes. Las principales aplicaciones del aprendizaje profundo en la agricultura se pueden clasificar como clasificación de plantas o cultivos, predicción de plagas y rendimiento, robots para cosechar, monitoreo de desastres, etc.

El problema de reconocimiento de enfermedades en las plantas se puede abordar principalmente mediante la clasificación de imágenes y patrones de hojas. Una de las arquitecturas de redes neuronales convolucionales más usada en la clasificación de plantas es la AlexNet. Con base en los resultados experimentales de Alexnet, se puede decir que con esta arquitectura de CNN se supera en eficiencia en comparación a los algoritmos del Machine learning. En (Karthik. et al., 2020) explican que la automatización en la detección y el diagnóstico de enfermedades de las plantas es una de las áreas de investigación desafiantes

que ha ganado una atención significativa en el sector agrícola. Los métodos tradicionales de detección de enfermedades se basan en la extracción de características básicas de las imágenes adquiridas para identificar el tipo de infección. Además, la ejecución de estos trabajos depende únicamente de la naturaleza de las características básicas seleccionadas. Esto se puede solucionar también con la ayuda de las redes neuronales convolucionales. Esta investigación presenta dos arquitecturas profundas diferentes para detectar el tipo de infección en hojas de tomate. La investigación trabajó sobre tres enfermedades, tizón temprano, tizón tardío y moho de las hojas. El trabajo aprovechó las características aprendidas por la CNN en varias jerarquías de procesamiento y logró una precisión general del 98% en los conjuntos de validación.

Hoy en día, están surgiendo nuevas tecnologías en el sector agrícola; por ejemplo, para el procesamiento de imágenes de alta calidad se utilizan vehículos aéreos no tripulados. Para los agricultores, operar máquinas altamente autónomas es bastante difícil. No es fácil operar estas máquinas sin supervisión.

También es necesario abordar, el uso sostenible de la tierra, se deben considerar ciertas condiciones, como la reducción de las emisiones de CO₂, la disminución de la degradación de la tierra y la mejora de los rendimientos económicos utilizando valiosos datos de satélites. Para la toma de decisiones en agricultura de precisión y agroindustria, la CNN y el algoritmo genético se han convertido en métodos convenientes con el uso de la traducción de imágenes de satélite. El pronóstico del tiempo es uno de los principales factores para los agricultores que se puede predecir también usando las CNN. De manera similar, la estimación del rendimiento de los cultivos es uno de los principales factores para los agricultores, los consumidores y el gobierno, que debe predecirse antes de la cosecha del cultivo.

Redes neuronales recurrentes (RNN)

La clasificación del terreno presenta desafíos en la agricultura, implica reconocer el tipo y la calidad de la tierra. En el pasado, muchas aplicaciones se basaban en la observación mono-temporal. Los métodos mono-temporales dependen de algunos factores como el clima. Para resolver los problemas relacionados con RNN, se introduce un modelo conocido como NARX

(Redes Neuronales No-lineales auto-regresivas con entradas externas). Con este método, los valores de predicción anteriores se consideran como entrada, y los valores actuales y anteriores se consideran como entrada externa. El sistema no solo juzga las entradas independientes sino también la respuesta previa del sistema que hace que el sistema sea más robusto.

Las RNN también se pueden usar para predecir el clima. En (Biswas, Sinha, Purkayastha, & Marbaniang, 2014) diseñaron tres modelos para la predicción del clima: autorregresivo no lineal con redes neuronales de entradas externas (NARXNN), modelo de razonamiento basado en casos y modelo de razonamiento basado en casos de segmentos. Presentaron un método de predicción de atributos meteorológicos múltiples para la predicción con un día de anticipación utilizando NARXNN en escala local. En este enfoque, un caso se representa de tal manera que puede capturar el comportamiento dinámico y caótico del clima, la base del caso se segmenta para capturar la estacionalidad del clima y luego NARXNN se utiliza para mapear las relaciones no lineales de los datos meteorológicos, así como el comportamiento dinámico del sistema durante un período de tiempo. Para el entrenamiento, validación y prueba de modelos, se utilizan los registros históricos recopilados de la estación meteorológica de 1980 a 2009.

3.3. Facilitadores técnicos para IoT

Esta sección presenta una descripción general de los componentes técnicos que se utilizan en el Internet de las Cosas.

3.3.1. Computación ubicua y sistemas embebidos

En la década de 1990 se inició la investigación sobre computación ubicua, esta tecnología se basa en la evolución y desarrollo de los sistemas embebidos (Kurkovsky, 2008), con la visión de que las plataformas de cómputo puedan reducir su tamaño e integrarse a los objetos físicos. El objetivo principal es tener acceso a los servicios de información en cualquier momento y lugar, donde la presencia de los sensores es casi invisible.

Los sistemas embebidos aparecieron en la década de 1960 cuando los primeros circuitos integrados y microprocesadores se usaron en los sistemas de ingeniería. Las primeras áreas de aplicación fueron las industrias aeronáutica y espacial, así como la industria

automotriz. Hoy en día, los sistemas embebidos están presentes en todas las áreas además de las ya mencionadas: dispositivos electrónicos de consumo, sistemas de entretenimiento, sistemas industriales, sistemas de telecomunicaciones y muchos más.

Los sistemas embebidos consisten en hardware y software integrados en sistemas electrónicos o mecánicos de un tamaño mayor (Henzinger & Sifakis, 2007). Las plataformas de hardware se basan en microcontroladores o sistemas basados en chips. Alrededor de la década de 1990 se empezaron a desarrollar también, sistemas operativos exclusivos para sistemas embebidos, si bien la intención de la computación ubicua ha sido desde el principio la interconexión y las funciones de computación en red, el enfoque de los sistemas embebidos siempre ha estado en la computación para tareas específicas. Los sistemas embebidos a menudo se enfrentan a varios requisitos, como capacidades de procesamiento en tiempo real y alta confiabilidad, restricciones de tamaño de memoria debido a, por ejemplo, limitaciones de espacio, tamaño, peso o costo, límites de consumo de energía y condiciones de operación potencialmente duras. Por eso los sistemas embebidos están definidos para un sólo propósito y no se basan en plataformas informáticas de uso general. Esto, sumado a los avances en las tecnologías de la comunicación y las tecnologías de los centros de datos para una informática eficiente conducen a una oportunidad de aprovechar la funcionalidad de los sistemas embebidos y, por lo tanto, de explotar las ventajas de IoT.

Un componente importante del Internet de las cosas es la interacción con los objetos o "cosas" del mundo físico. Las tecnologías clave en ese sentido son los sensores, que miden algunas propiedades físicas del objeto (por ejemplo, temperatura) y los actuadores que pueden actuar sobre el comportamiento del objeto (por ejemplo, encender un ventilador). Se han logrado importantes avances en el desarrollo de sensores y actuadores microscópicos, que se pueden producir a bajo costo y se pueden integrar de manera efectiva en un objeto físico. Los sistemas microelectromecánicos (MEMS) son una tecnología clave para sensores y actuadores a pequeña escala.

Otros desarrollos tecnológicos que permiten un uso más extendido de la computación ubicua son los avances en la electrónica de baja potencia y las tecnologías de baterías con mayor densidad de energía y mayor duración de la batería. La evolución de estas tecnologías

de captación de energía ofrecen mayor oportunidad de incorporar dispositivos con una dependencia reducida del suministro de energía local (Ku, Li, Chen, & Ray Liu, 2016).

3.3.2. Tecnologías de la comunicación

En las últimas dos décadas se ha desarrollado un número significativo de tecnologías de la comunicación con un impacto significativo en el IoT. Estas nuevas metodologías de procesamiento de señales distribuidas se destacan como habilitadores para los sistemas de IoT asistidos por la nube de próxima generación (Soatti et al., 2019).

Esto comprende tecnologías de comunicación por cable e inalámbricas. En particular, se desarrollaron soluciones de comunicación de máquina a máquina (M2M) para conectar dispositivos con aplicaciones. La mayoría de las soluciones de comunicación M2M están diseñadas específicamente para satisfacer una aplicación y necesidades de comunicación muy particulares.

Algunos ejemplos de estas aplicaciones específicas son la conectividad para control remoto de iluminación, monitores para bebés, aparatos eléctricos, etc. Para muchos de esos sistemas, las comunicaciones han sido diseñadas para un solo propósito. es así que una amplia gamas de dispositivos y objetos conectados se basan en tecnología M2M a través de protocolos patentados y no tanto a través de la conectividad de protocolo Internet (IP) de extremo a extremo (Liberg et al., 2020).

En el caso de los sistemas de comunicaciones inalámbricas, a mediados del decenio de 1990 se inició un importante esfuerzo de investigación y desarrollo con el desarrollo de las redes de área local inalámbricas, las redes de sensores inalámbricos (WSN) o las redes de sensores y actuadores inalámbricos (Akyildiz, Su, Sankarasubramaniam, & Cayirci, 2002), incluidas las redes inalámbricas industriales (Willig, 2008).

Los sensores necesitan comunicarse para enviar los datos detectados al centro de control. La conectividad puede ser totalmente inalámbrica o híbrida con cables. En este punto se explican algunas de las tecnologías de comunicación que se usan en el campo de IoT .

Zigbee

Zigbee opera en la banda ISM (Industrial, Científica y Médica) de 2.4 GHz, y se basa en el estándar IEEE 802.15.4. Además de proporcionar comunicación, Zigbee proporciona facilidades de enrutamiento, autenticación y redes de malla. Debido a esto, esta tecnología puede soportar 65.000 dispositivos en red.

En Zigbee se definen tres tipos de dispositivos: Dispositivos finales, enrutadores y coordinadores. Los sensores son dispositivos finales de Zigbee que no tienen capacidad de enrutamiento pero que pueden comunicar los datos al coordinador principal. El coordinador es el núcleo y la única estación de control de la red. Zigbee puede comunicarse en un rango de 10 a 20 metros, tiene un ciclo de trabajo bajo y un bajo consumo de energía. Por lo tanto, es adecuado para la gestión de redes de baja potencia (López Martínez, Blanco, Pérez Alonso, & Callejón Ferre, 2018).

GPRS

GPRS significa General Packet Radio Service. Fue estandarizado por el Instituto Europeo de Estándares de Telecomunicaciones (ETSI) y fue lanzado en el año 2000. Es un servicio basado en paquetes para dispositivos GSM (Sistema Global para Móviles). El GPRS no tiene una limitación de alcance y sus versiones avanzadas proporcionan una mayor velocidad de datos, ya que, los usuarios comparten los recursos, por lo que la demora depende de ello.

Se empezó a utilizar en los sistemas agrícolas para enviar alertas regulares al teléfono de los agricultores (Dan, Xin, Chongwei, & Liangliang, 2015). Estas alertas eran periódicas y requerían que el teléfono GSM del agricultor estuviera en la zona de cobertura. Esta tecnología también puede utilizarse para el registro de datos del entorno del sistema agrícola (Azaza, Tanougast, Fabrizio, & Mami, 2015). También es adecuado para la vigilancia a distancia de estos sistemas, en la mayoría de trabajos, el GPRS se utilizó para la comunicación entre el sensor y la estación base o con el gateway principal (Kassim et al., 2017).

La principal ventaja del GPRS es su amplia disponibilidad en todo el mundo, pero pronto podría desaparecer para la adquisición de servicios de mayor velocidad de datos, como los

4G y 5G. El GPRS es rentable para aplicaciones de baja tasa de datos como el monitoreo de invernaderos, pero 4G y 5G pueden no serlo.

Wifi

Wi-Fi significa Fidelidad Inalámbrica. Wi-Fi se basa en el estándar IEEE 802.11 y utiliza la banda de radiofrecuencia, es una marca registrada de Wi-Fi Alliance. Se lanzó a finales de los años noventa. Tiene un rango de comunicación de 20-100 m. La red Wi-Fi tiene un punto de acceso, a través del cual todos los dispositivos se comunican, proporciona una velocidad de 2-54 Mbps, por lo que los datos pueden ser enviados con una latencia tolerable (Thakur, Kumar, Kumar, Singh, & Singh, 2018). El uso de Wi-Fi para la comunicación entre sensores puede llevar a un alto consumo de energía y afectar a la vida útil de la red. Sin embargo, puede utilizarse para conectar múltiples sistemas agrícolas repartidos por una región con sistemas heterogéneos desplegados (López Martínez et al., 2018).

Bluetooth

Fue inicialmente estandarizado por el IEEE 802.15.1. Ahora es el Grupo de Interés Especial de Bluetooth (SIG) el que regula la estandarización y la licencia de esta tecnología. Bluetooth consume menos energía y fue desarrollado para WPAN (Wireless Personal Area Network). Puede soportar una velocidad de datos de 1 a 3 Mbps dependiendo de la versión. Los dispositivos Bluetooth de clase 3 tienen un alcance de 1 m, los de clase 2 tienen un alcance de 10 m y los de clase 1 tienen un alcance de 100 m. Esta tecnología necesita que los dispositivos formen una conexión antes de transmitir datos. En una comunicación, uno de los dispositivos actúa como maestro mientras que el otro actúa como esclavo. El nodo esclavo de una red puede ser un maestro en la red adyacente. El Bluetooth puede utilizarse para la comunicación entre sensores y, si las limitaciones de alcance lo permiten, también puede utilizarse para la comunicación entre sensores o entre un sensor y una estación base (Hong & Hsieh, 2016).

3.3.3. Tecnologías de la WWW para IoT

Uno de los componentes esenciales de Internet de las cosas son los avances que se han realizado en las tecnologías de la Web. Esto incluye actualizaciones que se han introducido

para proporcionar conectividad a objetos y dispositivos inteligentes que están limitados en sus capacidades de procesamiento y tamaño de memoria.


Esta exitosa base tecnológica de la comunicación por Internet y los protocolos Web ha sido seleccionada como base para la Internet de las cosas. Con la introducción de IPv6, las direcciones host en Internet han aumentado de 4 billones de dispositivos en IPv4 a más de 10^{38} direcciones. Un IoT basado en IPv6 parece ilimitado en cuanto a la cantidad de cosas que pueden conectarse.

La comunicación entre los hosts finales y los servidores en Internet generalmente se realiza a través de la World Wide Web (WWW), que es un espacio de información distribuida de recursos web a través de Internet. El enfoque original de la WWW era permitir el acceso humano a elementos de información distribuidos a través de Internet, por ejemplo a través de navegadores web que presentan diferentes tipos de información en un sitio web.

Los servicios web ampliaron el concepto al proporcionar comunicación entre diferentes dispositivos electrónicos a través de la WWW, donde la información se codifica en diferentes formatos de archivos. El protocolo web más común para acceder a los recursos web es el protocolo de transferencia de hipertexto (HTTP). HTTP sigue la arquitectura cliente-servidor basada en interacciones de solicitud y respuesta, donde un cliente envía solicitudes a un servidor que reacciona con mensajes de respuesta. Las solicitudes pueden contener métodos tales como GET, PUT, POST, DELETE para acceder o modificar recursos. En el contexto de IoT, un recurso puede ser un valor medido de un sensor al que se puede acceder desde un cliente a través de una solicitud GET, o puede ser un valor de control enviado a un actuador a través de una solicitud PUT. Se han realizado mejoras significativas para que los protocolos IP sean compatible con los servicios de Internet de las cosas. En la figura 16 se muestra una descripción general del protocolo IP para trabajar con IoT.

La capa central es la capa de red, donde IPv6 proporciona las capacidades de interconexión y enrutamiento. Los paquetes de Internet se pueden enviar a través de una variedad de sistemas de transmisión, como redes celulares, tecnologías de radio de corto o largo alcance, tecnologías de transmisión fija como Ethernet o comunicación por línea eléctrica, todo esto dentro de la capa física del modelo IP (Höller, Tsiatsis, Karnouskos, & Mulligan, 2018).

Figura 16.
Organización de los protocolos IP para IoT



Nota. Extraído de (Liberg et al., 2020)


Encima de la capa de red se encuentran los protocolos de transporte de Internet: el protocolo de control de transmisión (TCP) para un transporte confiable y el protocolo de datagramas de usuario (UDP) como protocolo de transporte no fiable. La seguridad de la capa de transporte (TLS) y la seguridad de la capa de transporte de datagramas (DTLS) proporcionan una conexión de transporte segura de un extremo a otro para TCP y UDP, respectivamente.

3.3.4. Tecnologías de baja potencia y área extendida (LPWA)

LPWA es un término genérico para un grupo de tecnologías que permiten comunicaciones de área extendida con nodos de bajo costo y menor consumo de energía. Son adecuadas para las aplicaciones de IoT que sólo necesitan transmitir pequeñas cantidades de información a larga distancia (Sinha, Yiqiao, & Hwang, 2017). A principios de 2013, ni siquiera existía el término "LPWA", sin embargo, a medida que el mercado de la IoT se expandía rápidamente, la LPWA se convirtió en una de las tecnologías de mayor crecimiento. Existen muchas de estas tecnologías de comunicación tales como LTE-M, SigFox, LoRa y NB-IoT (figura 17). Entre ellas, LoRa y NB-IoT son las dos tecnologías emergentes líderes, dentro de sus principales ventajas se tiene la duración de la batería, la cobertura y el alcance de la red, el modelo de despliegue y el coste (Sinha et al., 2017).

Estas tecnologías tienen 3 principales características que se explican detalladamente en el trabajo de (Muteba, Djouani, & Olwal, 2019):

Figura 17.
Tecnologías LPWA



Nota. Extraído de (Sinha et al., 2017)

- Bajo consumo: Hay varios factores de los que depende la vida útil de la batería, entre ellos, la topología de la red y el ciclo de trabajo. Se sabe que la topología de malla (Avonts & Blondia, 2016) se utiliza para ampliar la cobertura de la red inalámbrica de corto alcance, su alto costo de despliegue es una desventaja a la hora de conectar muchos dispositivos en largas distancias geográficas. Cuando hay mucho tráfico, algunos nodos se congestionan, lo que implica el agotamiento de la batería, lo que limita la vida útil de la red a unos pocos meses o años. Por lo tanto, la mayoría de las LPWA utilizan una topología estrella (Bai, Huang, Sun, & Wang, 2019) que optimiza la energía consumida y conecta los dispositivos directamente a la estación base, lo que aporta una enorme ventaja de ahorro de energía. En comparación con la topología de malla, en la topología en estrella los dispositivos no tienen que gastar energía en escuchar a otros dispositivos. La estación

base se mantiene siempre encendida para proporcionar un acceso adecuado y rápido cuando lo requieran los dispositivos finales. En cuanto al ciclo de trabajo, el ahorro de energía también se consigue apagando los dispositivos cuando no se transmiten datos. El ciclo de trabajo de la LPWA se adapta a la aplicación, al tipo de fuente de energía y al tráfico (datos transmitidos o no). El receptor está encendido sólo cuando es necesario transmitir datos. En el ámbito de la LPWA, el uso del ciclo de trabajo para transmitir datos no sólo es una forma de ahorrar energía, sino también un requisito de la legislación. La regulación regional sobre compartir el espectro establece el tiempo que un solo transmisor puede ocupar el espectro para garantizar la coexistencia con otros dispositivos que utilizan el mismo canal.

- **Comunicación de largo alcance:** La comunicación de largo alcance LPWA asegura que las señales lleguen a lugares de difícil acceso, dependiendo del entorno de despliegue (rural o urbano), la distancia puede ser de pocos o muchos kilómetros. Por área extendida se entiende una distancia que puede alcanzarse directamente sin necesidad de que ninguna topología malla amplíe la red. La LPWA está diseñada para alcanzar una distancia que va desde unos pocos kilómetros hasta decenas de kilómetros con un radio de enlace de alrededor de 150dB. La cobertura de LoRa puede estimarse tan grande como una ciudad, sobre todo donde no existe cobertura LTE, esto hace que LoRa sea adecuada para dichas zonas.
- **Bajo costo:** El costo es una de las principales claves del éxito de LPWA, esta tecnología se vale de diferentes formas para reducir costo, por ejemplo, el uso de la topología estrella en lugar de topología en malla, la reducción de la complejidad del hardware (velocidad máxima de transmisión de datos, tamaño de memoria), sólo necesita una infraestructura mínima (una estación base conecta 1.000 dispositivos), el uso de bandas de licencia propias o libres de licencia. Algunas LPWA utilizan la banda celular para evitar el costo de la licencia. En cuanto a LoRa el coste total es de aproximadamente 1000 USD por estación. En cuanto a la calidad del servicio, la LPWA se puede utilizar en muchas aplicaciones a pesar de que los requerimientos no siempre sean los mismos, ya que algunas aplicaciones pueden tolerar algún tipo de retardo (por ejemplo, la

medición inteligente), otras no pueden tolerar el retardo en la transmisión (por ejemplo, el monitoreo de la presión arterial de un paciente en estado crítico), por lo tanto, la calidad del servicio depende de los diferentes tipos de aplicaciones.

3.4. Long Range (LoRa)

LoRa es una tecnología de comunicación emergente en el mercado actual, está patentado por la empresa Semtech (<https://www.semtech.com/>) y está basada en la técnica de modulación CSS (inmune a la interferencia), opera en una banda no licenciada por debajo de 1 GHz para lograr la comunicación de largo alcance (Hwang, Chen, Ku, & Shyu, 2019). Esta tecnología LoRa (abreviatura de “long range” o largo alcance) permite el envío y recepción de información punto a punto, sus nodos proporcionan un mínimo consumo de energía asegurando una velocidad de transmisión baja pero segura. LoRa puede utilizarse con redes públicas, privadas o híbridas y logran una mayor autonomía que las redes celulares. La tecnología LoRa puede integrarse fácilmente con las redes existentes y permite aplicaciones de bajo coste de la Internet de las cosas. Dentro de sus principales ventajas tenemos:

- Alta tolerancia a las interferencias
- Alta sensibilidad para recibir datos
- Basado en modulación CSS
- Bajo Consumo (hasta 10 años con una batería)
- Largo alcance 10 a 20km
- Baja transferencia de datos
- Conexión punto a punto
- Frecuencias de trabajo: 915Mhz América, 868 Europa, 433 Asia

3.4.1. Modulación LoRa en la capa física

LoRa fue diseñado para permitir transmisiones de baja potencia, baja velocidad y largo alcance en áreas rurales o en zonas geográficas de hasta 10 ó 20 km. Está diseñada para trabajar

en bandas de frecuencia sin licencia como 433MHz, 868MHz o 915MHz, dependiendo de la ubicación geográfica y las regulaciones correspondientes (Sinha et al., 2017). En el nivel 1 de OSI, nivel físico, encontramos la tecnología LoRa de comunicación. Esta tecnología, como se ha descrito previamente, permite el envío y recepción de información punto a punto. Lo que caracteriza a un dispositivo LoRa es su largo alcance con un mínimo de dispositivos. Para ello emplea la técnica de espectro ensanchado, donde la señal a mandar utiliza más ancho de banda que el necesario teóricamente pero que permite una recepción de múltiples señales a la vez que tengan distinta velocidad. LoRa no incluye ninguna forma de cifrado y define una técnica de modulación de espectro ensanchado basada en la tecnología CSS (chirp spread spectrum) (Semtech Corporation, 2013). La modulación del CSS, o barrido de frecuencia lineal (SFL), tiene características teóricamente superiores a las de las técnicas de modulación tradicionales, como la modulación por frecuencia o por desplazamiento de fase (MDF/MDF).

3.4.2. LoRaWAN


LoRa Wan (Long Range Wide Area Network) quiere decir red de área extendida de largo alcance (Seneviratne, 2019), es una especificación de redes LPWAN. Este protocolo se encarga de unir diferentes dispositivos LoRa gestionando sus parámetros de conexión: canal, ancho de banda, cifrado de datos, etc.

LoRaWAN se compone de nodos finales (dispositivos finales), gateways (concentradores), un servidor de red y servidores de aplicaciones (figura 18) y ofrece las siguientes ventajas:

- Vida útil de la batería del nodo
- Capacidad de red
- Calidad de servicio
- Seguridad
- Aplicaciones server en red

En una red LoRaWAN, los datos transmitidos por un nodo final se reciben normalmente por múltiples gateway. Una vez recibidos los datos, cada puerta de enlace reenviará el paquete

Figura 18.
Elementos LoRaWAN




Nota. Extraído de (Seneviratne, 2019)

recibido al servidor de red a través de la red celular, Ethernet, Wi-Fi o satélite. El software que se ejecuta en el gateway es responsable de reenviar cualquier paquete de datos entrante al servidor de red. Este software es conocido como un despachador de paquetes. El servidor de red envía y recibe mensajes LoRaWAN que van y vienen desde el servidor de aplicaciones (Sinha et al., 2017).

3.4.3. Clases LoRaWAN

Para cumplir con los requisitos de muchas aplicaciones, LoRaWAN ofrece tres clases de dispositivos, según el equilibrio entre la latencia de la comunicación de enlace descendente de la red y la duración de la batería, como se muestra en la figura 19.

Figura 19.
Clases de dispositivos LoRaWAN



Nota. Extraído de (Sinha et al., 2017)

Clase A - Dispositivos finales bidireccionales

Los dispositivos finales de clase A son sensores alimentados por baterías y están diseñados principalmente para la eficiencia energética. Tiene una duración máxima de la batería y debe ser compatible con todos los demás dispositivos. La funcionalidad de la Clase A se muestra en la figura 19-a, en esta clase cada transmisión de enlace ascendente va seguida de dos ventanas de recepción de enlace descendente.

El receptor permanece activo hasta que se demodula la trama del enlace descendente, por lo que el dispositivo siempre está en modo de espera a menos que haya datos para transmitir (Muteba et al., 2019).

Clase B - Dispositivos finales bidireccionales con ranuras de recepción programadas

Estos dispositivos son alimentados por baterías y están diseñados principalmente como dispositivos actuadores. La eficiencia energética sigue siendo una preocupación para los dispositivos de esta clase, pero no tanto como los de clase A. Los dispositivos programan una señal sincronizada para que el servidor sepa que el dispositivo final está escuchando. Todos los dispositivos finales se inician y se unen a la red como dispositivos finales de Clase A y pueden decidir cambiar a Clase B. Como se muestra en la figura 19-b, el gateway envía una señal regular para sincronizar todos los dispositivos finales de la red. Cuando un dispositivo final recibe la señal, puede abrir una ventana de recepción corta llamada "ping slot" durante un intervalo de tiempo periódico (Muteba et al., 2019).

Clase C - Dispositivos finales bidireccionales con ranura de recepción máxima

Estos son dispositivos actuadores como los dispositivos de clase B, pero alimentados por una fuente permanente (principal). Los dispositivos de clase C utilizan más potencia para funcionar que los de clase A y B, pero ofrecen la latencia más baja para la comunicación con los dispositivos finales, y pueden permitirse el lujo de escuchar continuamente. Estos dispositivos no sólo abren dos ventanas de recepción como Clase A, sino que también abren una ventana de recepción continua hasta el final de la transmisión. Estos dispositivos de clase C se utilizan para aplicaciones que tienen suficiente energía disponible y por lo tanto no necesitan minimizar las ventanas de tiempo de recepción (Muteba et al., 2019).

3.5. Redes de sensores inalámbricos

Las Redes de Sensores Inalámbricos (WSN) pueden describirse como la capa de red de nodos y sensores que juntos permiten el monitoreo de un ambiente específico (Kochhar & Kumar, 2019). Esta tecnología se ha reconocido cada vez más como un componente útil para

la IoT y la Industria 4.0 (Li & Kara, 2017).

Una WSN típica, consiste en múltiples nodos de sensores y estaciones base. Los nodos de sensores normalmente tienen que medir las señales analógicas, utilizar un convertidor analógico - digital (ADC) y transmitir estos valores mediante el uso de un protocolo de comunicación.

La mayoría de las aplicaciones de las WSN utiliza una estación base, que puede ser un ordenador acoplado a un módulo RF (que es un pequeño dispositivo electrónico utilizado para transmitir y / o recibir señales de radio entre dos dispositivos) para recibir y decodificar los paquetes entrantes. El ordenador puede ser sustituido por un microprocesador, lo que constituye una solución más elegante y rentable.

Existen diferentes tipos de topología para estructurar una WSN, como la topología en estrella, la topología en malla, y la híbrida en estrella-malla (Bao et al., 2018). Se ha visto un número creciente de aplicaciones en diversos campos, como el de la ciencia ambiental, en la agricultura inteligente, los hogares inteligentes, la vigilancia militar, el cuidado de la salud en el hogar, etc.

Al diseñar una WSN se identifican varios desafíos:

- Gran cantidad de datos: Las WSNs típicas necesitan ser capaces de manejar grandes cantidades de datos entrantes y salientes. La sincronización de la transmisión es también un problema, ya que varios paquetes de datos que se transmiten al mismo tiempo pueden causar problemas a los receptores (Muteba et al., 2019).
- Robustez de la red: Para mantener la robustez de la comunicación de una red tan grande de dispositivos, deben desarrollarse mecanismos para la redundancia de la red, lo que constituye un reto debido a los requisitos de coste (Khan & Abbasi, 2016).
- Consumo de energía: Los nodos de sensores son comúnmente alimentados por baterías, lo que conlleva a realizar esfuerzos para recargar el sistema regularmente. La eficiencia energética de los nodos es también crítica para una amplia adopción en la industria.
- Costo más alto: Un reto clave de las WSN es su mayor coste en comparación con los sistemas de monitorización convencionales, que a menudo consisten sólo en sensores

analógicos conectados a máquinas de registro de datos.

- Seguridad de los datos: La aplicación industrial de las WSN a menudo transmite datos sensibles de una empresa que pueden ser perjudiciales en las manos equivocadas, como mínimo, las WSN desarrolladas deben cumplir con el estándar industrial de encriptación AES (Advanced Encryption Standard) de 128 bits (L. Oliveira & Rodrigues, 2011).

Según los estudios recientes, se prevé que para 2025 los dispositivos conectados a Internet aumentarán hasta los 22.000 millones, y para hacer frente a ese enorme número de dispositivos que evolucionan constantemente con requisitos adicionales como la cobertura, la fiabilidad, la latencia y la rentabilidad aparecen las tecnologías de baja potencia y de área extendida (LPWA) (Muteba et al., 2019).

3.5.1. Disposición de las WSN

Disposición significa la forma en que algo está dispuesto en un determinado lugar. En el caso de las WSN, la disposición no debe confundirse con la topología de la red. La topología se refiere a la colocación de los nodos para representar la dirección del flujo de información mientras que la disposición es la colocación física de los nodos. La disposición de los sensores es un hecho importante al que debe prestarse la atención adecuada. En algunos sistemas agrícolas, el entorno es muy dinámico en el que los parámetros cambian tanto espacial como temporalmente. Los cultivos crecerán con el tiempo y eventualmente afectarán el rendimiento de los sensores.

Por ejemplo, un sistema agrícola grande, que tendrá particularmente muchas zonas microclimáticas en su interior, puede tener zonas heterogéneas en las que los parámetros y el entorno general difieren de las zonas circundantes. Estos microclimas existen tanto horizontal como verticalmente. El monitoreo de estos parámetros requiere un despliegue no uniforme de sensores. Otros factores a tener en cuenta en la disposición de sensores son los de riego y fertilización que pueden ayudar a decidir la ubicación. En (Kochhar & Kumar, 2019) explican la disposición de los sensores en términos generales como disposición horizontal y disposición vertical.

Disposición horizontal

Las WSN convencionales comúnmente, tienen una disposición de sensores en forma aleatoria o en forma de cuadrícula. Por ejemplo, en (Mancuso & Bustaffa, 2006) propusieron colocar 6 nodos en filas y columnas que se cruzan entre sí para formar una cuadrícula para un sistema agrícola de tomates que cubría una superficie de 20 por 50 metros. Se puede ubicar una configuración similar para cubrir un sistema agrícola más grande, como el propuesto por (Ferentinos & Tsiligiridis, 2007), utilizando 900 sensores. En otro escenario, los autores proponen dividir el área geográfica del campo agrícola en cuadrículas y colocar 2 o 3 nodos en cada cuadrícula. Los nodos del borde de la cuadrícula se comparten con la cuadrícula vecina. La estación base se coloca en un borde del sistema agrícola (Quynh, Manh, & Nguyen, 2015).


Otra variante de la cuadrícula son los teselados (Caicedo-Ortiz et al., 2018). Las cuadrículas se visualizan normalmente como patrones repetidos. Los teselados están formados por polígonos regulares. Estos polígonos pueden ser triángulos, cuadrados, hexágonos, etc., heredan la simplicidad de las cuadrículas y tienen la ventaja adicional de cubrir los espacios libres, además evita la superposición y mantiene la uniformidad en la comunicación. Por ejemplo, los nodos situados en los bordes de tales teselaciones son equidistantes, en el trabajo de (Poe & Schmitt, 2009) mejoran aún más el concepto introduciendo capas de mosaicos. La figura 20 muestra ejemplos de mosaicos y la figura 21 representa capas de mosaicos.

La relación entre el número de nodos (N) y el número de capas (C) se da en la ecuación 3.1.

$$N = (2C + 1)^2 \quad (3.1)$$


Por otro lado, en (Song, Gong, Feng, Ma, & Zhang, 2011) modifican el diseño de la red para aumentar la vida útil de la misma. Dentro de la cuadrícula, se presenta la topología de los cúmulos jerárquicos. Se propone que los nodos padres tengan nodos redundantes para mejorar la vida útil de la red sobre un posicionamiento uniforme, utilizando el concepto de balanceo de carga para aumentar la vida útil de la red. Es así como, con un número reducido de nodos redundantes, la vida útil de la red puede prolongarse.

Figura 20.
Disposición de WSN en mosaicos



Nota. Extraído de (Kochhar & Kumar, 2019)

Figura 21.
Disposición de WSN capa de mosaicos



Nota. Extraído de (Kochhar & Kumar, 2019)

En (Raheemah, Sabri, Salim, Ehkan, & Ahmad, 2016) prefirieron desplegar antenas direccionales para construir una disposición de sólo filas. El transmisor se colocó delante de

cada fila para desarrollar un mejor modelo para un sistema agrícola de mangos. Aunque el invernadero es un sistema de control de bucle cerrado en sí mismo, no se puede suponer que sea completamente independiente de las condiciones climáticas exteriores. A veces existe la necesidad de controlar el ambiente exterior del invernadero junto con el ambiente interior. Por lo tanto, durante la etapa de diseño, se debió colocar sensores apropiados fuera del invernadero para medir los parámetros ambientales exteriores como la temperatura, la humedad, la lluvia, etc. En ese trabajo explican que los sensores exteriores pueden formar su propia topología aislados de los nodos de los sensores interiores, pero estableciendo algún tipo de comunicación entre ellos de ser necesario.

En el trabajo de (Kassim et al., 2017) dividieron 200 nodos en tipo "A" y tipo "B". Los de tipo "A" fueron nodos sensores para el monitoreo del clima exterior y los de tipo "B" fueron sensores para el monitoreo del clima interior. Otros autores prefirieron una estación meteorológica fuera del invernadero para la precisión de las mediciones (López Martínez et al., 2018). También se explica que la disposición de los nodos puede decidirse en función de las propiedades microclimáticas. En un invernadero de orquídeas, por ejemplo, se colocaron 24 sensores, 2 puertas de enlace y 48 cámaras inalámbricas en cuatro regiones para encontrar la dependencia del crecimiento de las hojas respecto a diferentes parámetros. Estas cuatro regiones eran: una región bien ventilada, región caliente y menos húmeda, una región calurosa y una región húmeda (Liao et al., 2017). Aunque en este trabajo los autores colocaron los sensores y las cámaras inalámbricas de manera uniforme, la heterogeneidad y la dinámica de la región pudo considerarse como un factor a la hora de decidir el número de nodos.

También está el concepto de redes múltiples o topologías múltiples para la vigilancia de sistemas agrícolas. Estas redes pueden estar totalmente aisladas, tener poca o total interdependencia. Por ejemplo, en un invernadero de tomates, los sensores se desplegaron uniformemente en una topología, mientras que los nodos de enlace formaban una rejilla triangular. La red de sensores y la red de nodos de enlace tenían una interdependencia total (Agric et al., 2016). También se pueden formar redes diferentes para distintos tipos de sensores.

En el trabajo de (López Riquelme et al., 2009) propusieron desplegar una red separada de nodos sensores del suelo y nodos sensores del medio ambiente y para vigilar la calidad

del agua utilizada para el riego, se desplegó otra red aislada. También explican que para la medición de parámetros como la temperatura, la humedad y la iluminación, la disposición de la cuadrícula no funciona de manera óptima. Para los parámetros en los que el rango de variabilidad de los parámetros está dentro de pocos metros como la temperatura del suelo, la humedad del suelo, el pH del suelo, etc., la disposición de la cuadrícula sí es adecuada, pero requiere un mayor número de sensores y por lo tanto cuesta más.

Disposición vertical

Dado que todos los cultivos crecen en dirección vertical, ya sea hacia arriba o hacia abajo, la disposición vertical tiene un significado especial para el control del clima en los sistemas agrícolas. El crecimiento y el follaje de los cultivos afectan en gran medida al rango de comunicación del sensor (Agric et al., 2016), por lo que la disposición vertical parece ser una buena solución.

En los primeros años de la era de los sensores, cuando éstos eran bastante caros, los sistemas agrícolas solían tener un solo nodo sensor en centro. Sin embargo, después empezó el despliegue de múltiples sensores para aumentar la precisión y la fiabilidad del monitoreo. Algunos trabajos propusieron que todos los nodos sensores estuvieran a una sola altura (Akkas & Sokullu, 2017), mientras que otros sugirieron que se colocaran sensores a niveles de altura distintos (Zou, Yao, Zhang, He, & Guan, 2017).

Otra variante de la disposición vertical es colocar los sensores en el suelo y poner nodos coordinadores en un nivel más alto o en el centro de ser el caso de un solo nodo coordinador (Sabri et al., 2011). (Yu, Yong, & Xi-yuan, 2011) propuso colocar sólo antenas a alturas separadas para aumentar el alcance de la comunicación, mientras que los sensores se quedarán a nivel del suelo. Los niveles de altura de los sensores dependen de la altura del cultivo. La disposición vertical puede ayudar entre otras cosas a adquirir parámetros relacionados con el crecimiento del cultivo.

Al igual que la disposición horizontal, la disposición vertical también depende de los parámetros medidos. Para la concentración de cloruro de suelo o el pH del suelo, los sensores deben colocarse verticalmente hacia abajo. Para la velocidad del viento, el sensor debe

colocarse en el exterior y a una cierta altura mínima, para el CO₂ los sensores más eficaces a nivel del cultivo, en cuanto al monitoreo de la iluminación o la irradiación que llega a las hojas del cultivo, los sensores de luz deben estar ubicados por encima del nivel de las hojas para evitar zonas de sombra. Otro parámetro importante que debe observarse son los niveles de altura. Al colocar los sensores en diferentes zonas de altura, debe tenerse en cuenta el nivel del dosel del cultivo para evitar interferencias.

3.5.2. Técnicas de muestreo

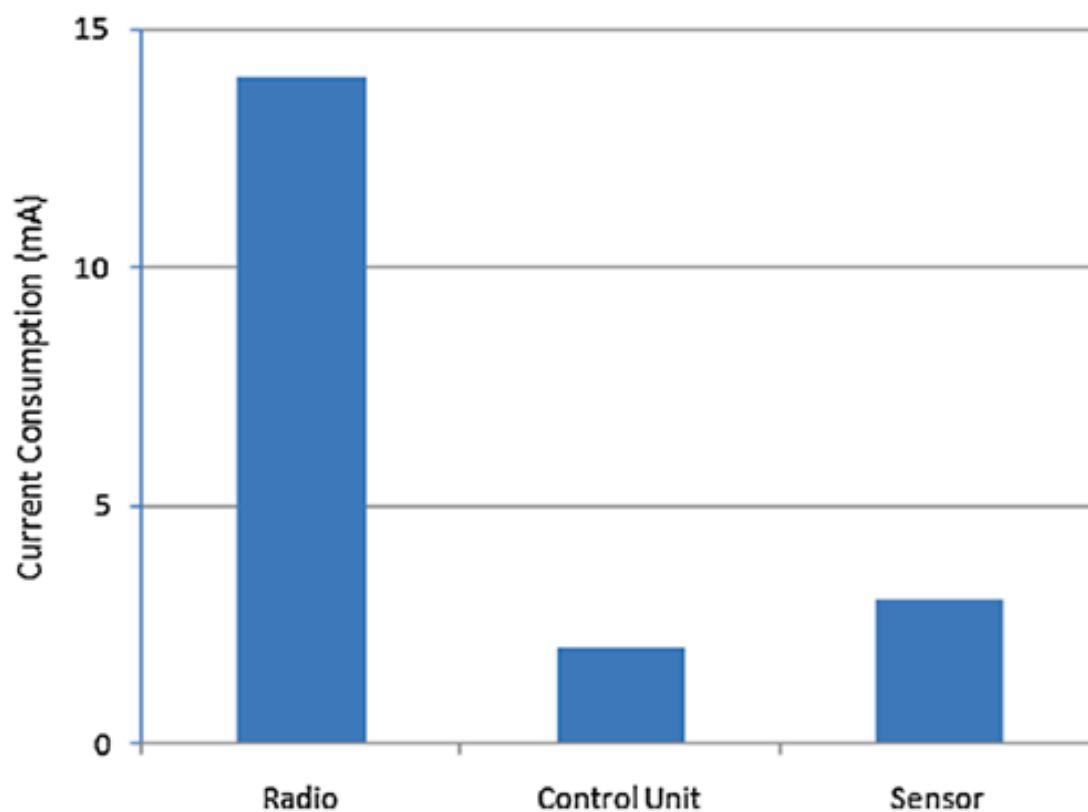
El muestreo en términos de análisis estadístico significa tomar pocas muestras de una población más grande. En términos de WSN, el muestreo es el proceso de enviar muestras de datos a través de un transceptor al siguiente nodo sensor, puerta de enlace o directamente al servidor central, es por eso que el muestreo tiene un profundo impacto en la vida de la red.

La mayor parte del consumo de energía en la configuración de una WSN es consumida por el transceptor o la radio (Didioui, 2014). Como se muestra en la figura 22, la radio consume la mayor parte de la energía en una red de sensores inalámbricos. Por lo tanto, optimizar la transmisión de datos o el muestreo puede ayudar a reducir el consumo total de energía y, por lo tanto, a prolongar la vida útil de la red.

La técnica de muestreo ayuda a decidir cuántos de los datos medidos se transmiten por el transceptor y a qué frecuencia. Dado que, en un sistema agrícola, a veces, el valor de los parámetros puede no cambiar durante horas, no es necesario transmitir los datos con frecuencia. También se debe tener en cuenta que los sistemas agrícolas requieren de técnicas de muestreo específicas para cada aplicación y para cada cultivo.

La más sencilla de todas es el muestreo periódico, es decir, el envío de datos a intervalos periódicos. El muestreo periódico es la técnica de muestreo más comúnmente utilizada, aunque el intervalo de muestreo puede variar desde unos pocos segundos hasta horas (Liao et al., 2017). Un intervalo de muestreo pequeño reduce el error de medición, pero aumenta el consumo de energía y viceversa. Así pues, debe existir un equilibrio entre el consumo de energía y el error de muestreo. Encontrar un período de muestreo adecuado es uno de los retos del diseño de los sistemas agrícolas.

Figura 22.
Consumo en un nodo WSN



Nota. Extraído de (Didioui, 2014)

El muestreo en tiempo real es otra técnica de monitoreo (Thakur et al., 2018). Los cultivos que tienen condiciones meteorológicas críticas o en un entorno muy dinámico pueden requerir un monitoreo en tiempo real, esto requiere que el transceptor esté siempre en estado activo para tomar muestras de datos; por lo tanto, no es eficiente desde el punto de vista energético.

También existe el muestreo de cruce de umbrales o niveles, los datos se comunican sólo si cruzan un nivel configurado de alarma. (Mekki et al., 2015) propuso enviar el valor medido de la temperatura, la humedad, la concentración de CO₂ y la intensidad de la luz sólo si se cruza un valor preestablecido. En (Pawlowski et al., 2009) sugirieron otra variante de muestreo de cruce de niveles, es decir, que los datos se transmitan sólo cuando haya una diferencia significativa

entre el valor actual y el último valor muestreado. Esta diferencia (δ) está preestablecida como umbral. Si $x(t_k)$ es el valor muestreado actual y $x(t_s)$ es el valor muestreado anterior, entonces la ecuación 3.2 representa la relación:

$$|x(t_k) - x(t_s)| > \delta \quad (3.2)$$

Algunos autores propusieron un control adicional (ecuación 3.3) para aumentar la estabilidad:

$$t_k - t_s \geq t_{max} \quad (3.3)$$

donde t_{max} es el intervalo máximo de muestreo. La regla de control dice que si ha transcurrido cierto tiempo (t_{max}) desde la última muestra tomada, entonces los datos serán muestreados independientemente de (δ). También se debe tener en cuenta que si (δ) es grande, los datos muestreados son menores pero el error de medición es mayor.

Para reducir el número de muestreos de parámetros altamente variables como la velocidad del viento, se propuso utilizar el filtrado. El umbral puede ser establecido manualmente por los agricultores con la ayuda de un experto o pueden utilizarse técnicas de inteligencia artificial. Las técnicas de muestreo pueden hacerse adaptables según el valor del parámetro, es decir, muestrear frecuentemente en rangos críticos de temperatura, humedad, etc. De este modo se puede equilibrar el equilibrio entre el error de muestreo y el consumo de energía (Bai et al., 2019).

En el muestreo dinámico a múltiples velocidades, la tasa de muestreo se cambia según la hora del día. Por ejemplo, como el cambio de temperatura es relativamente lento entre las 00:00 y las 08:00 que entre las 08:00 y las 14:00, la tasa de muestreo debe ser más lenta en el primer bloque horario que en el segundo. La técnica de muestreo también puede hacerse adaptativa según el tipo de parámetro, se sabe por ejemplo que los datos del suelo deben ser muestreados con mayor frecuencia que los parámetros ambientales como temperatura y humedad (Quynh et al., 2015).

El muestreo periódico con transmisión retardada promediada es otra técnica donde los datos se muestrean con frecuencia, pero no se transmiten con frecuencia. Los datos muestreados durante una duración más larga se promedian y es este valor el que se envía. En (Pahuja, Verma, & Uddin, 2013) propusieron muestrear los datos de temperatura y humedad intervalos de 2 minutos, pero enviar el valor medio en un intervalo de 15 minutos.

En (Lixuan, Hong, Minzan, Meng, & Yi, 2015) los datos se muestreaban periódicamente y se promediaban a lo largo de 10 lecturas. Otra técnica de muestreo es la que se hace al recibir una instrucción. Esta instrucción puede provenir de un centro de control (López Martínez et al., 2018). Este muestreo ayuda a la sincronización de la señal de datos de todos los nodos. Tiene una buena capacidad de manejo de riesgos, pero no es adecuado para la vigilancia de todo tipo de cultivos ya que la velocidad de transmisión de los datos puede depender también del tipo de cultivo.

El número de transmisiones para el muestreo periódico se calcula sobre la base del intervalo de muestreo. Por ejemplo, para un intervalo de muestreo de 5 minutos, los datos se transmiten 12 veces en una hora y 288 veces en un día. Análogamente, si el intervalo de muestreo es de 5 segundos, los datos se transmiten 17280 veces al día. Es así como un intervalo de muestreo largo implica un número menor de transmisiones, y con eso se ahorra energía a costa de la fiabilidad de los datos.

3.6. Protocolos de comunicación IoT

Los dispositivos de IoT se comunican de manera diferente a las computadoras conectadas a Internet, estas tienden a usar un ancho de banda elevado para transmitir una gran cantidad de datos, para los cuales la sincronización no siempre es importante. El protocolo de Internet más utilizado es el Protocolo de transferencia de hipertexto (HTTP), que es la magia detrás de la World Wide Web (WWW).

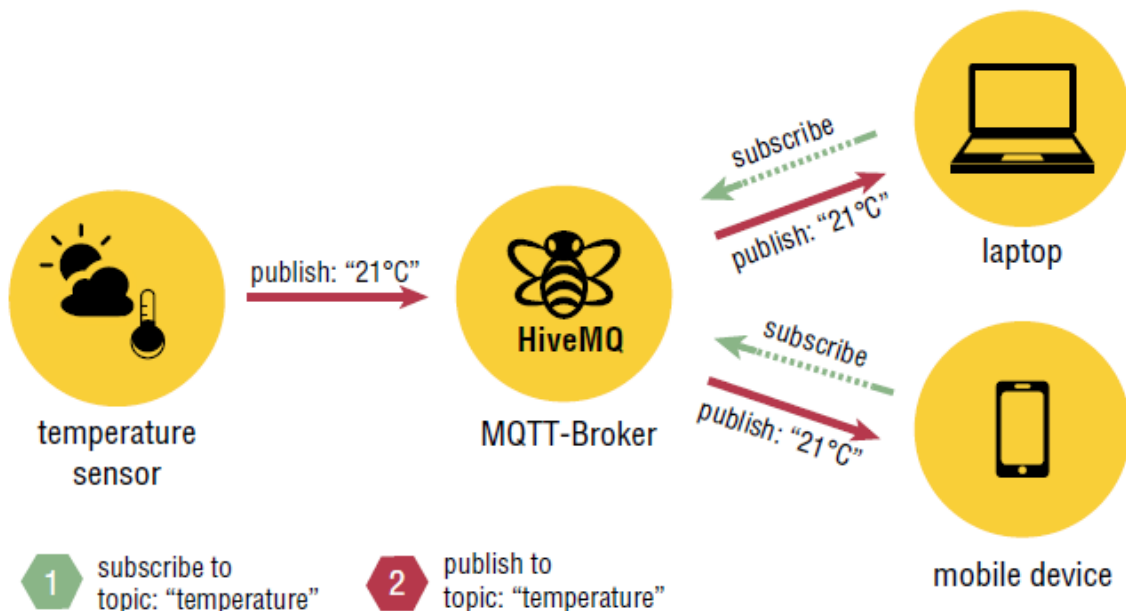
Sin embargo, los dispositivos en IoT tienden a tener una fuente de alimentación limitada, una potencia informática limitada y un ancho de banda limitado. Por lo general, necesitan transmitir una pequeña cantidad de datos de forma intermitente, además el tiempo suele ser importante. Existen varios protocolos de comunicación diseñados específicamente

para tales comunicaciones. Los siguientes son algunos de los protocolos de IoT más importantes.

3.6.1. MQTT

El transporte de telemetría de Message Queue Server (MQTT), desarrollado por IBM en 1999, es un protocolo de mensajería de publicación-suscripción. En el corazón de MQTT se encuentra el broker MQTT, que acepta y publica los mensajes (Xiao, 2019). La figura 23 muestra cómo funciona MQTT. En este ejemplo, primero se crea un topic llamado temperatura en el broker MQTT. Luego, el sensor de temperatura, la computadora portátil y el dispositivo móvil se suscriben al topic. El sensor de temperatura realizará una medición de vez en cuando y publicará los datos en el topic en el broker MQTT. El broker MQTT luego transmitirá los datos a la computadora portátil, o al el dispositivo móvil. En comparación con los protocolos HTTP, MQTT requiere mucha menos potencia informática, menos ancho de banda y menos consumo de energía.

Figura 23.
Funcionamiento del protocolo MQTT



Nota. Extraído de (Xiao, 2019)

MQTT ofrece tres niveles de calidad de servicio (QoS).

- 1er nivel: El mensaje se envía solo una vez.
- 2do nivel: El mensaje se envía varias veces hasta que el mensaje haya sido recibido.
- 3er nivel: Solo se envía una copia del mensaje (garantizada por un protocolo de enlace de dos niveles).

3.6.2. CoAP

Constrained Application Protocol (CoAP) es un protocolo de transferencia web especializado para usar con dispositivos IoT restringidos (con potencia informática limitada y consumo de energía limitado) y redes IoT restringidas (con ancho de banda limitado). El protocolo está diseñado para aplicaciones de máquina a máquina (M2M), como la automatización de edificios. CoAP se basa en mensajes de solicitud y respuesta, similar a HTTP, pero en lugar de ejecutarse en el Protocolo de control de transmisión (TCP), utiliza el Protocolo de datagramas de usuario (UDP). Por lo tanto, CoAP tiene encabezados mucho más pequeños y es mucho más rápido.

3.6.3. XMPP

Extensible Messaging and Presence Protocol (XMPP) es un protocolo de comunicación estándar abierto basado en el Extensible Markup Language (XML). XMPP permite la comunicación en tiempo real entre dispositivos de IoT mediante mensajes estructurados y extensibles. Proporciona una amplia gama de aplicaciones que incluyen mensajería instantánea, presencia y colaboración.

3.6.4. SOAP

El Protocolo simple de acceso a objetos (SOAP) es otro protocolo de mensajería basado en XML, diseñado por Microsoft, para intercambiar información entre computadoras a través de Internet. Con los mensajes XML, SOAP es altamente extensible y se puede utilizar para servicios web.

3.6.5. REST

Representational State Transfer (REST) es un estilo arquitectónico ligero para servicios web. REST se basa en el Identificador uniforme de recursos (URI) y el Protocolo de transferencia de hipertexto (HTTP), y utiliza la notación de objetos JavaScript (JSON) para un formato de datos. REST es totalmente compatible con cualquier navegador.

3.7. Plataformas IoT

Las plataformas de IoT son software que se ejecuta en Internet (la nube) y conectan sensores y dispositivos de usuario mediante protocolos de IoT como MQTT, CoAP, XMPP, etc. Las plataformas de IoT también se utilizan para almacenar datos, analizar datos y mostrar datos. La inteligencia artificial a menudo se implementa en las plataformas de IoT para proporcionar análisis complejos. A continuación se describe una lista de plataformas de IoT populares.

- Eclipse IoT: <https://iot.eclipse.org/>
- Oracle IoT Cloud: <https://cloud.oracle.com/iot>
- IBM Watson: <https://www.ibm.com/watson/>
- Amazon AWS: <https://aws.amazon.com/>
- Microsoft Azure: <https://azure.microsoft.com/en-us/>
- Google Cloud: <https://cloud.google.com/>
- Salesforce: <https://www.salesforce.com/uk/products/iot-cloud/overview/>
- Thinger: <https://thinger.io/>
- Thingspeak: <https://thingspeak.com/>
- Arduino IoT Cloud: <https://create.arduino.cc/iot/things>
- Ubidots IoT: <https://ubidots.com/>

3.8. Herramientas software para el IoT

3.8.1. Flask

Flask es un framework web ligero de código abierto construido en Python para implementar aplicaciones web. Un framework web, se refiere a un grupo de recursos necesarios para ejecutar una aplicación web. Esto puede incluir diferentes módulos, bibliotecas y herramientas que el desarrollador web puede utilizar para crear y ejecutar correctamente la aplicación (figura 24).

Figura 24.

Código de inicialización de flask

```
[In]: from flask import Flask
[In]: app = Flask(__name__)
[In]: @app.route("/")
[In]: def hello():
      return "Hello World!"
[In]: if __name__ == '__main__':
      app.run(debug=True)
```

Nota. Elaboración propia

(Grinberg, 2014) en su libro Flask Web Development, explica que Flask es un framework pequeño según la mayoría de los estándares, lo suficientemente pequeño como para llamarlo “microframework”. Es por eso que una vez familiarizado con el se puede leer y comprender todo su código fuente. Pero ser pequeño no significa que rinda menos que otros frameworks. Flask fue diseñado como una estructura extensible desde cero; proporciona un núcleo sólido con los servicios básicos, mientras que las plugins proporcionan el resto. Debido a que puede elegir los paquetes de extensión que se deseen.

Flask tiene dos dependencias principales. El enrutamiento y la depuración, también está el Web Server Gateway Interface (WSGI) interfaz de puerta de enlace del servidor web (WSGI) dado por las bibliotecas Werkzeug, mientras que Jinja2 proporciona soporte para plantillas. Werkzeug y Jinja2 fueron creados por el desarrollador principal de Flask.

No hay soporte nativo en Flask para acceder a bases de datos, validar formularios web, autenticar usuarios u otras tareas de alto nivel. Estos y muchos otros servicios clave que la mayoría de las aplicaciones web necesitan están disponibles a través de extensiones que se integran con los paquetes principales. El desarrollador, debe poder de elegir las extensiones que mejor funcionen para su proyecto o incluso escribir las suyas propias si se siente inclinado a hacerlo. Esto contrasta con un framework más amplio, donde la mayoría de las decisiones se han tomado por el desarrollador y son difíciles o, a veces, imposibles de cambiar.

3.8.2. Node.js

En el 2009, Ryan Dahl, presentó una plataforma que combinaba el motor JavaScript V8 de Google, un bucle de eventos y una API de E/S de bajo nivel. Este proyecto no era como otras plataformas de JavaScript del lado del servidor donde todas las E/S primitivas estaban impulsadas por eventos y no había forma de evitarlo. Al aprovechar el poder y la simplicidad de JavaScript, este proyecto convirtió la difícil tarea de escribir aplicaciones del lado del servidor impulsadas por eventos en una tarea fácil. El proyecto se llamó Node.js y ahora los desarrolladores lo conocen simplemente como Node.

Node proporciona una infraestructura sin bloqueo puramente impulsada por eventos para crear software altamente concurrente como son las aplicaciones del Internet de las Cosas. Una razón es JavaScript. JavaScript es el lenguaje de programación más utilizado en el planeta. La mayoría de los programadores web están acostumbrados a escribir JavaScript en el navegador, y el servidor es una extensión natural de eso. La otra razón es la simplicidad de Node. Las funcionalidades centrales de Node se mantienen al mínimo y todas las API existentes son bastante elegantes, exponiendo la mínima cantidad de complejidad a los programadores. Cuando se desea crear algo más complejo, se puede elegir, instalar y utilizar fácilmente varios de otros módulos desarrollados por terceros.

3.8.3. Bases de datos

Los datos son una de las propuestas de valor principales de las aplicaciones de Internet de las cosas (IoT). Los dispositivos conectados no solo proporcionan un puente para recopilar

datos de sensores del mundo físico, sino que tienen la capacidad de ejecutar análisis y crear valor recurrente.

Si bien a menudo las investigaciones se enfocan en el firmware que recopila y procesa los datos de IoT o en los algoritmos de aprendizaje automático que convierten los datos recopilados en inteligencia en la nube, hay un intermediario que lo reúne todo, como es la ingeniería de datos.

Las bases de datos relacionales han sido el tipo dominante de base de datos utilizado para aplicaciones durante décadas. Las bases de datos relacionales abordaron muchas de las limitaciones de los almacenes de datos basados en archivos planos, las bases de datos jerárquicas y las bases de datos de red. Sin embargo, con la llegada de la Web, sus limitaciones se volvieron cada vez más problemáticas. Empresas como Google, Facebook, y Amazon descubrieron que admitir un gran número de usuarios en la Web era diferente de admitir un número mucho menor de usuarios comerciales.

Los desarrolladores de aplicaciones web que trabajaban con grandes volúmenes de datos y una gran cantidad de usuarios se encontraron con las siguientes retos:

- Grandes volúmenes de operaciones de lectura y escritura
- Tiempos de respuesta de baja latencia
- Alta disponibilidad

Estos requisitos eran difíciles de cumplir con el uso de bases de datos relacionales. Estos no fueron los primeros usuarios de bases de datos que necesitaban mejorar el rendimiento. El problema es que las técnicas utilizadas en el pasado no funcionaban a la escala de operaciones, usuarios y datos que ahora demandaban las empresas. En el pasado, si una base de datos relacional respondía lentamente, se podía mejorar con más CPU, memoria adicional o dispositivos de almacenamiento más rápidos. Esta es una opción costosa y funciona solo hasta cierto punto porque siempre habrán límites en la cantidad de CPU y memoria que pueden admitir en un solo servidor.

Algunas veces los diseñadores de bases de datos rediseñaban el esquema de la base

de datos para utilizar técnicas que mejorarían el rendimiento, pero a costa de aumentar el riesgo de anomalías en los datos (Estas técnicas se conocen como desnormalización). Otra opción aunque compleja era utilizar varios servidores con la base de datos relacional. Sin embargo, esto dificulta la gestión a largo plazo. También hay problemas de rendimiento al admitir una serie de operaciones que se ejecutan en diferentes servidores, ya que todas deben completarse correctamente o de lo contrario todas deben fallar, a este conjunto de operaciones se les conoce como transacciones.

Con el Internet de las cosas y la gran cantidad de datos a procesar también comenzó el auge de las bases de datos NoSQL.

3.8.4. NOSQL

Los problemas urgentes del mundo actual motivaron a los profesionales de la gestión de datos y los diseñadores de software a crear las bases de datos NoSQL.

Este tipo de base de datos aborda cuatro características particularmente importantes para las tareas de administración de datos a gran escala, dependiendo de las necesidades de una aplicación en particular, algunas de estas características pueden ser más importantes que otras:

- Escalabilidad:

La escalabilidad es la capacidad de satisfacer de manera eficiente las necesidades de distintas cargas de trabajo. Por ejemplo, si hay un aumento en el tráfico a un sitio web, se pueden conectar servidores adicionales para manejar la carga adicional. Cuando el pico disminuye y el tráfico vuelve a la normalidad, algunos de esos servidores adicionales pueden apagarse.

Agregar servidores según sea necesario se denomina escalado horizontal. Cuando se trabaja con bases de datos relacionales, a menudo es un desafío escalar horizontalmente. Es posible que se necesite software de base de datos adicional para administrar varios servidores que funcionan como un solo sistema de base de datos. Oracle, por ejemplo, ofrece Oracle Real Applications Clusters (RAC) para bases de datos basadas en clústeres.

Los componentes adicionales de la base de datos pueden agregar complejidad y costo a las operaciones. Alternativamente, los administradores de bases de datos podrían optar por escalar, lo que es actualizar un servidor de base de datos existente para agregar procesadores adicionales, memoria, ancho de banda de red u otros recursos que mejorarían el rendimiento en un sistema de administración de base de datos o reemplazar un servidor existente por uno con más CPU, memoria, etc.

- Costo

El costo de las licencias de bases de datos es una consideración obvia para cualquier empresa u organización. Los proveedores de software comercial emplean una variedad de modelos de licencias que incluyen cobrar por el tamaño del servidor que ejecuta el RDBMS, por el número de usuarios concurrentes en la base de datos o por el número de usuarios designados a los que se les permite usar el software.

Cada uno de estos modelos presenta desafíos para los usuarios del sistema de base de datos. Las aplicaciones web pueden tener picos de demanda que aumentan el número de usuarios que utilizan una base de datos en cualquier momento. ¿Deberían los usuarios del RDBMS pagar por la cantidad de usuarios pico o la cantidad de usuarios promedio? ¿Cómo deberían presupuestar las licencias de RDBMS cuando es difícil saber cuántos usuarios utilizarán el sistema dentro de seis meses o un año?.

Los usuarios de software de código abierto evitan estos problemas. El software es de uso gratuito en tantos servidores del tamaño necesario porque los desarrolladores de código abierto no suelen cobrar tarifas por ejecutar su software. Afortunadamente para los usuarios de bases de datos NoSQL, las principales bases de datos NoSQL están disponibles como código abierto. Las empresas de terceros brindan servicios de soporte comercial para bases de datos NoSQL de código abierto para que las empresas puedan tener soporte de software como lo hacen con las bases de datos relacionales comerciales.

- Flexibilidad

Los sistemas de gestión de bases de datos relacionales son flexibles. La gama de problemas que se pueden abordar utilizando modelos de datos relacionales son muchas,

diferentes industrias como la banca, la fabricación, el comercio minorista, la energía y la atención médica hacen uso de bases de datos relacionales.

Sin embargo, hay otro aspecto de las bases de datos relacionales que es menos flexible. Los diseñadores de bases de datos esperan conocer al inicio del proyecto todas las tablas y columnas que serán necesarias para dar soporte a una aplicación. También se asume comúnmente que la mayoría de las columnas de una tabla serán necesarias para la mayoría de las filas. Por ejemplo, todos los empleados tendrán nombres y un identificador de la empresa. Hay ocasiones en que los problemas modelados son menos homogéneos que eso.

Por ejemplo, una aplicación de comercio electrónico que utiliza una base de datos para rastrear los atributos de los productos. Los productos informáticos tendrían atributos como el tipo de CPU, la cantidad de memoria y el tamaño del disco. Los hornos de microondas tendrían atributos como tamaño y potencia. Un diseñador de base de datos podría crear tablas separadas para cada tipo de producto o definir una tabla con tantos atributos de diferentes productos como pudiera imaginar en el momento en que diseña la base de datos.

A diferencia de las bases de datos relacionales, algunas bases de datos NoSQL no requieren una estructura de tabla fija. Por ejemplo, en una base de datos de documentos, un programa podría agregar dinámicamente nuevos atributos según sea necesario sin tener que modificar el diseño de la base de datos.

- Disponibilidad

Siempre se espera que los sitios web y las aplicaciones web estén disponibles para utilizarlas. Si alguna persona nota que su sitio de comercio electrónico o redes sociales favoritas estuvieran caídas con mucha frecuencia probablemente comenzaría a buscar nuevas opciones.

Las bases de datos NoSQL están diseñadas para aprovechar múltiples servidores de bajo costo. Cuando un servidor falla o se pone fuera de servicio por mantenimiento, los otros servidores del clúster pueden asumir toda la carga de trabajo. El rendimiento puede

ser algo menor, pero la aplicación seguirá estando disponible. Si una base de datos se ejecuta en un solo servidor y falla, la aplicación dejará de estar disponible a menos que haya un servidor de respaldo. Los servidores de respaldo mantienen copias replicadas de los datos del servidor primario en caso de que falle este servidor. Si eso sucede, la copia de seguridad puede asumir la carga de trabajo que el servidor primario había estado procesando.

3.9. Topologías de nube y niebla

Sin la nube, el crecimiento de IoT y su mercado no sería posible. Esencialmente, miles de millones de dispositivos finales necesitarían administrarse por sí mismos sin la capacidad de compartir o agregar datos y sobre todo no aportarían algún valor a las personas. El valor de IoT está en los datos que produce, no en un solo punto final, sino en miles o millones de nodos. La nube brinda la posibilidad de que sensores, cámaras, actuadores simples participen en un lenguaje común entre sí. La nube es el denominador común en la importancia de los datos (Aslanpour, Gill, & Toosi, 2020).

La metáfora de la nube ubicua se refiere a una infraestructura de servicios informáticos que generalmente son bajo demanda. El conjunto de recursos (informática, redes, almacenamiento y los servicios de software asociados) puede escalar dinámicamente hacia arriba o hacia abajo según el promedio de carga o la calidad del servicio. Las nubes suelen ser grandes centros de datos que brindan servicios externos a los clientes en un modelo de pago por uso. Estos centros brindan la ilusión de un solo recurso en la nube, mientras que, de hecho, puede haber muchos recursos dispersos geográficamente en uso. Esto le da al usuario una sensación de independencia de ubicación (Alli & Alam, 2020).

Los recursos son escalables y los servicios son a pedido, lo que genera un flujo de ingresos recurrente para el proveedor. Las aplicaciones basadas en la nube se pueden desarrollar e implementar más rápido. Por eso con el advenimiento de nuevas tecnologías de la computación en la nube, esta se volvió práctica para la industria.

Tradicionalmente, la industria de las telecomunicaciones se basaba en un sistema punto a punto. La creación de VPN (virtual private network) permite un acceso seguro y

controlado a los clústeres de servidores y ha permitido que existan híbridos de nubes públicas y privadas.

3.9.1. Modelo de servicios en la nube

Los proveedores de nube suelen brindar un servicio XaaS, que significa "Everything as a Service", básicamente, cualquier función tecnológica se puede transformar en un servicio para el consumo empresarial. El servicio se paga según un modelo de consumo flexible en lugar de obtener una licencia o comprarlo antes.

Estos servicios pueden ser:

- NaaS (Networking as a Service).
- SaaS (Software as a Service).
- PaaS (Platform as a Service).
- IaaS (Infrastructure as a Service).


Existen muchos proveedores para cada modelo de estos servicios, estas ofertas son el valor agregado de la computación en la nube.

Como mínimo, lo que se requiere con estos servicios debe compensar el gasto de capital que enfrenta un cliente por comprar y mantener dicho equipo en un centro de datos y reemplazarlo como un gasto operativo.

La definición estándar de computación en la nube se puede encontrar a través del Instituto Nacional de Estándares y Tecnología (Mell & Grance, 2011) donde explican que es un modelo para permitir el acceso a red bajo demanda, donde se comparten recursos informáticos configurables (por ejemplo redes, servidores, almacenamiento, aplicaciones y servicios).

La figura 25 ilustra las diferencias en la gestión de modelos en la nube. NaaS incluye servicios como SDP y SDN. IaaS impulsa los sistemas de hardware y el almacenamiento a la nube. PaaS incluye la infraestructura, pero también administra el sistema operativo y el tiempo de ejecución del sistema o los contenedores en la nube. Finalmente, SaaS recae todos los servicios, infraestructura y servicios en el proveedor de la nube.

Figura 25.
Modelos de arquitectura en la nube



Nota. Extraído de (Alli & Alam, 2020)

- Dentro de los servicios NaaS, están las redes definidas por software (SDN) y los perímetros definidos por software (SDP). Estos productos son mecanismos organizados y administrados en la nube para proporcionar redes superpuestas y seguridad empresarial. En lugar de construir una infraestructura para respaldar las comunicaciones de una corporación, se puede utilizar un enfoque de nube para formar una red virtual. Esto permite que la red aumente o reduzca los recursos de manera óptima según la demanda, y se pueden comprar e implementar nuevas funciones de red rápidamente.
- SaaS es la base de la computación en la nube. Un proveedor suele ofrecer aplicaciones o servicios que se brindan al usuario final a través de dispositivos clientes como los dispositivos móviles, clientes ligeros o marcos en otras nubes. Desde el punto de vista del usuario, la capa SaaS se ejecuta virtualmente en dispositivo cliente. Esta abstracción de software ha permitido a la industria lograr un crecimiento sustancial en la nube.
- PaaS se refiere al hardware subyacente y las instalaciones de software de capa inferior

que proporciona la nube. En este caso, el usuario final simplemente utiliza el hardware del centro de datos, el sistema operativo, el middleware y diversos marcos de trabajo de un proveedor para alojar sus aplicaciones o servicios privados.

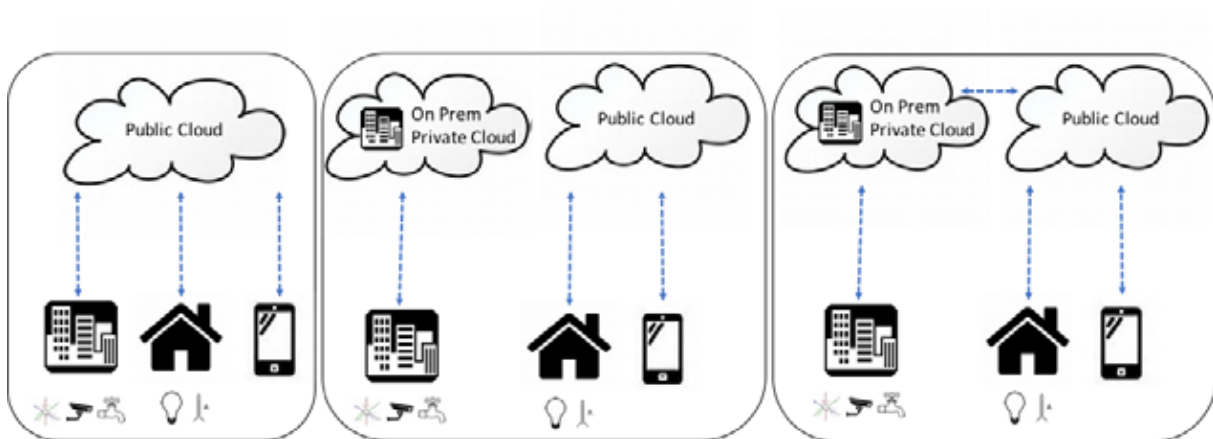
- IaaS fue el concepto original de servicios en la nube. En este modelo, el proveedor crea servicios de hardware escalables en la nube y proporciona un mínimo de marcos de software para construir máquinas virtuales cliente. Esto ofrece la mayor flexibilidad en la implementación, pero requiere mayor preparación por parte del usuario final.

3.9.2. Nube pública, privada e híbrida

Dentro del entorno de la nube se encuentran tres modelos diferentes de topologías: nube privada, nube pública y nube híbrida (Caiza, Saeteros, Oñate, & Garcia, 2020). Independientemente del modelo, la nube (figura 26) deben proporcionar la capacidad de escalar, desarrollar e implementar aplicaciones de forma dinámica.

Figura 26.

Izquierda: nube pública. Medio: nube privada versus pública. Derecha: nube híbrida.



Nota. Extraído de (Alli & Alam, 2020)

Las nubes privadas también implican componentes administrados en instalaciones. Los sistemas empresariales modernos tienden a usar una arquitectura híbrida para garantizar la seguridad de las aplicaciones y los datos críticos en sus instalaciones, y usan la nube pública para la conectividad, la facilidad de implementación y el desarrollo rápido.

Nube privada

En una nube privada, la infraestructura se proporciona para una sola organización o corporación. No existe el concepto de compartir recursos fuera de la propia infraestructura del propietario. Sólo es posible compartir recursos dentro de las instalaciones. Una nube privada existe por varias razones, incluida la seguridad y la garantía, es decir, para garantizar que la información se limite únicamente a los sistemas administrados por el cliente. Sin embargo, para ser considerada una nube, deben existir ciertos aspectos de los servicios similares a la nube, como la virtualización y una carga balanceada. Una nube privada puede estar en las instalaciones de la organización o puede ser máquinas dedicadas proporcionadas por un tercero exclusivamente para su uso.

Nube pública

En una nube pública la infraestructura se provee bajo demanda para una multitud de clientes y aplicaciones. La infraestructura es un conjunto de recursos que cualquiera puede usar en cualquier momento como parte de sus acuerdos de nivel de servicio. La ventaja es que la gran escala de los centros de datos en la nube permite una escalabilidad sin precedentes para muchos clientes, que solo se limitan a la cantidad del servicio que desean comprar. Un ejemplo de nube pública es Microsoft Azure o Amazon AWS.

Nube híbrida

El modelo arquitectónico híbrido es una combinación de la nube pública y privada. Las organizaciones tienden a favorecer un modelo híbrido si los datos confidenciales necesitan una gestión única, mientras que la interfaz front-end puede aprovechar el alcance y la escala de la nube. Otro caso de uso es mantener un acuerdo de nube pública para compensar las condiciones en las que la escalabilidad excede la infraestructura de la nube privada de la corporación.

En este caso, la nube pública se utilizará como un equilibrador de carga hasta que la cantidad de datos y el uso se reduzcan a las limitaciones de la nube privada. Esto es especialmente frecuente en situaciones en las que los servicios front-end y los portales web

pueden ser instalados en la nube pública.

Arquitectura de nube OpenStack

OpenStack es un marco con licencia Apache 2.0 de código abierto que se utiliza para crear plataformas en la nube (Pyati, D G, & Kengond, 2020). Es principalmente un IaaS y ha estado en la comunidad de desarrolladores desde 2010. La Fundación OpenStack administra el software y cuenta con el apoyo de más de 500 empresas, incluidas Intel, IBM, Red Hat y Ericsson. OpenStack comenzó como un proyecto conjunto entre la NASA y Rackspace alrededor de 2010. La arquitectura tiene todos los componentes principales de otros sistemas en la nube, incluida la computación y el equilibrio de carga; componentes de almacenamiento, incluida la copia de seguridad y la recuperación; componentes de red, paneles, seguridad, paquetes para análisis de datos, herramientas de despliegue de aplicaciones, monitoreo, y servicios de aplicaciones. Estos son los componentes esenciales al elegir un servicio en la nube.


Esta arquitectura es una alternativa a las nubes comerciales (figura 27), muchos de los componentes de OpenStack análogos a componentes en servicios de nube comerciales como Microsoft Azure o AWS. Arquitectónicamente, OpenStack es una capa de componentes entrelazados. La forma básica de una nube OpenStack se muestra en la siguiente figura. Cada servicio tiene una función particular y un nombre único.

Componentes OpenStack

El sistema actúa como un todo, proporcionando una funcionalidad de nube escalable de clase empresarial: toda la comunicación dentro de los componentes de OpenStack se realiza a través de las colas de mensajes del Protocolo AMQP (Advanced Message Queuing Protocol). El beneficio en un entorno de nube es que el cliente y el servidor están completamente desacoplados, y esto permite que los servidores escalen dinámicamente hacia arriba o hacia abajo. Los mensajes no se transmiten sino que se dirigen, lo que mantiene el tráfico al mínimo.

La cloud de OpenStack está compuesta por diferentes elementos, entre los cuales destacan los siguientes (Couto et al., 2018):

Figura 27.
Diagrama de la arquitectura OpenStack



Nota. Extraído de (Alli & Alam, 2020)

- **Nova (Servicio de cómputo):** Es el corazón del servicio de gestión de recursos informáticos de OpenStack. Es la columna vertebral sobre la que recae la tarea de gestionar las máquinas virtuales. Su propósito es identificar y brindar recursos informáticos en función de la demanda.
- **KeyStone (Gestión de identidad):** Es el servicio de gestión de identidad de la nube OpenStack. Un administrador de identidad establece las credenciales de usuario y la autorización de inicio de sesión. Es esencialmente el punto de partida o el punto de entrada a la nube. Este recurso mantendrá un directorio central de usuarios y sus derechos de acceso. Este es el nivel superior de seguridad para garantizar que los

entornos de usuario sean mutuamente excluyente y seguros.

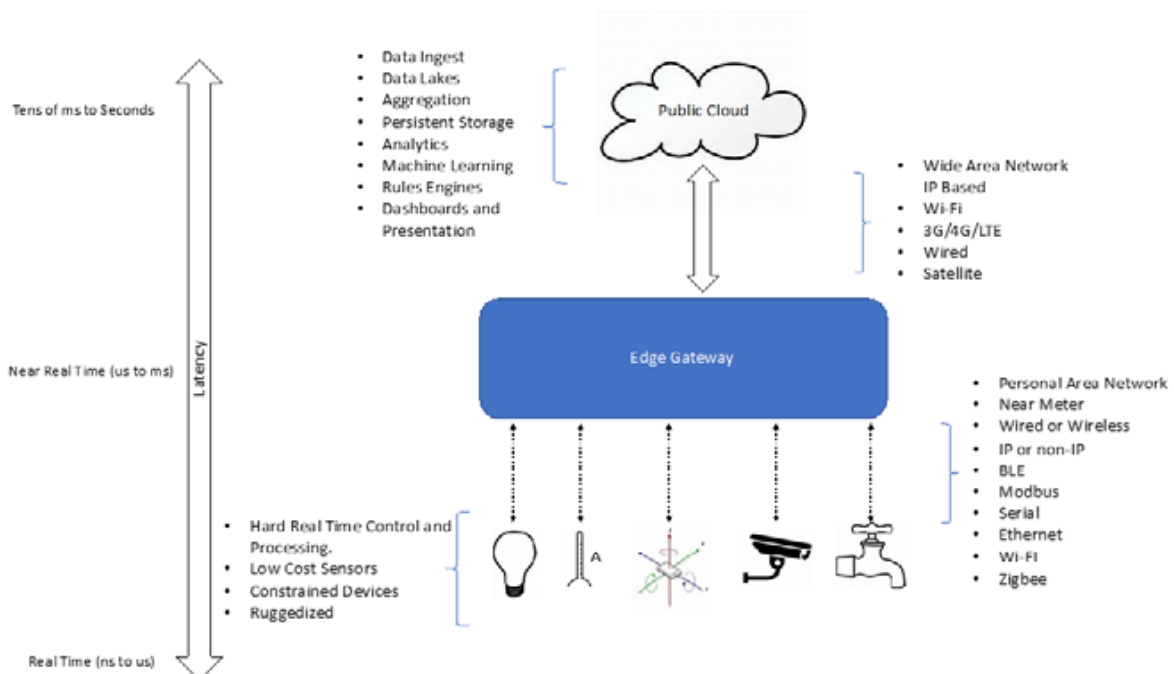
- Glance (Servicio de máquinas virtuales): Proporciona el soporte para la gestión de máquinas virtuales para OpenStack. La mayoría de los servicios en la nube proporcionarán cierto grado de virtualización y el componente Glance es el encargado de esto en OpenStack. La API del servicio de imágenes es un servicio RESTful y permite al cliente desarrollar plantillas de máquinas virtuales, descubrir las que están disponibles, e incluso mover máquinas virtuales en ejecución a diferentes servidores físicos sin interrupción.
- Neutron (Servicio de red): Es el servicio de administración de red y VLAN de OpenStack. Toda la red es configurable y proporciona servicios tales como: Servicios de nombre de dominio, DHCP, funciones de puerta de enlace, administración de VLAN, conectividad L2, SDN, protocolos de túnel VPN, NAT (SNAT y DNAT), sistemas de detección de intrusos, equilibrio de carga y cortafuegos.
- Cinder (Almacenamiento en bloque): Se encarga de crear memorias permanentes en formato de almacenamiento en bloque como, por ejemplo, discos duros. Lo hace mediante virtualización, lo cual permite adaptar el volumen como se desee (escalabilidad). La memoria en bloque de Cinder se comporta como un disco duro físico en el ordenador. La seguridad de los datos se consigue de forma sencilla, ya que el usuario accede a los discos a través de Cinder, mediante una interfaz que incluye una función de snapshot (copia instantánea de volumen).
- Swift (Servicio de almacenamiento): Swift provee un sistema de almacenamiento redundante en el centro de datos de OpenStack. Permite que los clusters instalados puedan escalar agregando nuevos servers. El almacenamiento puede contener entre otras cosas las cuentas de los usuarios y los contenedores como las máquinas virtuales.
- Horizon (Interfaz gráfica): Horizon es la interfaz gráfica de OpenStack. Proporciona una vista basada en la web de los diversos componentes que componen OpenStack (Nova, Cinder, Neutron y otros). Horizon proporciona una vista de la interfaz de usuario del sistema en la nube como un medio alternativo a la API. Horizon es extensible para que

un tercero pueda agregar sus widgets o herramientas a la interfaz.

3.9.3. Restricciones de las arquitecturas en la nube para IoT

Un proveedor de servicios en la nube está fuera de los llamados dispositivos Edge. Un rasgo particular de la arquitectura de IoT es que los dispositivos PAN y WPAN pueden no ser compatibles con el protocolo IP. Los protocolos como Bluetooth Low Energy (BLE), LoRaWAN y Zigbee no están basados en IP, mientras que todo en la WAN, incluida la nube, está basado en IP. Por lo tanto, la función de la puerta de enlace de la capa Edge es la encargada de realizar ese nivel de traducción. Otro punto importante es la latencia y el tiempo de respuesta según los eventos. A medida que se está más cerca al sensor, se ingresa al ámbito de los requisitos estrictos del tiempo real. Los sistemas de IoT suelen ser sistemas embebidos o microcontroladores que tienen una latencia establecida por eventos del mundo real (figura 28).

Figura 28.
Efectos de latencia en la nube



Nota. Extraído de (Alli & Alam, 2020)

3.9.4. Capa de computación en niebla (Fog Computing)

La computación en la niebla es la extensión evolutiva de la computación en la nube en la capa Edge (Singh, Singh, & Gill, 2021). La niebla representa una arquitectura horizontal a nivel de sistema que distribuye recursos y servicios a través de una estructura de red. Estos servicios y recursos incluyen componentes de almacenamiento, dispositivos informáticos, funciones de red, etc. Los nodos pueden ubicarse en cualquier lugar entre la nube y las "cosas" (sensores). Existen diferencias entre la computación de niebla y de borde que se verán a continuación.

Comparación de la computación en niebla, borde y nube


La computación en el borde es como el procesamiento en movimiento cerca de donde se generan los datos. En el caso de IoT, un dispositivo de borde podría ser el propio sensor con un pequeño microcontrolador o un sistema integrado capaz de comunicación WAN. Otras veces, el borde será una puerta de enlace en arquitecturas con puntos finales particularmente restringidos. El procesamiento de borde también se suele denominar en un contexto de máquina a máquina donde existe una estrecha correlación entre el borde (cliente) y un servidor ubicado en otro lugar. La computación de borde existe, como se dijo, para resolver problemas con la latencia y el consumo innecesario de ancho de banda, y para agregar servicios como desnaturalización y seguridad cerca de la fuente de datos. Un dispositivo de borde puede tener una relación con un servicio en la nube a costa de la latencia y un operador y no participa activamente en la infraestructura de la nube.

La computación en la niebla es ligeramente diferente de un paradigma de computación en el borde. La computación de niebla, en primer lugar, comparte APIs y un estándar de comunicaciones con otros nodos de niebla y/o servicios de nube superpuesto. Los nodos de niebla son extensiones de la nube, mientras que los dispositivos de borde pueden o no involucrar una nube en absoluto. Otro principio clave de la computación en la niebla es que la niebla puede existir en capas de jerarquía. La computación en la niebla también puede equilibrar la carga y dirigir los datos de este a oeste y de norte a sur para ayudar en el equilibrio de recursos, entonces se puede pensar en estos nodos de niebla simplemente como más (aunque menos poderosas) infraestructuras en una nube híbrida.

Hay otra capa de niebla llamada también "cloudlets" o "mist computing". Esta otra capa de niebla está formada generalmente por un extremo de la red donde están los microcontroladores o sistemas embebidos de bajo costo y consumo. Dehen estar lo más cerca posible físicamente de los sensores para recopilar datos y realizar cálculos de origen cercano. Se interconectan con los nodos de Fog a través de protocolos estándar. Los componentes del "mist computing" suelen formar parte de la topología general de la red. Un ejemplo de dispositivo de niebla es un termostato inteligente (figura 29).

Figura 29.

Relación entre la nube, el borde, la niebla y el mist computing



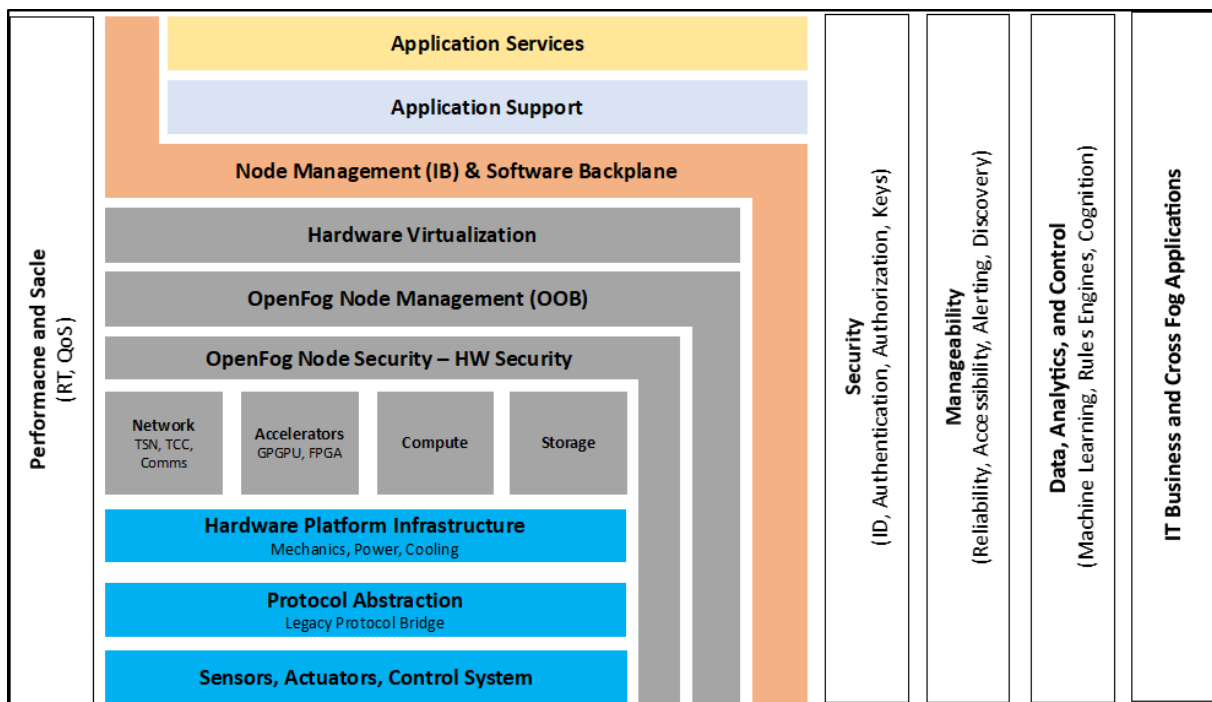
Nota. Extraído de (Alli & Alam, 2020)

3.9.5. Arquitectura OpenFog

La arquitectura OpenFog es un modelo para ayudar a los arquitectos y desarrolladores a crear hardware, desplegar software y adquirir infraestructura para la computación en la niebla. OpenFog se basa en el beneficio de las soluciones basadas en la nube y busca mover ese

nivel de computación, almacenamiento, redes y escalado a la capa Fog sin sacrificar la latencia y el ancho de banda (Caiza et al., 2020). La arquitectura OpenFog consiste en un enfoque en capas desde los sensores y actuadores de borde en la parte inferior hasta los servicios de aplicación en la parte superior. La arquitectura tiene algunas similitudes con la arquitectura típica de la nube, como OpenStack, pero la amplía aún más, ya que es más análoga a una PaaS que a una IaaS. De hecho, OpenFog proporciona una estructura completa y generalmente es independiente del hardware, o al menos abstrae la plataforma del resto del sistema (figura 30).

Figura 30.
Arquitectura OpenFog



Nota. Extraído de (Alli & Alam, 2020)

Capítulo 4

Solución IoT para el monitoreo de plantaciones de banano

Con esta solución se busca empezar el camino de la digitalización del sector agrícola en Piura, específicamente se ha trabajado con el cultivo de banano, fruto tan importante en la agricultura piurana. Sin embargo, esto no quiere decir que la solución no pueda adaptarse a otros campos agrícolas. Como se ha visto en capítulos anteriores, una agricultura digital necesita la incorporación de redes inteligentes y herramientas de gestión de datos. Además tiene el objetivo de utilizar la información y experiencias disponibles para llevar a cabo la automatización de los procesos centrándose principalmente en el valor de los datos a fin de obtener ciertos conocimientos prácticos para lograr una agricultura inteligente.

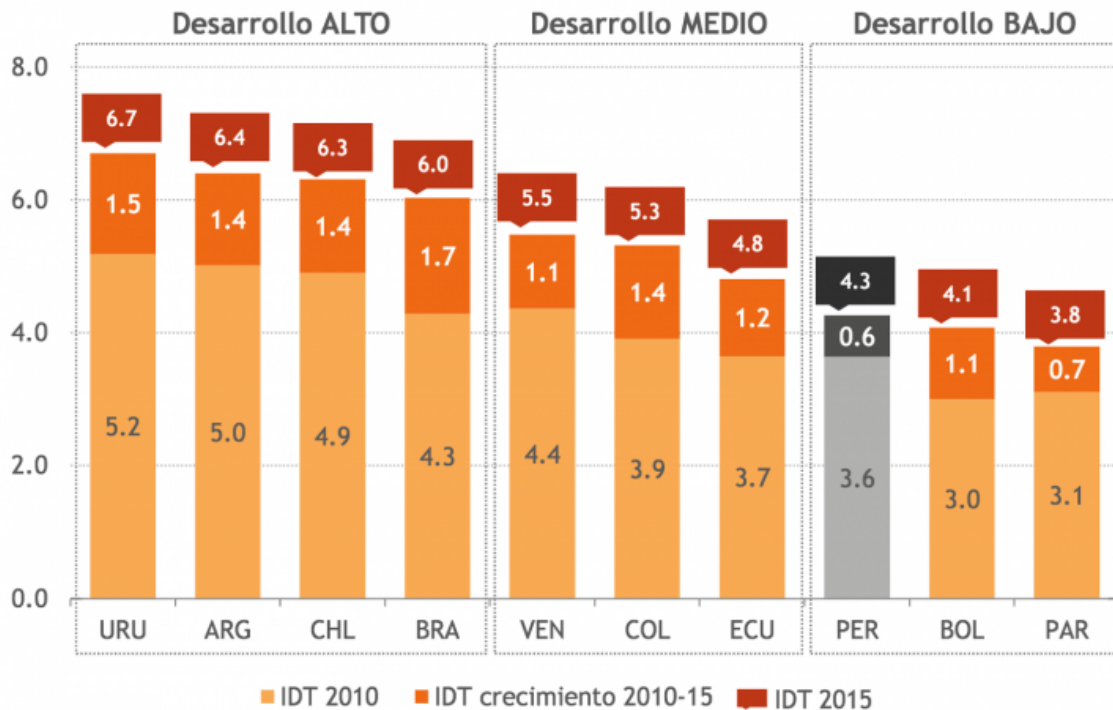
4.1. Factores importantes para la adopción de la tecnología en países en desarrollo

Para la implementación de esta tecnología también se ha estudiado factores importantes que afecten la buena adopción de la solución IoT. Las altas tecnologías desarrolladas en países avanzados ha creado un verdadero desafío para los ingenieros a la hora de implementar tecnologías de agricultura inteligente para países en desarrollo. El Perú está todavía lejos de los países desarrollados en tecnología digital, según la Unión Internacional de Telecomunicaciones de la ONU en una publicación del 2015 el índice de desarrollo en TIC's del país era catalogado como bajo comparado con otros países de Sudamérica (figura 31).

Con esta información podemos inferir que la utilización de las tecnologías de información y comunicación por parte de los agricultores sigue siendo extremadamente baja.

Figura 31.
Índice de desarrollo en Tic 2015

Índice de Desarrollo TIC 2015 Sudamérica



Nota: las sumas pueden no cuadrar debido al redondeo
Fuente: Unión Internacional de Telecomunicaciones (2015)



Nota. Extraído de Unión Internacional de Telecomunicaciones de la ONU

Por lo que se requiere tener en cuenta pautas estratégicas para promover la adopción de la agricultura inteligente y en particular de la solución IoT propuesta.

4.1.1. Características de las organizaciones agrícolas en Piura

Las organizaciones agrícolas en Piura y en el Perú en general se caracterizan porque sus estructuras organizativas son simples, sólo unas pocas personas toman las decisiones importantes. La mayoría tiene una estructura flexible que une a miembros de la familia y compañeros de trabajo. Las decisiones importantes dependen en gran medida de los dueños

de las parcelas. Se ubican en áreas rurales remotas que están significativamente rezagadas con respecto a áreas urbanas en términos de velocidad y conectividad a Internet.

Junto a esta limitación también se conoce que sus miembros son personas mayores que en su mayoría carecen de una formación profesional que tienden a adoptar tardíamente nuevas tecnologías o experiencia en gestión, lo que significa que la capacidad de gestión de estas organizaciones es menor al de las grandes organizaciones agrícolas con las que pueden competir.

En cuanto a tecnología, las organizaciones agrícolas piuranas generalmente tiene una utilización mínima o casi nula de las tecnologías de la información, además de que carecen de experiencia en su uso y recurso humano. Todos estos factores como la falta de preparación en recursos humanos, el desconocimiento de las tecnologías de la información, algunas circunstancias externas como la falta de apoyo del gobierno central pueden tener un impacto significativo en las tomas de decisiones para la adopción de tecnología para la agricultura inteligente (Yoon, Lim, & Park, 2020b).

4.1.2. Investigación sobre la adopción de tecnologías de la información

Para afrontar este desafío se buscó en la literatura trabajos relacionados con la adopción de la tecnología, por ejemplo (Rogers, Singhal, & Quinlan, 2019) explica que un obstáculo importante para la adopción de nuevas tecnologías o innovaciones es la incertidumbre, por lo que propuso 3 apartados que deberían tener las innovaciones para reducir la incertidumbre.

- Ventaja relativa
- Compatibilidad
- Complejidad

La ventaja relativa es el grado en que se percibe que una nueva tecnología proporciona mayores beneficios a las empresas, muchos estudios encontraron que esta variable está relacionada positivamente con la adopción de nuevas soluciones tecnológicas, porque cuando

se percibe que las nuevas tecnologías ofrecen una ventaja relativa sobre la práctica actual de la organización es más probable que se adopten (Yoon et al., 2020b).

La complejidad es la medida en que la nueva tecnología se percibe como relativamente difícil de comprender y utilizar. Un cierto grado de complejidad de una innovación puede funcionar como un inhibidor para que la implementación sea exitosa, por lo que se asocia negativamente con la adopción de la tecnología sobre todo en el contexto de pequeñas y medianas empresas.

La compatibilidad es el grado en que una innovación tecnológica tiene coherencia con las necesidades y prácticas actuales de la organización. En casos de alta compatibilidad se ha confirmado que la adopción tecnológica es muy probable si las tecnologías agrícolas inteligentes son compatibles con el trabajo actual de la organización (Y.-M. Wang, Wang, & Yang, 2010).

Otros aspectos importantes son el costo financiero y la competencia técnica de los recursos humanos, que se presentan como factores que influyen en la adopción de tecnología en pequeñas organizaciones. El costo financiero determina si una organización puede permitirse invertir en la introducción y operación de nuevas tecnologías o procedimientos y se reconoce como factor importante en el caso de inversiones a gran escala, como la introducción a la agricultura inteligente. En particular, el costo financiero puede ser un factor de decisión importante para las pequeñas y medianas empresas como son las organizaciones agrícolas en Piura, donde la introducción de la agricultura inteligente puede suponer una inversión relativamente alta para ellos.

En cuanto a los recursos humanos, algunas organizaciones agrícolas carecen de personal adecuado para implementar procesos de innovación o nuevas tecnologías esta puede ser una de las razones por lo que la implementación de la agricultura inteligente todavía está en sus inicios en el Perú.

Otro factor es la presión competitiva, que es el grado de presión que siente la organización por parte de sus competidores. En algunos estudios de adopción de tecnología como en (Y.-M. Wang et al., 2010) y (Low, Chen, & Wu, 2011) se ha sugerido que este factor es

importante para la adopción de tecnología. Ese fue el caso de una empresa agrícola piurana que impulsada por la competencia con empresas extranjeras decidieron innovar en una nueva tecnología para sistema de pesaje en el empaquetamiento de la uva (figura 32), donde el autor de esta tesis fue parte del equipo técnico, con este sistema la empresa logró duplicar su productividad.

Figura 32.
Sistema de pesaje instalado



En (Raj et al., 2021) también destacan obstáculos parecidos para la implementación de la tecnología en la agricultura inteligente, estos obstáculos se pueden resumir en:

- Mano de obra no calificada
- Miedo a las nuevas tecnologías
- Alto costo en las inversiones
- Deficiencia de cobertura y conectividad

Todos estos factores se han tenido en cuenta para poder implementar la solución IoT de manera exitosa, la actualidad exige a los diseñadores e innovadores que examinen conscientemente estos problemas en las primeras etapas de desarrollo ya que las organizaciones agrícolas tienen una tendencia a seguir usando prácticas tradicionales basando sus decisiones en conocimiento empírico y no sobre la base de datos procesados.

Para la mayoría de agricultores en países en desarrollo los avances tecnológicos les debe parecer muy heterógeno y variable incluso en un mismo país (Pivoto et al., 2017), por lo que empezar con los conceptos de la agricultura inteligente tomará algo de tiempo, sobre todo porque cambiarían su forma de trabajar. En una cultura basada en la tradición, es difícil introducir un cambio, por que es necesario que no sólo las empresas y/o universidades expongan lo que es la agricultura inteligente a los productores y agricultores sino también que las entidades públicas y privadas muestren las ventajas de utilizarla, explicando que es la mejor manera de reducir costos, aumentar la calidad de la producción y la sostenibilidad.

4.1.3. Datos insuficientes en las organizaciones agrícolas

El enfoque de agricultura inteligente se basa en la recopilación de datos de diferentes fuentes de la manera más automática posible. Los datos y el flujo de conocimientos son la materia prima de la agricultura inteligente junto con la aceleración del ciclo de desarrollo. Los datos recopilados generalmente se exportan a la nube desde varios tipos de sensores de campo, estaciones meteorológicas, etc. Después de la recopilación automática de datos, el núcleo de la plataforma principal se encarga de procesar esa información y brindarla a los usuarios finales para analizar la producción, el estado del cultivo, la existencia de enfermedades y plagas y así brindar resultados valiosos a los agricultores. Estos sistemas se denominan sistemas de apoyo para la toma de decisiones (Maohua, 2001) y permiten involucrar a todos los actores de la organización agrícola.

En su mayoría las organizaciones agrícolas en Piura no tienen fuentes de datos organizadas para poder iniciar el proceso, es por eso que la solución propuesta ha partido de la puesta en marcha de sensores adaptados para la agricultura inteligente. En soluciones ya implementadas la comunicación se realiza mediante el uso de Internet, y se usan diversos

servicios de recopilación de datos regionales o distribuidos, procesamiento inteligente de información basado en la nube y toma de decisiones, interfaces de usuario y operaciones agrícolas automatizadas. Sin embargo en Piura no tiene un servicio de recopilación de datos regionales organizado. En el año 2016 se implementó 10 estaciones agro meteorológicas con un proyecto de inversión pública llamado "Mejoramiento de la competitividad de la cadena productiva del banano orgánico para mejorar la oferta exportable en la región Piura"; sin embargo, a la fecha esas estaciones no se han podido aprovechar de la mejor manera por parte de los productores de banano, ya sea porque algunas están inoperativas por falta de mantenimiento o por el desconocimiento que se tiene para el tratamiento de la información.

Esas fuentes de datos son aprovechables en la solución tecnológica implementada. Esto se basa en la idea de que si se pueden capturar suficientes datos y se puede aplicar suficiente potencia informática a esos datos, será posible comprender y gestionar cualquier sistema complejo como lo son los ecosistemas agrícolas. Es bien sabido que los datos brindan conocimiento, los buenos datos proporcionan evidencia indiscutible, mientras que las evidencias basadas en suposiciones o en observaciones abstractas pueden llevar a la pérdida de recursos debido a que se toman decisiones basadas en conclusiones incorrectas.

Para poder empezar a trabajar con una agricultura inteligente ha sido necesario administrar diversas fuentes de datos, recopilar la información mediante las nuevas tecnologías IoT, organizarla para procesarla y así poder brindar recomendaciones basadas en el tratamiento de esa información que ayude a mejorar la toma de decisiones en este caso en las plantaciones de banano orgánico de la Región Piura. Uno de los cambios importantes es, por supuesto, la extraordinaria cantidad de datos que deben procesarse y agregarse para extraer información que sea útil para la toma de decisiones operativas en el contexto específico del cultivo de banano. Otro cambio importante es la complejidad de las herramientas y equipos necesarios. Esta complejidad requiere nuevos conocimientos para permitir una implementación adecuada, configuraciones óptimas de herramientas y experiencia técnica para garantizar una interoperabilidad óptima, etc.

El procesamiento de datos automatizado y las redes inalámbricas completamente integradas son el futuro no tan lejano para lograr una agricultura sostenible. Se necesitan

esfuerzos dedicados de todos los actores interesados para hacer realidad esta visión de futuro por lo que debemos afrontar estas limitaciones para que los agricultores puedan adoptar esta nueva tecnología en sus parcelas.

4.2. Implementación de la solución IoT

La introducción de los sistemas de supervisión agrícola en la agricultura han mejorado la forma en que los agricultores toman sus decisiones y, por lo tanto, ha mejorado la producción agrícola (Barakabitze, Fue, Kitindi, & Sanga, 2016). Sin embargo en el Perú no existe un sistema acorde al contexto de la agricultura piurana, por eso se planteó una nueva arquitectura de software IoT para implementar un sistema de apoyo para la toma de decisiones en el cultivo del banano orgánico en la región Piura.

Este sistema implementado combina las siguientes funcionalidades:

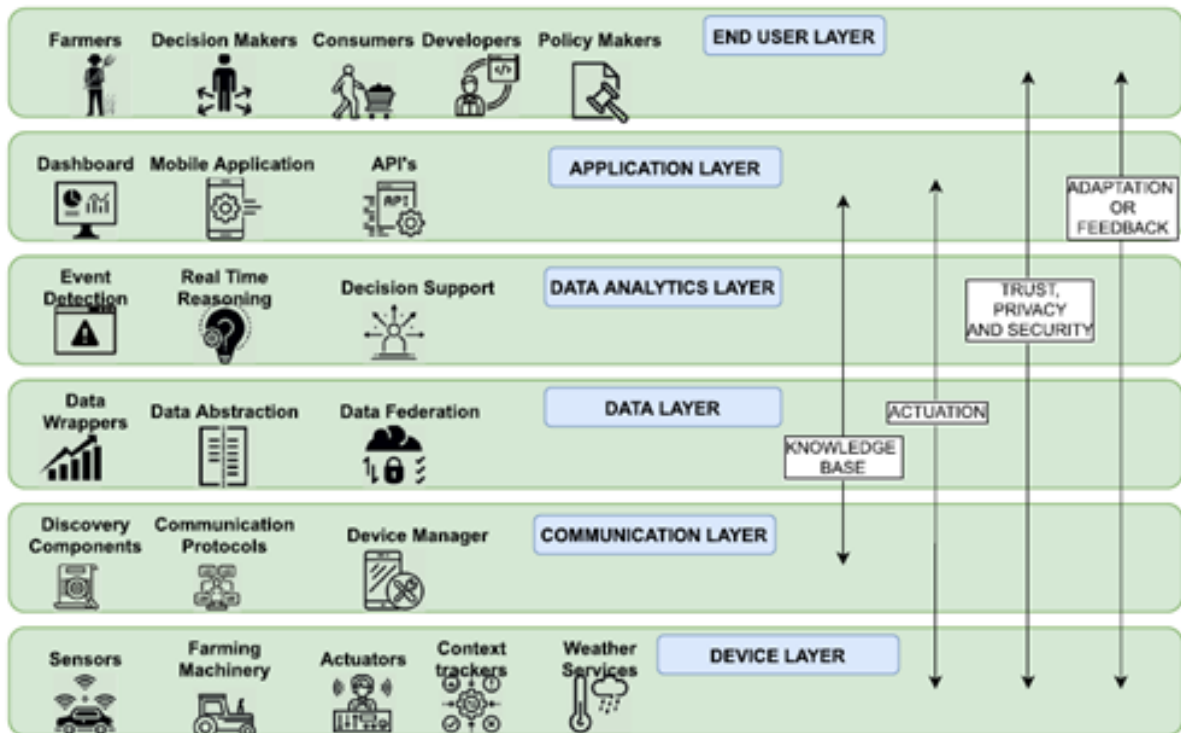
- Adquisición, consulta en intercambio de datos meteorológicos para poner los datos a disposición de usuarios debidamente autenticados.
- Procesamiento de la información a través de modelos matemáticos y herramientas de inteligencia artificial.
- Una plataforma de apoyo en las decisiones sobre el crecimiento del cultivo.

4.2.1. Arquitectura de software

En la literatura existen diversas arquitectura dependiendo del contexto en los que han trabajado. Por ejemplo en (Raj et al., 2021) muestran el esquema de arquitectura de una plataforma denominada Agri-IoT (figura 33), está compuesta por varias capas, la inferior (dispositivos y capas de comunicación), la media (datos y análisis de datos) y la superior (aplicaciones y capa de usuario).

La parte claramente crítica es la integración automatizada de dispositivos a una escala inmensamente grande y garantizar la interoperabilidad entre ellos.

Figura 33.
Arquitectura Agri-IoT




Nota. Extraído de (Raj et al., 2021)

Se necesita incorporar un núcleo de middleware centralizado que pueda resolver las dependencias entre las aplicaciones, que admita la transcodificación entre los distintos protocolos a usar, realizar una interacción eficiente entre los dispositivos y crear servicios dinámicamente innovadores.

En (Sunhare, Chowdhary, & Chattopadhyay, 2020) presentan una arquitectura para el IoT en general donde combinan diferentes protocolos de comunicación (figura 34). Otra arquitectura que es adaptable a la realidad piurana es la presentada en (Roukh et al., 2020), donde explican que la gran cantidad de datos provenientes del IoT deben gestionarse y analizarse para conseguir valor (figura 35).

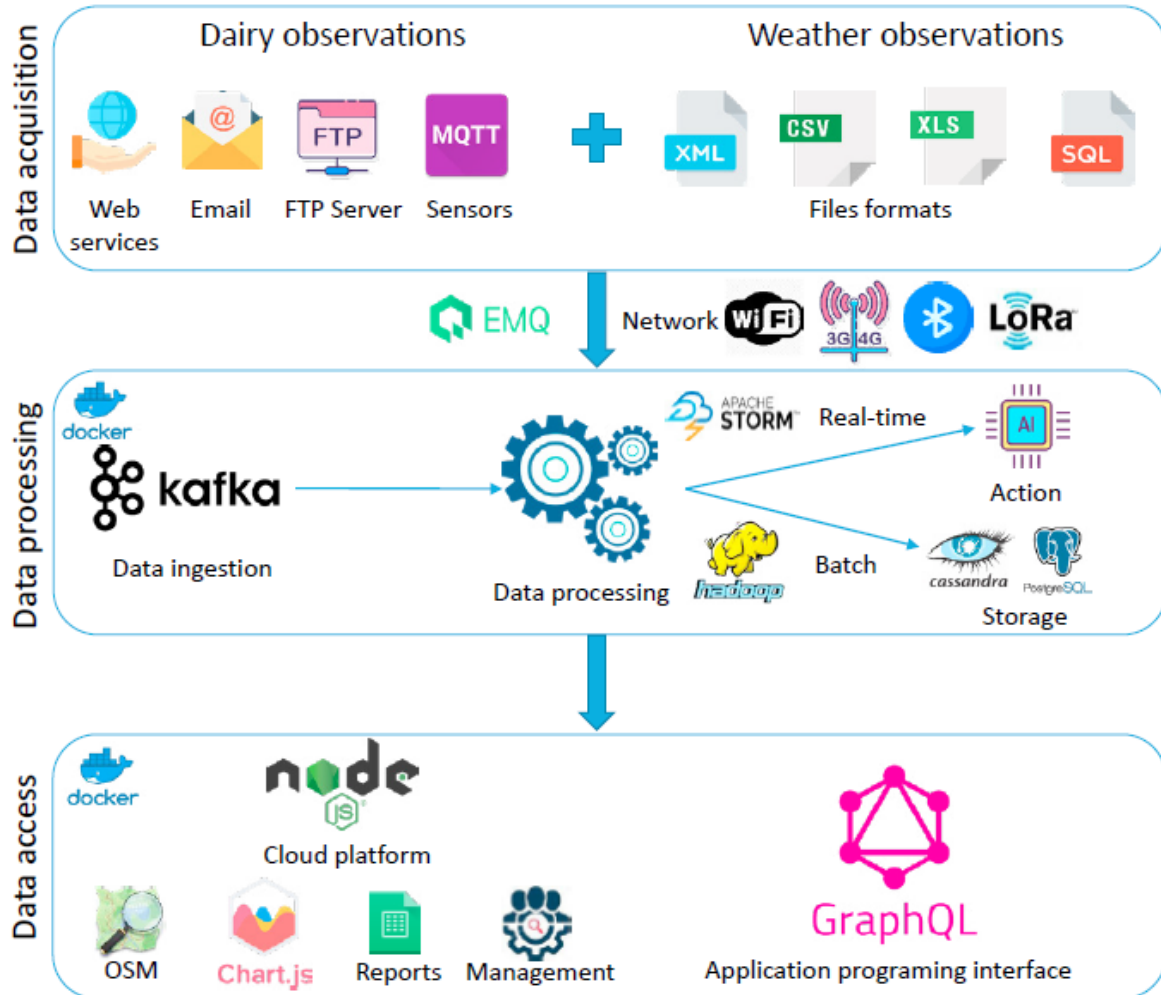
Figura 34.
Arquitectura de una plataforma de soporte de decisiones para el IoT



Nota. Extraído de (Sunhare et al., 2020)

Con este fin, primero, los datos son adquiridos de diferentes fuentes, se integran y se almacenan en un repositorio centralizado. En segundo lugar, se deben utilizar soluciones de bigdata para procesar estos datos, basándose en trabajos por lotes de larga ejecución, así como trabajos en tiempo real para filtrar, agregar y preparar los datos para el análisis. El último paso consiste en proporcionar información a partir de los datos mediante tareas de análisis y

Figura 35.
Arquitectura desarrollada para la agricultura inteligente



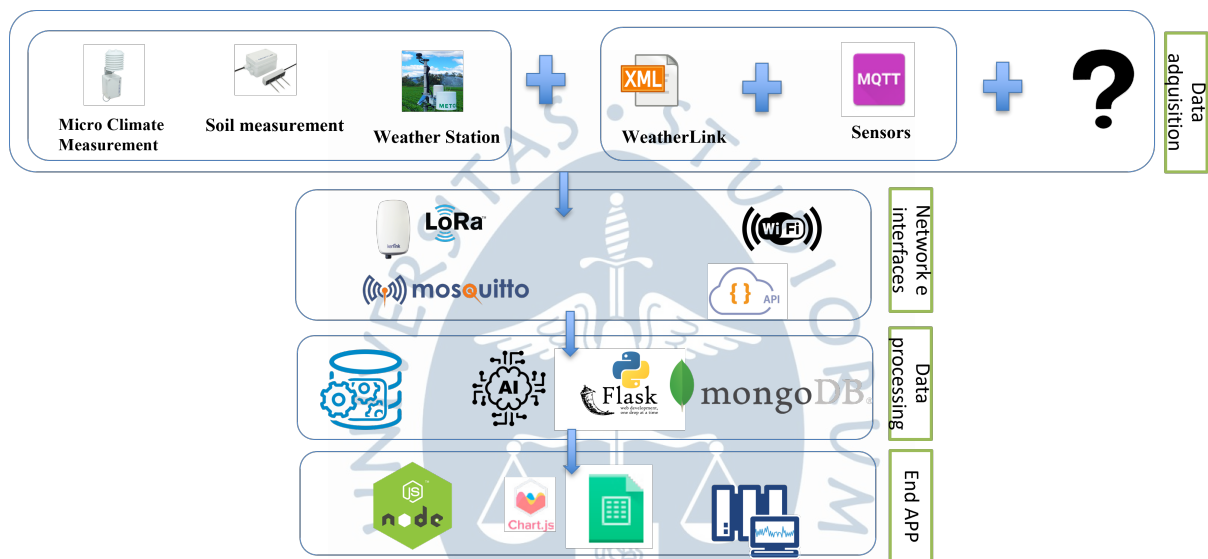
Nota. Extraído de (Roukh et al., 2020)

generación de informes.

Teniendo en cuenta los trabajos anteriores, lo que se ha propuesto en esta investigación es una nueva arquitectura acorde al contexto de la agricultura en Piura, donde se pueda recibir un flujo de datos masivo en tiempo real de diferentes fuentes y segundo, realizar un análisis de estos datos para obtener resultados de inmediato.

La arquitectura propuesta en esta tesis (figura 36) tendrá 3 fuentes de datos principales: los datos provenientes de los sensores con tecnología inalámbrica Lora, datos provenientes de las API de las estaciones meteorológicas instaladas, y las fuentes de datos que se puedan recopilar de las estaciones meteorológicas instaladas por el Gobierno Regional de Piura por lo que es necesario trabajar en un protocolo estándar.

Figura 36.
Arquitectura IoT de la solución a implementar



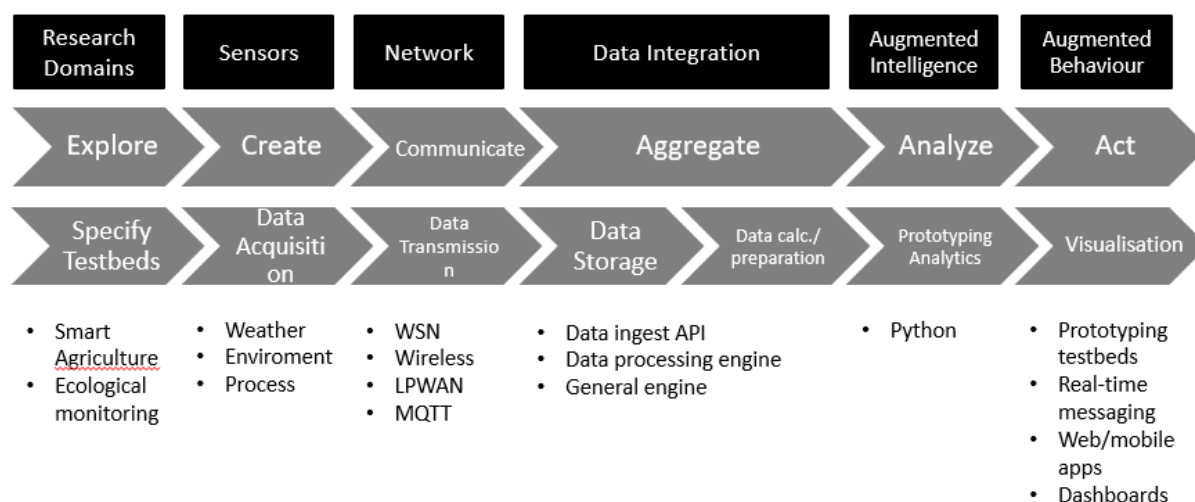
Nota. Elaboración propia

Diseñar e implementar sistemas informáticos y electrónicos, especialmente IoT, para la agricultura inteligente es un desafío, por lo que se plantea el siguiente enfoque sistemático. Varias plataformas de nube de IoT están disponibles en forma de servicios de nube pública (Azure IoT Suite, Amazon AWS IoT y otras), pero se quiere centrar en una implementación privada utilizando software de código abierto.

Esta solución puede ayudar a los agricultores, empresarios agrícolas e individuos particulares a conectar datos meteorológicos de su cultivo a Internet sin una cobertura de red masiva. El sistema adopta sensores LoRa, integrando además tecnología de plataforma en la nube y transmisión inalámbrica LoRaWAN. El sistema podrá realizar la visualización de los datos, seguimiento del cultivo y algunas recomendaciones para tener un mejor soporte de las

decisiones a tomar.

Figura 37.
Enfoque sistemático de la solución



Nota. Elaboración propia


Entonces, siguiendo este concepto, nuestro campo de investigación es la agricultura inteligente y su monitoreo. Se pueden adquirir datos climatológicos y de proceso. La transmisión se realizará a través de redes WSN, Wireless, y LPWAN. La solución contará con un motor de procesamiento de datos como MySQL y MongoDB, además las aplicaciones prototipo a implementar estarán basadas en Java Script y Python para hacer analíticas. Y la visualización se realizará a través de Dashboard, web, web versión móvil, mensajería en tiempo real, etc.

4.2.2. Desarrollo del sistema en el contexto Piurano

La plataforma debe obtener la mayor cantidad de datos posible para poder organizarla, nuestra principal fuente de datos serán los datos producidos por los sensores Lora que se instalarán en Sullana, pero también debemos procesar los datos de la estación en Chulucanas y el datos que podemos recopilar de las estaciones meteorológicas instaladas en Piura.

Cuanto más datos se tengan será mejor, Piura no tiene una fuente organizada de información agrícola y con esta solución podemos empezar a desarrollar esto. La plataforma estará en la nube con funcionalidades prototipo a las que se podrá acceder a través de Internet.

Figura 38.
Sistema en el contexto piurano



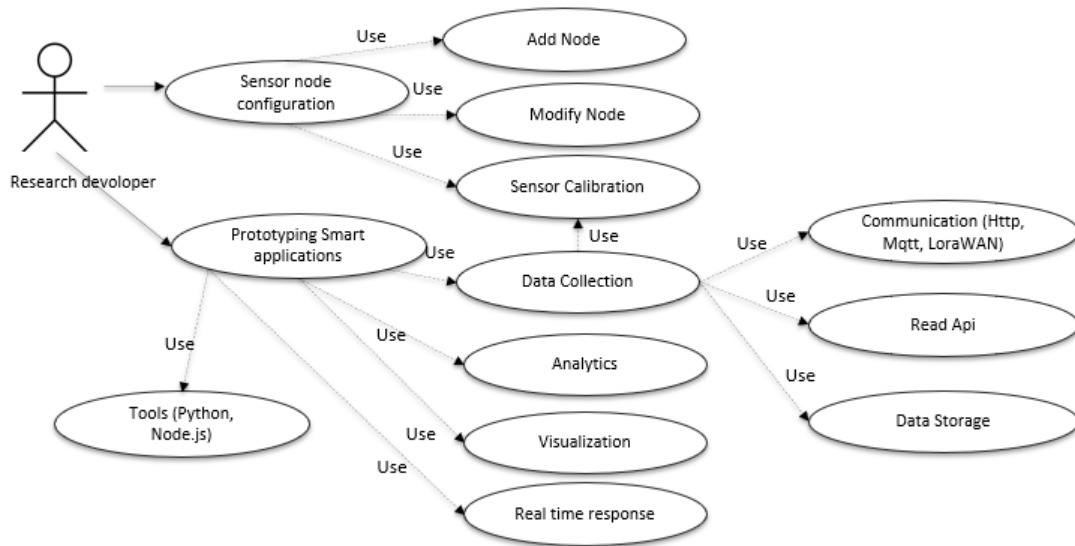
Nota. Elaboración propia

4.2.3. Diagramas UML de la arquitectura de software

La siguiente figura muestra el diagrama de casos de uso de las funcionalidades a implementar. La plataforma proporcionará al usuario herramientas para leer los nodos de sensores. Cada nodo sensor se identifica con su nombre, ubicación, y la descripción de las medidas obtenidas por sus sensores. La recopilación de datos es otra funcionalidad. La plataforma espera continuamente los datos de los sensores, se han habilitado los protocolos http, LoRaWAN y cuando lleguen nuevos datos se almacenarán. Finalmente, la plataforma proporcionará herramientas para visualización en tiempo real.

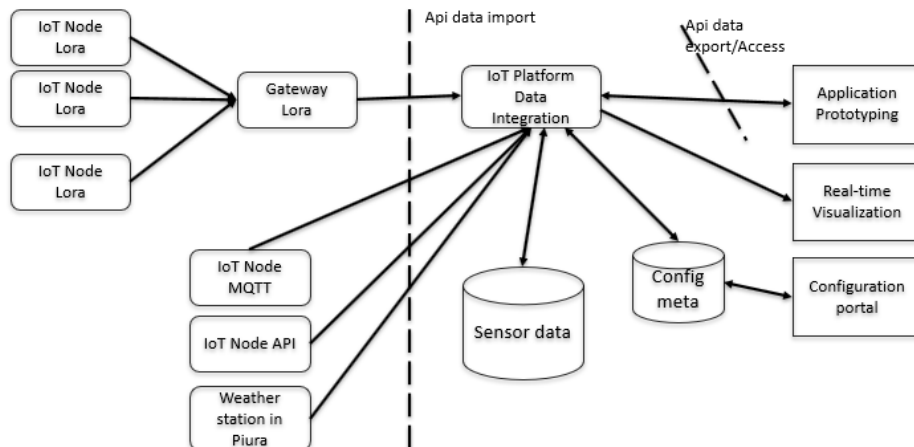
También se ha diseñado la interacción de los bloques del sistema. Se propone que los datos de los nodos de IoT se transfieren a la plataforma utilizando el protocolo Lora, http y Api para la importación de datos. Los nodos se comunican con la plataforma a través de un Gateway. La base de datos se utiliza para el almacenamiento. La plataforma también proporcionará una API para la exportación y acceso de datos (históricos), y esto permita crear nuevas aplicaciones. La vista de implementación del sistema propuesto se muestra con el siguiente diagrama de componentes.

Figura 39.
Casos de uso



Nota. Elaboración propia

Figura 40.
Diagrama de bloques



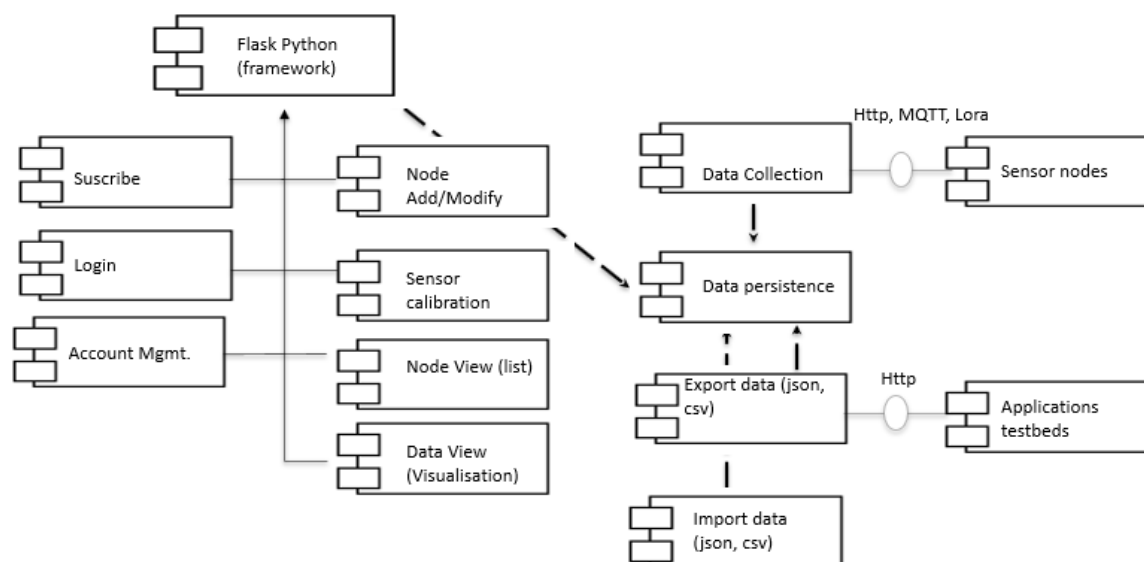
Nota. Elaboración propia

Los nodos sensores se comunican con el módulo de recopilación de datos mediante solicitudes HTTP, API y Lora. Cuando se reciben, los datos se guardan en la base de datos, que también es utilizada por otros componentes (flechas discontinuas).

Para el usuario, la plataforma se implementa como un portal web dinámico utilizando Python, JavaScript y el framework Flask, que implementa el patrón de arquitectura Modelo-Vista-Controlador. A través de la web, el usuario puede acceder a las páginas para suscribirse, iniciar sesión y administrar su cuenta.

El usuario puede exportar e importar manualmente los datos para su análisis y copia de seguridad. Por último, se puede acceder a los datos utilizando la API de lectura para su uso en aplicaciones prototipo desarrolladas.

Figura 41.
Diagrama de componentes



Nota. Elaboración propia

4.2.4. Requisitos de sensado

Se trabajó en una hectárea de una plantación de banano. Se instalaron 4 nodos de medición de parámetros del suelo, 4 nodos de medición de parámetros climatológicos cercanos a una planta de banano los cuales se denominaron nodos micro clima y 1 estación meteorológica en una esquina de la hectárea para monitorear las condiciones meteorológicas generales.


El sistema tiene propiedades para lograr una amplia cobertura de red de comunicación y adquisición de los datos de los diferentes puntos de la hectárea. Para esto la tecnología Lora

es importante sobre todo en zonas rurales que es donde más se trabaja la agricultura. Con esta tecnología se puede aumentar la distancia de comunicación entre los nodos y reducir la cantidad de nodos de retransmisión que se necesiten instalar.

En el complejo entorno de áreas remotas, la distancia de comunicación LoRa puede alcanzar más de 2 km. El sistema planteado también podrá transmitir los datos recopilados a una plataforma desarrolla e instalada en la nube, que puede monitorear y visualizar la información.

El diagrama esquemático de la instalación de sensores se muestra en la figura 42 .

Figura 42.
Diagrama de instalación de sensores



Nota. Elaboración propia

Todos estos sensores son compatibles con la arquitectura LoRaWAN de tal manera que se comunican inalámbricamente a un gateway instalado en una oficina de la asociación que está aproximadamente a 2km de distancia de la plantación.

Hardware para sensado del suelo

Se decidió trabajar con los sensores del fabricante Decentlab, para el sensado de parámetros del suelo se usará el sensor modelo DLTRS12, este sensor se instaló a metro y medio del suelo. Consta de 2 partes, una es la caja que se encarga de la transmisión que va conectada a los sensores directamente (figura 43). Los sensores están enterrados a 30 cm, 60

cm, 90 cm en el suelo. El margen de error de este dispositivo es de ± 0.1 °C entre -40 y 60 °C y para conductividad eléctrica ± 0.0001 decisiemens/metro entre 0 y 20 decisiemens/metro. La duración de la batería es mayor a 10 años.

Figura 43.
Modelo DLTRS12



Nota. Extraído de Web Decentlab: <https://cdn.decentlab.com>

Hardware para sensado del micro clima

Para estos nodos se usó el sensor del fabricante Decentlab modelo DLH35, este sensor se instaló en un poste a más de 2 metros del suelo (figura44). Mide temperatura con buena precisión, ± 0.1 °C entre 20 y 60 °C y ± 0.2 en un rango más amplio. A nivel de humedad es ± 1.5 % entre 0 y 80% y ± 2 % de 80 a 100%. Las pilas que utiliza son alcalinas estándar tipo C y pueden durar hasta 12 años.

Hardware para sensado de las condiciones meteorológicas

Para este punto se seleccionó una estación meteorológica modelo μ METOS que tiene configurada una variedad de sensores para el monitoreo de datos en la agricultura (figura 44). Esta estación meteorológica es LPWAN (Low Power Wide Area Network), opera en la red LoRaWAN. Puede conectarse a cualquier red LoRaWAN existente, si cumple con los parámetros de distancia. Está diseñada para monitorear parámetros meteorológicos básicos (lluvia y

Figura 44.
Modelo DLH35



Nota. Extraído de Web Decentlab: <https://cdn.decentlab.com>

temperatura, humedad, radiación solar, velocidad del viento). También se le podría instalar sensores adicionales si es necesario.

Los datos se miden permanentemente en intervalos de 5 minutos y se envían cada 15 minutos al servidor.

Hardware para la transmisión de datos

Para la recepción de datos se usó un gateway LoRa de tipo exterior (figura 46). Este equipo modelo iStation del fabricante Kerlink tiene la frecuencia autorizada para trabajar en Latinoamérica, soporta hasta 2500 dispositivos y tiene un alcance máximo de 6km.

El gateway estará conectado a una antena para obtener la potencia necesaria para lograr una comunicación eficiente a la distancia requerida, también estará conectado a Internet mediante una conexión ya existente y alimentado por un panel solar y UPS.

Figura 45.
Estación meteorológica μ METOS



Nota. Extraído de Web Decentlab: <https://cdn.decentlab.com>

Figura 46.
Gateway para la transmisión de datos modelo iStation



Nota. Extraído de Web Kerlink: <https://www.kerlink.com/product/wirnet-station/>

4.2.5. Estructura de la arquitectura y diseño del sistema

DetECCIÓN Y RECOPIACIÓN DE DATOS

Todas las prácticas agrícolas inteligentes se inspiran en las tecnologías de detección, ya sea que los datos se recopilen de sensores en el suelo, de sensores que midan variables climatológicas o de señales satélites.

Los sensores que se instalaron en las parcelas se personalizaron de acuerdo al tipo de datos requeridos, las decisiones se tomaron en base a:

- La ubicación de los sensores en el suelo y microclima, el gateway de transmisión.
- La configuración del tiempo de muestreo.
- El tamaño de la carga útil de los datos.
- Asegurar el suministro de energía de los sensores por lo que se planteó trabajar con equipos a batería.

ADQUISICIÓN DE DATOS LoRaWAN

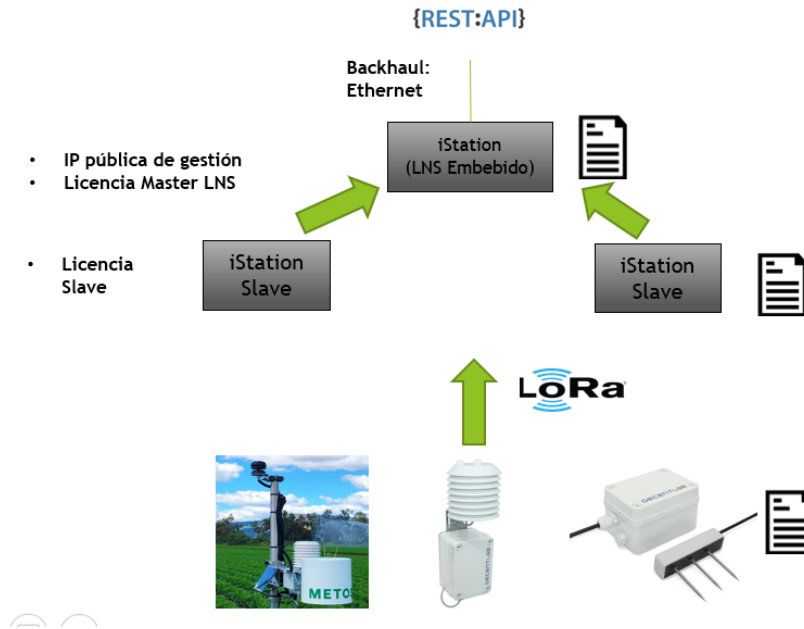
La solución tiene énfasis en los datos de los sensores LoRa, La adquisición de esos datos se hará a través del consumo de un api rest instalado en el servidor de red embebido en el gateway encargado de la transmisión de datos a Internet.

Este servidor recibe los datos encriptados enviados desde los sensores a través del protocolo LoRaWAN. El servidor tiene una licencia, que puede ser de tipo máster o tipo esclavo, sin embargo como la solución tiene un solo gateway instalado se le llama standalone. Con esa licencia se puede generar todo el servidor de red, con todas las cualidades necesarias para la administración, gestión y captura de la información de cada uno de los sensores (figura 47).

A través del ip lo que se hace es registrar los sensores autenticados, ver el proceso de encriptación de datos y comenzar la captura de datos.

Figura 47.

Interfaz de comunicación entre la capa física de sensado y los sistemas de red



Nota. Elaboración propia

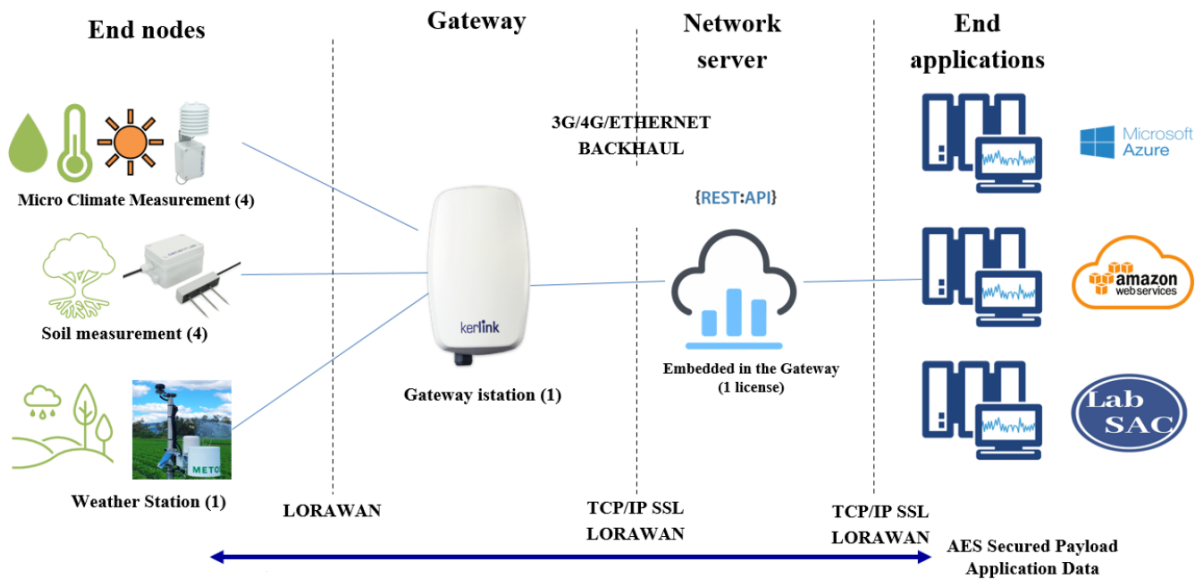
Transmisión de datos

La plataforma tendrá habilitada diferentes interfaces de red para la conexión con la capa de procesamiento, tales como el Gateway Lora, Internet, y API-Rest. Estas son herramientas de código abierto para la transmisión de datos que se convierten en la mejor opción considerando costo y efectividad (Terengia Materu et al., 2016). En las zonas rurales existe muy poca disponibilidad y confiabilidad de la conectividad móvil, por lo que se le ha dado más énfasis a las redes LPWAN porque ya se ha demostrado que con esta tecnología se pueden atender el manejo de cultivos agrícolas.

Arquitectura LoRaWAN

La transmisión de datos desde los nodos finales hasta las aplicaciones finales son basados en una arquitectura LoRaWAN transparente. Los datos transmitidos pueden ser caracteres o hexadecimales. El diagrama esquemático se muestra en la figura 48.

Figura 48.
Arquitectura LoRaWAN llevada al sistema planteado



Nota. Elaboración propia

Almacenamiento de datos

El volumen de datos en la agricultura inteligente aumenta día a día ya que se deben guardar diferentes variables. Por lo tanto, el almacenamiento y procesamiento de estos datos es un tema necesario y desafiante. Generalmente, las bases de datos relacionales se utilizan para almacenar datos que están dentro de un contexto masivo y diverso. Por lo que ahora se propone usar una solución NoSQL para gestionar la gran cantidad de datos a recolectar.

Entre los diferentes tipos de soluciones de base de datos no NoSQL, se han seleccionado las basadas en documentos de acuerdo con la naturaleza de los datos agrícolas. El modelo considerado se ha implementado en un entorno de nube para aprovechar las propiedades de distribución.

El trabajo de (Celesti et al., 2020) demostró que el rendimiento de MongoDB era mejor que el servidor SQL tradicional en términos de flexibilidad, preparación de datos y extensibilidad por lo que todos los datos serán almacenados en una en este gestor, además esos datos podrán ser procesados para aplicaciones de inteligencia artificial con el framework

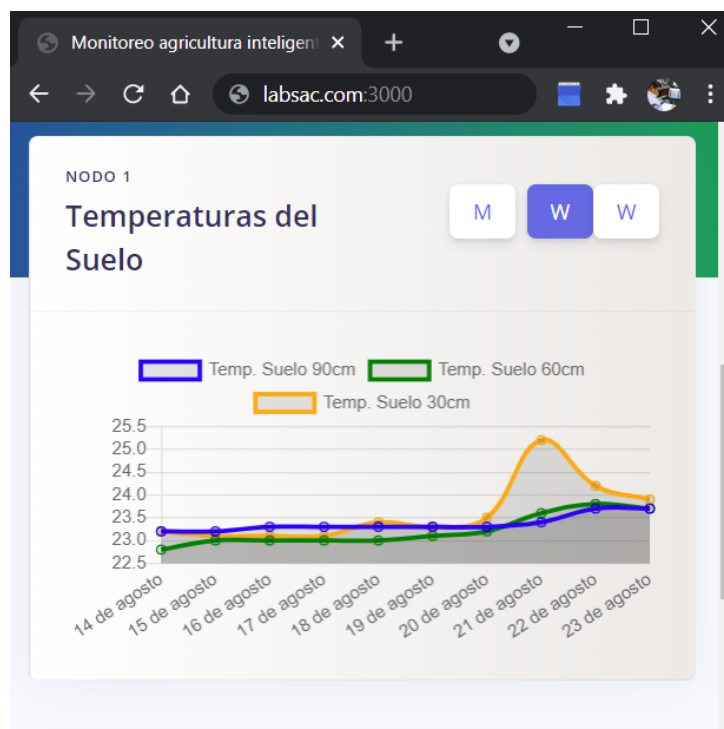
Flask de Python.

Este punto es un verdadero desafío porque es sabido que en el mundo de la inteligencia artificial y la minería de datos los problemas más comunes tienen que ver con el almacenamiento de datos, su organización y administración, la privacidad y seguridad, las limitaciones de procesamiento en tiempo real.

Interfaz de monitoreo

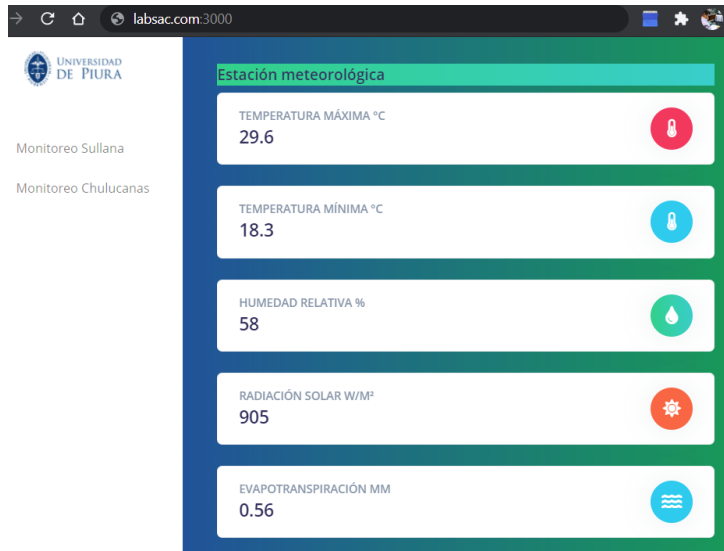
La interfaz de monitoreo fue desarrollada en el framework Flask de python y Node.js (figuras 49, 50 y 51) con formato adaptable para una correcta visualización de los datos en distintos dispositivos electrónicos, con esto, el usuario puede monitorear la situación climatológica de la plantación desde cualquier dispositivo conectado a Internet a través de un navegador web.

Figura 49.
Monitoreo de los parámetros del suelo del nodo 1



Nota. Elaboración propia

Figura 50.
Monitoreo de las variables climáticas de la estación



Nota. Elaboración propia

Figura 51.
Monitoreo de las variables climáticas de la estación



Nota. Elaboración propia



Capítulo 5

Funcionalidades de la plataforma para apoyar la producción bananera

La industria bananera necesita de buenas condiciones climáticas y de suelo para una producción intensiva con fines de exportación. Sin embargo, como es característico de las zonas tropicales durante el año, se producen variaciones considerables en el clima que pueden causar un impacto significativo en la producción. Un conocimiento detallado del comportamiento del clima en tiempo real puede ayudar a optimizar el pronóstico del tiempo, el control de la producción (mejorar tiempos de siembra y cosecha), el desarrollo de sistemas de pronóstico de enfermedades y plagas, recomendaciones para la aplicación de fertilizantes, etc (Calberto et al., 2018).

La aplicación desarrollada en esta etapa de la investigación se especializa en el almacenamiento y manejo de datos de diversas estaciones meteorológicas instaladas cerca a plantaciones de banano en diferentes países tales como Perú (Piura), Colombia y República Dominicana.

La red hace uso de diferentes protocolos para la transmisión de datos logrando relacionar parámetros ambientales como temperatura, humedad relativa, radiación solar, con aspectos del manejo del cultivo como la tasa potencial de emisión de hojas, las semanas de floración a cosecha y el peso potencial del racimo. Con esta aplicación los productores y administradores de los cultivos podrán realizar un monitoreo continuo de las condiciones climáticas de las principales zonas productoras de banano de los tres países en cuestión. La

información en tiempo real para cada país se encuentra en tres sitios web diferentes:

- Perú: <https://ahorapp.herokuapp.com/>
- Colombia: <http://ahorappv3colombia.herokuapp.com/>
- República Dominicana: <https://ahorappv2republicadominicana.herokuapp.com/>

Esta aplicación web facilita el uso de la información para que el productor y los encargados de las fincas optimicen los recursos y obtener mayores beneficios económicos y ambientales. La información disponible contribuye con la industria bananera nacional e internacional a optimizar el manejo de las plantaciones, reduciendo costos y aumentando la producción por parte del uso de la agricultura inteligente.

5.1. Importancia de los datos meteorológicos

El clima es el estado del aire y la atmósfera en un momento y lugar determinados, se expresa mediante elementos meteorológicos como la temperatura, la humedad, el viento, la lluvia, etc. El clima es el efecto combinado de todos los elementos meteorológicos y sus causas están determinadas por factores como latitud, longitud, distribución continental y oceánica de masas, corrientes oceánicas, centro de presiones y barreras orográficas (Salvacion, 2020).

En Perú, Piura posee un clima tropical y seco, con una temperatura promedio anual de 24°C, en el verano supera los 35°C, pudiendo llegar hasta 40°C cuando se presenta el Fenómeno El Niño. La época de lluvias es entre enero y marzo y en las zonas andinas, el clima presenta noches frías y mañanas templadas. El clima de República Dominicana es tropical cálido, que presenta una temperatura bastante estable a lo largo de las estaciones, que ronda entre 25 y 35 °C. Las temperaturas más elevadas se alcanzan en verano entre los meses de julio y agosto, mientras que de noviembre a enero se modifican un poco disminuyendo a 18 °C, en regiones de gran altitud, y 24 °C en el resto del país.

La actividad bananera se concentra principalmente en estas condiciones climáticas y de suelo, para una producción intensiva con fines de exportación. Sin embargo, como es característico de las zonas tropicales, durante el año existen variaciones considerables en el

clima que pueden causar un impacto significativo en la producción, debido a la alta influencia del clima en el crecimiento, la producción del cultivo y sobre la incidencia y severidad del ataque de plagas. Enfermedades como los trips de la mancha roja en Piura, la Sigatoka negra en Colombia y República Dominicana, continúan siendo una seria amenaza para la producción sostenible de banano. Además, puede afectar el uso de insumos como fertilizantes y reducir el impacto de aplicaciones de herbicidas y fungicidas. Un conocimiento detallado del comportamiento del clima en tiempo real podría ayudar a optimizar la previsión, el control de la producción (mejores épocas de siembra y cosecha), el desarrollo de sistemas de previsión en enfermedades y plagas, mejorar las recomendaciones para la aplicación de plaguicidas, etc. La estrecha relación entre el desarrollo del banano y los factores meteorológicos vienen siendo estudiadas desde siempre. Tanto la tasa de emisión de hojas, como el período de floración y cosecha, están estrechamente relacionada con los grados día acumulados (GDA). Así, el potencial de acumulación de biomasa y la demanda de nutrientes, está fuertemente vinculada con la radiación. Los GDA se relacionan estrechamente con la tasa de emisión de hojas, En (Turner D.W., 1983) explican que para la cosecha del fruto del banano se requieren aproximadamente 900 GDA que es la sumatoria de los grados día desde el momento de la floración. La demanda de nutrientes para el suelo, como el nitrógeno, puede estimarse a partir del crecimiento de la biomasa, que depende a su vez de la radiación recibida e interceptada.

Para el sector bananero en estudio de los diferentes países es de suma importancia determinar la influencia del clima en el cultivo de banano, la variabilidad climática y el cambio climático en el cultivo de banano, por lo que se está desarrollando un sistema automatizado de adquisición de datos de redes de estaciones meteorológicas cercanas a las fincas bananeras. El principal objetivo es generar información en tiempo real disponible para el usuario en una aplicación web, además de promover y facilitar la generación de pronósticos meteorológicos, mejorar la producción y el manejo de plagas para el cultivo de banano.

5.2. Metodologías

Esta parte de la investigación propone tres indicadores de alta importancia para el proceso productivo de banano (tabla 1). Los indicadores propuestos para la plataforma

relacionan los datos de estaciones meteorológicas: temperatura, radiación solar, precipitación y evaporación potencial con parámetros de crecimiento potencial del banano.

Tabla 1.
Indicadores propuestos para la plataforma

Parámetro climático de entrada	Indicador de crecimiento potencial de banano a calcular	Importancia del indicador
Temperatura	Hojas potencialmente emitidas en función de la temperatura promedio diaria.	Verificación del ritmo de desarrollo del cultivo y racimos.
Temperatura promedio diaria	Estimación del período floración a cosecha del racimo.	Verificación del ritmo de desarrollo de racimo.

Nota. Elaboración propia

5.3. Indicadores mostrados en la plataforma

5.3.1. Cálculo de la tasa potencial de emisión de hojas

La temperatura ambiente es el factor más importante que influye en el crecimiento de las plantas. Un aceptable desarrollo de un cultivo ocurre cuando la temperatura ambiente se mantiene dentro de un rango de temperaturas denominadas temperatura base y temperatura óptima.

Este rango de temperatura depende del cultivo, en (Ganry & Chillet, 2008) definen la temperatura base para el cultivo de banano variedad Cavenish en 14 °C (variedad cultivada en la hectárea de medición) y la temperatura óptima alrededor de los 30 °C. Así mismo con los datos de los *GDD* y los *GDA* se pueden realizar cálculos aproximados acerca del número de hojas potenciales del banano (ecuación 5.1).

$$NHojas = GDA/108. \quad (5.1)$$

Donde *NHojas* es el número de hojas del banano, *GDA* son los grados días acumulados y 108 es la constante que representa el valor en *GDA* medido como potencial

para generación de una hoja.

Para esta funcionalidad se desarrolló el siguiente formulario, el usuario debe elegir la estación más cercana a su parcela e indicar la fecha aproximada de cosecha.

Figura 52.

Formulario para el cálculo de número de hojas

Número de semanas necesarias de floración a cosecha, para garantizar madurez fisiológica y calibre óptimo de racimo. Un cálculo basado en temperatura promedio diario y acumulación de grados día.

Seleccionar estación de interés:

Chulucanas

Indique la fecha de la última cosecha realizada, para calcular la fecha aproximada en que se dio la floración:

dd/mm/aaaa



Nota. Elaboración propia


Después de hacer clic en calcular datos los resultados son los siguientes:

5.3.2. Cálculo del período de floración a cosecha

En (Ganry & Chillet, 2008) y (Chillet, Hubert, & De Lapeyre, 2010) explican que para la cosecha del fruto del banano se requieren aproximadamente 900 *GDA* (grados días acumulado) que es la sumatoria de los *GDD* desde el momento de la floración. Por lo que también se pueden aproximar los días faltantes para la cosecha (ecuación 5.2).

$$DCosecha = (900 - GDA)/GDDPromedio. \quad (5.2)$$

Figura 53.
Resultados para el cálculo de número de hojas



Nota. Elaboración propia

Donde $DCosecha$ representa los días que faltan para la cosecha, GDA son los grados días acumulado y $GDDPromedio$ es el valor promedio de grados día. Basados en estas ecuaciones, y al tener los datos de temperaturas en la base de datos, se puede calcular los grados días acumulados desde el momento de la floración. El productor sólo debe ingresar al sistema el día de floración aproximado para empezar la cuenta. Para esta funcionalidad se desarrolló el siguiente formulario, el usuario debe elegir la estación más cercana a su parcela e indicar la fecha aproximada de floración.

Después de hacer clic en calcular datos los resultados son los siguientes:

5.3.3. Cálculo del peso potencial de racimo

La radiación solar es la base de la productividad potencial de un agroclima. Los modelos en la literatura se basan en la radiación incidente y la radiación interceptada por el cultivo con la aplicación de la ley de Beer-Lambert (5.3).

Figura 54.


Formulario para el cálculo del período de floración a cosecha

Número de semanas necesarias de floración a cosecha, para garantizar madurez fisiológica y calibre óptimo de racimo. Un cálculo basado en temperatura promedio diario y acumulación de grados día.


Seleccionar estación de interés:

Chulucanas

Indique la fecha de la última cosecha realizada, para calcular la fecha aproximada en que se dio la floración:

dd/mm/aaaa 

Indique la fecha de floración más reciente, para proyectar la semana óptima de cosecha:

dd/mm/aaaa 

Calcular datos

Nota. Elaboración propia

$$I = I_0(1 - e^{-KL}) \quad (5.3)$$

Donde:


- I : Radiación captada
- I_0 : Radiación incidente llegando a la superficie de la copa de banano
- K : Es la tasa de extinción o como la luz se transmite entre la copa de banano
- L : Es el índice foliar.

El indicador del peso potencial de racimo se fundamenta en que la radiación

Figura 55.
Resultados del cálculo del período de floración a cosecha

Estimación de la próxima fecha de cosecha - Estación: Chulucanas

Fecha de cosecha proyectada según acumulación de grados día desde floración.



Variación de temperatura, humedad relativa y acumulación de grados día, desde floración 15/01/2022 hasta el día anterior a la fecha de consulta.



Nota. Elaboración propia

interceptada por la floración a la cosecha, es la base principal de la formación del racimo. La radiación interceptada durante la acumulación de los 900 GDA se convierte en biomasa seca a razón de 1.5 g/MJ. La radiación solar es calculada en MJ/m². Para esta funcionalidad se desarrolló el siguiente formulario, donde el usuario deberá ingresar la fecha aproximada de cosecha y la densidad de plantas de banano por hectárea.

Después de hacer clic en calcular datos los resultados son los siguientes:

5.4. Predicción de población de trips en base a condiciones climáticas usando PCA, redes neuronales y series de tiempo

Con el auge de las tecnologías de la información y comunicación se ha podido desarrollar sistemas de gestión agrícola más precisos y lograr lo que se llama ahora agricultura inteligente (Kiran, Sandeep Kanumalli, Venkata Sessa Sai Rama Krishna, & Chandra, 2021). Estudios enfocan la agricultura inteligente por etapas; como siembra(Kumar & Ashok, 2021), cosecha(Sadowski & Spachos, 2020) y poscosecha(M S, R, & M, 2021). En cada una de estas etapas es necesario adoptar medidas agronómicas apropiadas en base a información relevante,

Figura 56.


Formulario para el cálculo del peso potencial de racimo

Estimación del peso potencial del racimo para verificar la productividad del cultivo. Calculo en función de la radiación solar.

Seleccionar estación meteorológica de interés:

Chulucanas

Indique la fecha de la última cosecha realizada, para calcular el peso potencial que debió alcanzar el racimo:

dd/mm/aaaa 

Densidad de plantas de banano por hectárea (Rango 1800 - 2600)

Calcular datos

Nota. Elaboración propia

Figura 57.

Formulario para el cálculo del peso potencial de racimo

Peso potencial de racimo - Estación: Chulucanas

Estimación del peso potencial de racimo para la fecha de cosecha especificada.

Información

Para la fecha de cosecha 1/01/2022 y un período de llenado de 12 semanas, el peso potencial del racimo fue de 38.5 kg por planta o 69.3 toneladas por hectárea

Nota. Elaboración propia

que se obtiene de la recopilación de diferentes fuentes de datos, la expansión del Internet de las cosas (IoT) y la instalación de redes de sensores inalámbricos (WSN).

Uno de los objetivos de la aplicación de las tecnologías de la agricultura inteligente es la detección en fase temprana de plagas para reducir su población. Para esto es importante el monitoreo de las condiciones climáticas en la agricultura, porque permite recabar información que puede ser aprovechada para el manejo de este problema en los cultivos, y así obtener

productos de mejor calidad. Por otro lado, si las parcelas agrícolas se infectan por encima de un umbral específico los daños llegan a ser importantes y afectan de manera negativa el rendimiento ocasionando pérdidas considerables. Un ejemplo importante en Sudamérica fue el descrito en (C. Oliveira, Auad, Mendes, & Frizzas, 2014), donde indicaron que en Brasil las plagas causan una pérdida anual promedio de 7.7% en la producción, lo que representa una pérdida anual de aproximadamente US\$ 17.7 mil millones. Así también, la información sobre la ocurrencia de plagas es importante para reducir el uso de pesticidas, y proteger el medio ambiente (Xiu, Lu, Qi, Wang, & He, 2021). Sin embargo, a pesar de la certeza que existe sobre los impactos negativos de los pesticidas sintéticos, los agricultores de América Latina continúan usando pesticidas en altos niveles y con un alto costo para la sostenibilidad social, ambiental e incluso para la salud. Por ejemplo, en (Hammond Wagner, Cox, & Bazo Robles, 2016) hicieron un estudio con agricultores peruanos y encontraron que el 22% de los encuestados experimentaron envenenamiento por pesticidas. Todas estas problemáticas demuestran lo importante que es desarrollar estrategias para el manejo sostenible de plagas a nivel local en comunidades latinoamericanas.

La mayoría de investigaciones que afrontan el problema se enfocan en sensores de imágenes para la detección y el seguimiento de insectos. En (Li et al., 2021) desarrollan un modelo de redes neuronales convolucionales trabajando con un dataset de imágenes y aplicando técnicas de preprocesamiento de datos y modelado. En (Karar, Alsunaydi, Albusaymi, & Alotaibi, 2021) presentan un modelo para clasificar automáticamente las plagas utilizando deep learning (redes convolucionales), trabajaron con cinco grupos de imágenes de plagas: áfidos, cicadellidae, gusanos, escarabajos y araña roja, logrando un F1-score (medida de la precisión de un modelo en un conjunto de datos) del 98%. En (Kalkura, B, N, Surya, & Ramyashree, 2021) describen un software para el control de plagas, donde se captura la imagen de la plaga usando una aplicación móvil, y una vez obtenido el dataset de imágenes adoptaron una clasificación de redes neuronales convolucionales para identificar la clase de plaga obteniendo una precisión del 98%.

Las investigaciones descritas anteriormente están orientadas al procesamiento de grandes cantidades de datos obtenidos de dispositivos de detección de imágenes, con lo que el enfoque

de deep learning está bien aprovechado, como lo demuestra la gran precisión en sus resultados. Sin embargo, en el caso de la agricultura a menor escala no se dispone de mucha información o datasets para entrenar ese tipo de modelos. La información más factible de recopilar es la de las condiciones climáticas que se obtienen de las estaciones meteorológicas cercanas a la zona del cultivo. Estos datos se pueden aprovechar para relacionar el comportamiento del clima con el crecimiento de plagas y tomar mejores decisiones basados en datos objetivos y así lograr una mayor sostenibilidad (Said Mohamed et al., 2021). Otras investigaciones aprovechan los datos climáticos para otros enfoques, como en (Ukhurebor et al., 2022), donde explican la importancia del monitoreo de las condiciones climáticas, la inteligencia artificial, el IoT y el BigData para predecir la variabilidad climática. Se enfocan en el estudio de sistemas de monitoreo de clima para evitar efectos negativos en las actividades agrícolas. En (Kiran et al., 2021) hacen predicciones del desarrollo del rendimiento de los cultivos en base a pronósticos del tiempo. En (Garrett et al., 2013) han relacionado la variabilidad climática debido al cambio climático a la pérdida de rendimiento en los cultivos y al riesgo de la aparición de insectos, explicando que la agricultura de menor escala es más susceptible a ser atacada por plagas. En (Manrique-Silupu, Campos, Paiva, & Ipanaqué, 2021) desarrollaron cuatro modelos para estimar la cantidad de plagas en una parcela de banano (uno por estación), usando técnicas de machine learning y tomando como datos de entrada determinadas variables atmosféricas.

La magnitud de una plaga en una parcela se comprueba generalmente mediante la observación visual y contando los insectos capturados. Esta forma de trabajo requiere de una o varias personas que revisen de forma diaria o semanal una muestra de plantas del cultivo, este trabajo consume mucho tiempo y no todos los pequeños agricultores están dispuestos a realizarlo, sobre todo por el costo de mano de obra y en algunos casos los costos de recursos necesarios, como el combustible de los vehículos para acceder a diferentes zonas de las plantaciones. A esto se suma que, los pequeños agricultores en su mayoría, no tienen acceso a fuentes de datos climáticos organizados (Yoon, Lim, & Park, 2020a) que les brinde información relevante.

Esta parte de la investigación se enfoca en la predicción de plagas, concretamente de los trips de la mancha roja (*Chaetanaphothrips signipennis*) que afectan al cultivo de banano

(McGuire & Northfield, 2021). El Perú es uno de los principales productores y exportadores de este fruto (Belupú, Estrada, Oquelis, & Ipanaqué, 2021), sin embargo, la falta de tecnología en el proceso productivo, el manejo de prácticas tradicionales ineficientes, y el aumento de los estándares que se requieren para exportar un producto de calidad, complican la sostenibilidad de este sector. La motivación de este trabajo proviene de la necesidad de predecir de manera oportuna la aparición de esta plaga en función de los datos climáticos y evitar pérdidas en el rendimiento de los cultivos. Para afrontar el problema, se buscó primero la adquisición automática de variables de estaciones meteorológicas ya instaladas en la zona de estudio, para relacionarlas con el crecimiento de trips. Los datos de clima se obtuvieron a través de sensores WSN, se desarrolló un módulo software para la adquisición de estos datos, además se desarrolló un sistema Web para que los agricultores puedan registrar la incidencia de esta plaga, estos datos fueron usados para entrenar los diferentes modelos de machine learning probados. El objetivo final es predecir el grado de infestación de estos insectos, usando parámetros meteorológicos para dar a los agricultores el tiempo suficiente para reaccionar y evitar la propagación de este mal en su cultivo.

5.4.1. Metodología

La metodología propuesta tiene como objetivo la predicción de la aparición de los trips de la mancha roja en el cultivo de banano tomando como base las condiciones ambientales.

Como datos de entrada, se seleccionaron once variables climáticas que se detallarán más adelante. Para la adquisición de estos datos, se desarrolló un módulo software que permite la recopilación automática de la información de estaciones meteorológicas que trabajan con el protocolo de transferencia de datos Api-Rest. Después, fue necesario obtener el grado de población de trips que existía en la parcela de estudio, para configurarlo como datos de salida del modelo. En este caso, se desarrolló un sistema web donde el agricultor podía digitalizar la incidencia de trips. Esto permitió evaluar el estado de la parcela en cuanto a esta plaga, sin embargo, vale recalcar que las evaluaciones no fueron hechas de forma periódica.

Una vez construido el dataset, se usó el algoritmo de análisis de componentes principales (PCA) para el pre-procesamiento de los datos, y finalmente se probaron diferentes

técnicas de machine learning para la creación del modelo y generación de resultados.

5.4.2. Dataset

Las muestras de la plaga de trips fueron obtenidos de la base de datos del sistema de registro de plagas desarrollado.

El dataset original corresponden a 161 muestras de trips, que van desde finales del año 2019 hasta inicios del año 2022. En cuestión, no se cuenta con datos diarios de reconocimiento de esta plaga. Sin embargo, el rango temporal de información de trips nos permite seleccionar las observaciones obtenidas por la estación meteorológica durante tales fechas. Finalmente, los datos corresponden a 851 días consecutivos (observaciones) de once variables meteorológicas:

- Temperatura promedio diaria
- Energía Solar
- Evapotranspiración
- Precipitación acumulada diaria
- Tasa de lluvia
- Humedad relativa promedio diaria
- Temperatura máxima del día
- Temperatura mínima del día
- Humedad relativa máxima del día.
- Humedad relativa mínima del día.
- Velocidad del viento.
- Grados día (GDD)

La variable de grados día (GDD) no es un dato que proporciona la estación meteorológica, se obtiene en un cálculo posterior a partir de la variable Temperatura promedio

diaria para añadirse al conjunto total de variables meteorológicas, es uno de los indicadores que comúnmente se utilizan para estimar el desarrollo de un cultivo (Belupú et al., 2021).

Otras variables agregadas al dataset fueron las de estrategias de fumigación y limpieza, como se propone en (Manrique-Silupu et al., 2021). Estas estrategias son variables con comportamiento exponencial con tasa negativa. Con esto se logra agregar al dataset una variable que relaciona la limpieza de la planta y dos variables para la fumigación, correspondientes a una correctiva y otra preventiva. La finalidad es evaluar la incidencia de estas variables sobre la plaga.

- F1, fumigación con efecto acumulativo para trips de la mancha roja.
- F2, fumigación con efecto acumulativo para otras plagas.
- TL, Limpieza de la planta con efecto acumulativo.

Los datos de estas variables acumulativas son un total de 734 observaciones continuas en el tiempo. Finalmente, si se contrastan con el set de datos de variables climáticas además del set de datos de la plaga, se obtiene un total de 148 observaciones totales para realizar el entrenamiento de un modelo de machine learning.

El dataset final de los datos de entrada está formado por las variables meteorológicas y las variables acumulativas, conformando un total de 14 variables y 148 observaciones (148x14). La variable de salida corresponde únicamente a los datos de trips y tiene un tamaño de (148x1).

5.4.3. Análisis de datos

Primero se hizo un análisis de correlación entre todas las variables de entrada, respecto de la variable de salida (Tabla 2). En base a ello se encontró que dentro de las variables meteorológicas, la temperatura promedio diaria, GDD, temperatura máxima y temperatura mínima, son las variables que más correlación tenían con los valores de trips en comparación con las otras variables restantes.

Posteriormente se normalizaron todos los datos de trabajo para observar si se lograba destacar una mayor correlación de algunas variables. El ensayo arrojó los mismos valores de correlación y con la misma magnitud para las 4 variables mencionadas anteriormente.

Tabla 2.

Correlación entre datos de entrada y salida

VARIABLES DE ENTRADA	CORRELACIÓN CON TRIPS
Temperatura promedio diaria	0.188565
GDD	0.189595
Energía solar	0.083318
Precipitación	0.043758
Tasa de lluvia	-0.016941
Humedad relativa	-0.042555
Temperatura máxima	0.206325
Temperatura mínima	0.191236
Humedad relativa máxima	-0.123801
Humedad relativa mínima	-0.033811
Velocidad del viento	-0.163032
F1	0.217702
F2	-0.01283
TL	0.105858

Nota. Elaboración propia

5.4.4. Red neuronal para predecir valores de trips futuros en el tiempo

En base al análisis de correlación, como primer paso, se decidió usar las cuatro variables meteorológicas con mayor correlación y observar cómo se desenvuelven las predicciones del modelo. Se usó un modelo de red neuronal de perceptrón multicapa (MLP) con 80% de los datos totales para el entrenamiento y 20% para validación. Finalmente, y luego de realizar diferentes pruebas cambiando los hiperparámetros de la red se obtuvieron pobres resultados en las predicciones, tal y como se observa en la tabla 3.

El bajo rendimiento del modelo (2.34% de precisión) se puede explicar por la poca correlación entre las entradas y la salida. Por eso, se decidió agrupar las muestras de trips para sesgar las predicciones a un conjunto mucho más pequeño de datos. Además para los agricultores no es tan necesario saber el número exacto de trips, sino el grado de población que podría existir en su parcela.

Tabla 3.
Resultados del primer modelo de red neuronal

Valor real de trips	Predicción
4.04	1.186
5.12	-1.728
6.84	2.136
17.32	3.134
19.84	2.929
15.52	-0.358
0.8	2.948
0.32	29.513
10.2	0.1199

Nota. Elaboración propia

Finalmente, se agruparon las observaciones totales en tres grupos (grados de población), como se muestra a continuación.

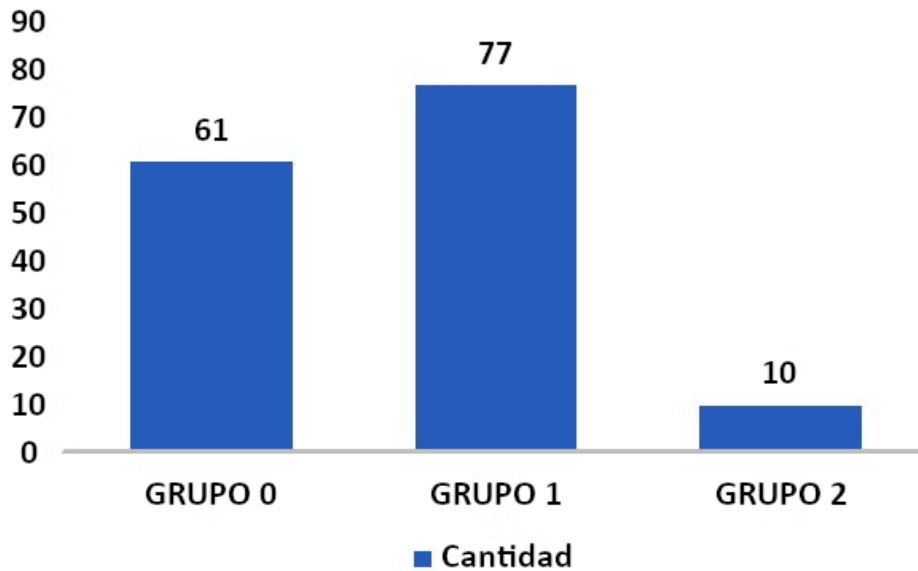
- Grupo 0: Valores de trips entre 0 y 1
- Grupo 1: Valores de trips entre 1 y 10
- Grupo 2: Valores de trips mayores a 10

La cantidad de cada grupo es la siguiente (figura 58):

Con este nuevo formato en los datos de salida, se modificó el modelo MLP logrando mejorar la métrica del rendimiento de las predicciones, alcanzando el 53%. Sin embargo, no es un valor que pueda considerarse como óptimo, además puede apreciarse que las predicciones tienden a inclinarse por el grupo 1 que es el grupo que tiene más muestras. También hay presencia de un sobreajuste hacia el grupo con mayor cantidad de datos (tabla 4).

Usando esa misma clasificación por grupos, se decidió añadir todas las demás variables de entrada para introducir nuevas características en el modelo y lograr una mejora en el entrenamiento. Los resultados de la nueva modificación en los datos se aprecian en la tabla 5. Puede notarse la inclinación del modelo por el grupo 1, el rendimiento alcanza el 57%. Pero aún no se destacan los otros grupos. Esto puede deberse al desequilibrio de datos en los grupos, además de la poca correlación que existe entre las variables.

Figura 58.
Cantidad de datos por grupo



Nota. Elaboración propia

Tabla 4.
Resultados luego de clasificar los datos en tres grupos

Clase real de trips	Predicción
1	1
0	1
1	1
1	1
0	1
1	1
2	1
1	1
0	1

Nota. Elaboración propia

5.4.5. Análisis de Componentes Principales PCA

Se comprobó que la poca correlación de los datos impide que la red pueda aprender las características. Por eso, se propuso usar la técnica de análisis de componentes principales (PCA) para estudiar mejor el conjunto de datos y reducir la dimensionalidad de las entradas a un nuevo conjunto de variables (componentes) con una mejor correlación.

Tabla 5.

Prueba realizada usando todas las variables meteorológicas y acumulativas

Clase real de trips	Predicción
1	1
1	1
0	1
0	1
1	1
2	1
1	1
0	1
1	1

Nota. Elaboración propia

Las nuevas componentes se ordenan de tal manera que las primeras representen la mayor parte de la varianza presente en todas las variables originales. PCA es una técnica antigua para el análisis multivariante, dentro de sus aplicaciones están la compresión de datos, reducción de ruido, extracción de características y análisis de datos (Peper, Noda, & Shirazi, 2002).


El análisis de componentes principales fue realizado en R Studio, la figura 59 muestra el comportamiento de las variables con respecto a los individuos. Se puede destacar que en el primer cuadrante hay valores con mayor energía solar y evapotranspiración. En el segundo cuadrante están los valores con mayor velocidad de viento y humedad relativa máxima, en el tercer cuadrante están los mayores valores de precipitación y tasa de lluvia y en el último cuadrante están los valores con mayor temperatura máxima, mayor temperatura mínima, mayor valor de la variable F1 que representa los días que han pasado desde la última fumigación, y mayor valor de la variable TL que representa los días que han pasado desde la última limpieza.

Al agregar la variable de salida (trips) al análisis de componentes, ésta se ubica en el cuarto cuadrante, por lo que se puede concluir de manera general, que a mayores valores de este cuadrante habrá mayor población de trips.

Se obtuvieron 14 componentes, el mismo tamaño de las variables de entrada. Para

Figura 59.

Comportamiento de las variables con respecto a los individuos



Nota. Elaboración propia

el entrenamiento se decidió usar las primeras 6 componentes, ya que hasta esa cantidad se explica la mayor varianza de los datos totales.

Los resultados obtenidos de entrenar el modelo MLP con las componentes de PCA lograron aumentar el rendimiento y con ello los resultados obtenidos (tabla 6). Sin embargo, las predicciones aún se clasificaban de mejor manera al grupo 1, esto debido al desbalance en los datos.

Tabla 6.

Resultados usando PCA para el entrenamiento

Clase real de trip	Predicción
1	2
1	1
0	1
0	0
1	1
2	2
1	0
0	0
1	1

Nota. Elaboración propia

5.4.6. Aumento de datos SMOTE

Existen algunos procedimientos para equilibrar los datos de entrenamiento. Por ejemplo, sub muestrear o también equilibrar todos los datos a la cantidad del menor grupo. Sin embargo, debido a la poca cantidad de datos ninguno de estos dos métodos era conveniente para este estudio.

El método que se usó aquí es el sobre muestreo. La técnica más usada es el SMOTE (Synthetic Minority Over-sampling Technique) (Chawla, Bowyer, Hall, & Kegelmeyer, 2002), el cual consiste en generar datos sintéticos a partir de datos ya conocidos. SMOTE logró aumentar la cantidad de observaciones en grupos faltantes, sobre todo el grupo 2. Usando esta técnica se pudieron obtener 77 observaciones para cada grupo, lo cual logró un total de 231 observaciones.

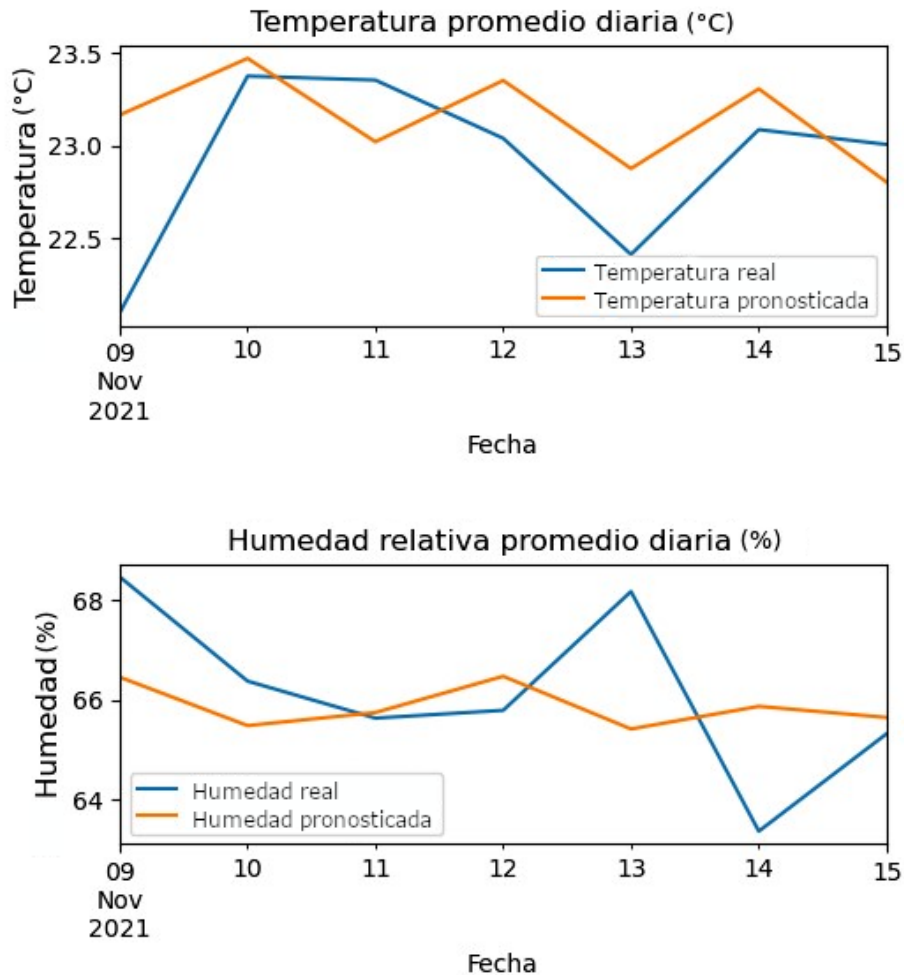
Cabe resaltar que el método SMOTE se aplicó solamente a las 148 observaciones obtenidas del análisis de PCA y conformaron las nuevas entradas para el entrenamiento de la red neuronal. No se generaron datos sintéticos antes del análisis de PCA pues se generarían nuevas características que no corresponden al dataset original.

5.4.7. Predicción de una serie temporal

Uno de los objetivos de esta investigación fue predecir en un tiempo futuro la gravedad del estado de trips. Con lo realizado hasta este punto el modelo MLP mediante el entrenamiento y reconocimiento de características podía clasificar e identificar el estado de trips. Sin embargo, los datos de entrada al modelo, los cuales fueron obtenidos de una estación meteorológica, correspondían a un tiempo actual o pasado. La estación meteorológica, no suministra datos futuros. Y precisamente se requieren datos meteorológicos de los siguientes 7 días, por ejemplo, para dar una estimación del estado de trips en la semana siguiente.

Por lo que se desarrolló un modelo de predicción de series temporales para predecir las variables meteorológicas de entrada. Este nuevo modelo realiza una regresión a cada variable meteorológica y pronostica 7 días posteriores usando datos de días ya conocidos. En la figura 60 se tienen el pronóstico durante 7 días para la temperatura promedio y humedad relativa (en color naranja), frente al valor real suministrado por la estación meteorológica (en color azul).

Figura 60.
Comparativa de resultados para las series temporales

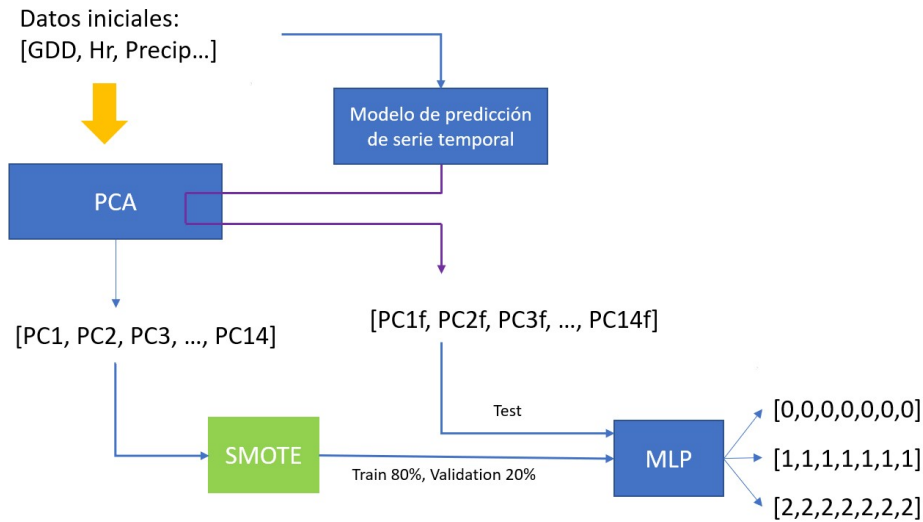


Nota. Elaboración propia

Una vez que se realiza la predicción para cada variable, los nuevos datos se ingresan al modelo de PCA que se usó para el dataset original, ya que deben usarse los mismos ejes de componentes calculados por el PCA. Se obtienen nuevas componentes, ahora ya de las predicciones temporales de cada variable y que a su vez se ingresaron en el modelo MLP para predecir la gravedad de los trips en la semana siguiente.

Finalmente, la figura 61 muestra un esquema de la metodología aplicada para predecir la gravedad de la plaga en un futuro cercano.

Figura 61.
Esquema de la metodología



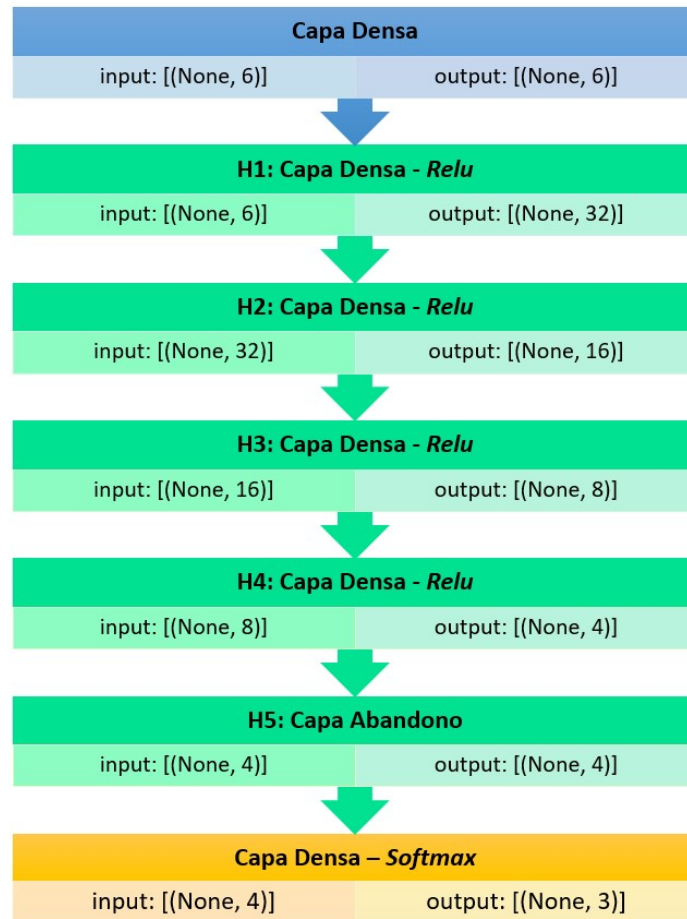
Nota. Elaboración propia

5.5. Resultados

El modelo desarrollado MLP, después de varias pruebas y ajustes en los hiperparámetros, consiguió mejorar el rendimiento durante el entrenamiento y posteriormente en los resultados, las predicciones. Se probaron además otros modelos de clasificación como Support Vector Machine (SVM), Random Forest y K-Nearest neighbor. Entre los modelos que se probaron, el que mejor destaca es el MLP para clasificación. Este además permite la configuración y ajuste de los hiperparámetros en las capas, a diferencia de random forest que ofrece limitados parámetros de ajuste. A continuación, se presenta el esquema del modelo final de la red neuronal MLP que se ha usado en este artículo (figura 62).

Durante la experimentación con los datos para seleccionar un mejor modelo que pueda pronosticar el crecimiento de la plaga. El modelo de clasificación Random Forest fue uno de los métodos que se perfiló a la par con nuestro modelo MLP. Desafortunadamente no lograba clasificar equitativamente a los tres grupos, en la mayoría de pruebas tiende a clasificar mejor siempre la clase del grupo 2 frente a los otros grupos, y es la clase a la cual se le aumentaron

Figura 62.
Arquitectura MLP




Nota. Elaboración propia

las observaciones con el método SMOTE. Esto Puede apreciarse en el gráfico de matriz de confusión (figura 63) .

Los métodos de support vector machine (SVM) y K-Nearest neighbor (KNN) nuevamente vuelven a repetir el comportamiento de Random Forest al clasificar mejor el grupo 2. También hay una disminución en el porcentaje de la métrica de exactitud al comparar los resultados reales frente a los predichos para cada uno de los modelos. Mientras que MLP y random Forest se mantienen arriba del 80%, estos dos últimos modelos se encuentran entre el 55% y 73%. Así mismo, en la gráfica (figura 64) pueden verse los resultados para cada uno de los modelos descritos.

Figura 63.
Matriz de confusión del modelo Random Forest




Nota. Elaboración propia

Se ha usado la métrica F1-Score como la métrica de exactitud para evaluar las predicciones del modelo para cada grupo.

La arquitectura del modelo MLP consiste en capas organizadas secuencialmente, la cantidad de capas ocultas conforman un total de 5 capas, en su mayoría capas densas, a excepción de la última capa que es una capa de abandono (dropout). La capa dropout ha permitido regularizar el modelo para evitar un posible sobreajuste (overfitting), ya que durante el entrenamiento desactiva aleatoriamente neuronas de la red que pretenden ser sesgadas por cada grupo.

El overfitting se hace notorio en la curva de la función de costo (función de pérdida) durante el entrenamiento, precisamente en la curva de los datos de validación, en color naranja (figuras 65 y 66). Cuando no hay presencia de una capa dropout en el modelo presentado, la función de pérdida en la validación nunca desciende 65, ello implica un overfitting y como tal el

Figura 64.
F1-score para diferentes modelos



Nota. Elaboración propia


modelo no se generaliza a nuevos datos. En la figura 66 puede apreciarse cómo se ha logrado disminuir el sobreajuste tras añadir la capa dropout en el modelo.

Finalmente tras el ajuste de los hiperparámetros, funciones de activación, número de capas y organización de las mismas, se muestra la matriz de confusión (figura 67) construida a partir de comparar los datos reales y predichos por el modelo MLP. Se logró un f1 score de 82,3% como métrica de rendimiento del modelo.

De la matriz de confusión, se puede rescatar el gráfico de barras (figura 68) exponiendo los valores de verdaderos positivos y falsos positivos que el modelo, predijo cuando se le añadieron nuevos datos. Nuevamente hay un equilibrio en los resultados.

Este modelo de red neuronal artificial multicapa se propone como una solución para pronosticar la evolución de la plaga respecto a los factores meteorológicos del ambiente. La ventaja de este modelo frente a otros presentados en la introducción de este trabajo, es que además de clasificar la población de trips, hace un pronóstico de la población para los siguientes 7 días con un rendimiento mayor al 80%. Este rendimiento se ha conseguido con un conjunto de datos de tamaño mediano.

Figura 65.
Curva de la función de costo del modelo sin capa Dropout




Nota. Elaboración propia

Las métricas obtenidas son comparables con otros modelos presentados en la literatura que basan su entrenamiento en una gran cantidad de imágenes para clasificar algún tipo de plaga pero que no tienen el componente de estimación a futuro.

Es bien sabido que cualquier modelo de machine learning necesita una ingente cantidad de datos. Los datos constituyen un punto clave en la solución de un problema. En este trabajo se pudo registrar en una base de datos la población de plagas de una determinada parcela de banano. La recolección de datos inicialmente supuso un gran desafío para iniciar con la realización de un modelo. Afortunadamente se logró implementar un sistema de adquisición de datos para el registro de plagas que posteriormente se asoció a las condiciones climáticas para poder predecir el grado de población de trips. Este trabajo supone además una nueva estrategia en la detección temprana de plagas y lograr una actuación más eficaz frente a ellas.

Figura 66.


Curva de la función de costo del modelo añadiendo la capa Dropout



Nota. Elaboración propia


También puede ayudar a los productores bananeros a definir un plan de fumigación y a organizar la compra de pesticidas (los más efectivos suelen ser de alto costo). En la mayoría de los casos en la agricultura de menor escala, no se tienen planes de fumigación preventivos y sólo se empiezan la fumigación cuando la planta ya se encuentra atacada por la plaga. Ello puede generar cuantiosas pérdidas en la producción tanto por la calidad del banano y por las plantas muertas a las cuales no les llegó la cura a tiempo. Otro punto importante es la contaminación ambiental que generan los pesticidas de mejor rendimiento. Si se conociera en que fechas es necesario aplicar los pesticidas se podría ahorrar costos y cuidar el medio ambiente.

Figura 67.
Matriz de confusión del modelo MLP



Nota. Elaboración propia

Figura 68.
Diagrama de barras por grupos



Nota. Elaboración propia

Conclusiones

Según los datos presentados, podemos concluir que el Internet de las Cosas (IoT) es ampliamente aplicable a las actividades de los campos agrícolas, como los cultivos de banano orgánico ubicados en la costa norte del Perú, permitiendo su monitoreo y control continuo, haciendo un uso más eficiente de los recursos.

En ese sentido, de acuerdo a la literatura revisada, se puede afirmar que las aplicaciones del IoT que más se adaptan a las necesidades del cultivo de banano orgánico son el almacenamiento en la nube, redes de sensores inalámbricos, sistemas de geoposicionamiento, Big Data, Machine Learning, vehículos aéreos no tripulados, robots, entre otros.

Del mismo modo, se puede asegurar que las ventajas del uso del IoT en la cadena productiva del banano orgánico son amplias; entre ellas destaca el potencial para el incremento de la eficiencia y productividad agrícola, los datos de ayuda en la planificación y toma de decisiones, la evaluación del estado del suelo, la temperatura, humedad, el estado del cultivo y otras variables, que darían lugar a lo que se conoce como agricultura inteligente.


Los estudios también demuestran que el IoT aplicado a la agricultura o la agricultura inteligente facilita el análisis y contención de plagas y enfermedades de los cultivos, activando alertas para combatirlas a tiempo, evitando su propagación en el campo y las pérdidas de los cultivos.

Sin embargo, pese a su éxito comprobado en países de América del Norte, Europa y Asia, en América Latina y especialmente, en el Perú, la aplicación del IoT es escasa y casi nula en la pequeña y mediana agricultura, debido a las brechas de acceso a internet, la falta de datos

científicos específicos sobre los cultivos y el mercado de productos tecnológicos de alto costo.

Para participar en los inicios de la transformación de la agricultura tradicional a una agricultura inteligente del banano orgánico en la costa norte del Perú, se requiere construir un sistema de recolección y transmisión de datos climáticos de las plantaciones que es complementado con modelos matemáticos y algoritmos de Inteligencia Artificial, tal como el que se presenta en este trabajo.

Esta plataforma, que ha sido planeada tomando en cuenta los principales obstáculos energéticos y de comunicación que existen en las zonas rurales de la región de Piura, podrá servir de punto de partida para continuar con el desarrollo de nuevas y accesibles tecnologías del IoT que permitan mejorar la gestión y supervisión del banano y otros cultivos y revalorar la pequeña agricultura familiar y los lleven a gozar de las ventajas de la agricultura inteligente, una actividad económica que, de una u otra forma, nos beneficia a todos.



Referencias bibliográficas

- Abioye, E. A., Abidin, M. S. Z., Mahmud, M. S. A., Buyamin, S., Ishak, M. H. I., Rahman, M. K. I. A., ... Ramli, M. S. A. (2020). A review on monitoring and advanced control strategies for precision irrigation. *Computers and Electronics in Agriculture*, 173, 105441. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169919314826> doi: <https://doi.org/10.1016/j.compag.2020.105441>
- Agric, I., Eng, B., Chen, Y., Yuling, S., Zhongyi, W., Huang, L., ... Wang, Y. (2016, 01). Connectivity of wireless sensor networks for plant growth in greenhouse citation. *Int J Agric and Biol Eng*, 9. doi: 10.3965/j.ijabe.201606901.1314
- Akkas, M., & Sokullu, R. (2017, 12). An iot-based greenhouse monitoring system with micaz motes. *Procedia Computer Science*, 113, 603-608. doi: 10.1016/j.procs.2017.08.300
- Akyildiz, I., Su, W., Sankarasubramaniam, Y., & Cayirci, E. (2002, 09). A survey on sensor networks. *Communications Magazine, IEEE*, 40, 102 - 114. doi: 10.1109/MCOM.2002.1024422
- Alcácer, V., & Cruz-Machado, V. (2019). Scanning the industry 4.0: A literature review on technologies for manufacturing systems. *Engineering Science and Technology, an International Journal*, 22(3), 899-919. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2215098618317750> doi: <https://doi.org/10.1016/j.jestch.2019.01.006>

- Alli, A. A., & Alam, M. M. (2020). The fog cloud of things: A survey on concepts, architecture, standards, tools, and applications. *Internet of Things*, 9, 100177. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2542660520300172> doi: <https://doi.org/10.1016/j.iot.2020.100177>
- Alreshidi, E. (2019). Smart Sustainable Agriculture (SSA) solution underpinned by Internet of Things (IoT) and Artificial Intelligence (AI). *International Journal of Advanced Computer Science and Applications*, 10(5), 93–102. doi: 10.14569/ijacsa.2019.0100513
- Amatya, S., Karkee, M., Gongal, A., Zhang, Q., & Whiting, M. (2015, 11). Detection of cherry tree branches with full foliage in planar architecture for automated sweet-cherry harvesting. *Biosystems Engineering*, 146. doi: 10.1016/j.biosystemseng.2015.10.003
- Ascorti, L., Savazzi, S., Soatti, G., Nicoli, M., Sisinni, E., & Galimberti, S. (2017). A wireless cloud network platform for industrial process automation: Critical data publishing and distributed sensing. *IEEE Transactions on Instrumentation and Measurement*, 66(4), 592–603. doi: 10.1109/TIM.2016.2640579
- Aslanpour, M. S., Gill, S. S., & Toosi, A. N. (2020). Performance evaluation metrics for cloud, fog and edge computing: A review, taxonomy, benchmarks and standards for future research. *Internet of Things*, 12, 100273. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2542660520301062> doi: <https://doi.org/10.1016/j.iot.2020.100273>
- Avonts, J., & Blondia, C. (2016, 02). A framework to compare topology algorithms in multi-channel multi-radio wireless mesh networks. *Computer Networks*, 98. doi: 10.1016/j.comnet.2016.02.002
- Azaza, M., Tanougast, C., Fabrizio, E., & Mami, A. (2015, 12). Smart greenhouse fuzzy logic based control system enhanced with wireless data monitoring. *ISA Transactions*, 61. doi: 10.1016/j.isatra.2015.12.006
- Bai, Y.-N., Huang, N., Sun, L., & Wang, L. (2019, 05). Reliability-based topology design for large-scale networks. *ISA Transactions*, 94. doi: 10.1016/j.isatra.2019.04.004
- Banco Mundial, CIAT, & CATIE. (2014). Agricultura Climáticamente Inteligente en el Perú. *Serie*

- de Perfiles Nacionales de Agricultura Climáticamente Inteligente para América Latina*, 1-12.
- Bao, L., Jiang, C., Miao, W., Guo, B., Li, W., Cheng, X., ... Zou, J. (2018, 01). Coverage analysis on nb-iot and lora in power wireless private network. *Procedia Computer Science*, 131, 1032-1038. doi: 10.1016/j.procs.2018.04.252
- Barakabitze, A., Fue, K., Kitindi, E., & Sanga, C. (2016, 08). Developing a framework for next generation integrated agro food-advisory systems in developing countries. *International Journal of Information Communication Technologies and Human Development (IJICTHD)*, 8, 13-31. doi: 10.4018/IJICTHD.2016100102
- Barbedo, J. G. A. (2019). Detection of nutrition deficiencies in plants using proximal images and machine learning: A review. *Computers and Electronics in Agriculture*, 162, 482-492. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169918318957> doi: <https://doi.org/10.1016/j.compag.2019.04.035>
- Belupú, I., Estrada, C., Oquélis, J., & Ipanaqué, W. (2021). Smart agriculture based on wsn and node.js for monitoring plantations in rural areas: Case region piura, peru. In *2021 ieee chilean conference on electrical, electronics engineering, information and communication technologies (chilecon)* (p. 1-6). doi: 10.1109/CHILECON54041.2021.9702965
- Biswas, S., Sinha, N., Purkayastha, B., & Marbaniang, L. (2014, 01). Weather prediction by recurrent neural network dynamics. *International Journal of Intelligent Engineering Informatics*, 2, 166. doi: 10.1504/IJIEI.2014.066208
- Brun-Laguna, K., Diedrichs, A. L., Dujovne, D., Taffernaberry, C., Léone, R., Vilajosana, X., & Watteyne, T. (2018). Using smartmesh ip in smart agriculture and smart building applications. *Computer Communications*, 121, 83-90. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0140366417305212> doi: <https://doi.org/10.1016/j.comcom.2018.03.010>
- Cabas, J., Weersink, A., & Olale, E. (2010). Crop yield response to economic, site and climatic variables. *Climatic Change*, 101(3), 599-616. doi: 10.1007/s10584-009-9754-4
- Caicedo-Ortiz, J. G., la Hoz-Franco, E. D., Morales Ortega, R., Piñeres-Espitia, G., Combita-Niño,

- H., Estévez, F., & Cama-Pinto, A. (2018). Monitoring system for agronomic variables based in wsn technology on cassava crops. *Computers and Electronics in Agriculture*, 145, 275-281. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169917310189> doi: <https://doi.org/10.1016/j.compag.2018.01.004>
- Caiza, G., Saeteros, M., Oñate, W., & Garcia, M. (2020, 04). Fog computing at industrial level, architecture, latency, energy, and security: A review. *Heliyon*, 6, e03706. doi: [10.1016/j.heliyon.2020.e03706](https://doi.org/10.1016/j.heliyon.2020.e03706)
- Calberto, G., Blake, D., Staver, C., Carvajal, M., & Brown, D. (2018). The frequency and effects of weather events on banana productivity – results of a global survey. *Acta Horticulturae*, 1196, 179–186. doi: [10.17660/ActaHortic.2018.1196.22](https://doi.org/10.17660/ActaHortic.2018.1196.22)
- Celesti, A., Lay-Ekuakille, A., Wan, J., Fazio, M., Celesti, F., Romano, A., ... Villari, M. (2020). Information management in iot cloud-based tele-rehabilitation as a service for smart cities: Comparison of nosql approaches. *Measurement*, 151, 107218. Retrieved from <https://www.sciencedirect.com/science/article/pii/S026322411931084X> doi: <https://doi.org/10.1016/j.measurement.2019.107218>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002, jun). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. Retrieved from <https://doi.org/10.1613/jair.953> doi: [10.1613/jair.953](https://doi.org/10.1613/jair.953)
- Chillet, M., Hubert, O., & De Lapeyre, L. (2010). Postharvest disease: Effects of the physiological age of bananas (*Musa spp.*) on their susceptibility to wound anthracnose due to *colletotrichum musae*. *Acta Horticulturae*, 879, 419–424. doi: [10.17660/ActaHortic.2010.879.46](https://doi.org/10.17660/ActaHortic.2010.879.46)
- Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and Electronics in Agriculture*, 151, 61-69. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169917314710> doi: <https://doi.org/10.1016/j.compag.2018.05.012>

- Chowdhury, A., & Raut, S. A. (2018). A survey study on internet of things resource management. *Journal of Network and Computer Applications*, 120, 42-60. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1084804518302315> doi: <https://doi.org/10.1016/j.jnca.2018.07.007>
- Couto, R., Sadok, H., Cruz, P., Silva, F., Sciammarella, T., Campista, M., ... Rubinstein, M. (2018, 09). Building an iaas cloud with droplets: a collaborative experience with openstack. *Journal of Network and Computer Applications*, 117, 59-71. doi: 10.1016/j.jnca.2018.05.016
- Dan, L., Xin, C., Chongwei, H., & Liangliang, J. (2015, 12). Intelligent agriculture greenhouse environment monitoring system based on iot technology. In (p. 487-490). doi: 10.1109/ICITBS.2015.126
- De Souza, A. V., Bonini Neto, A., Cabrera Piazentin, J., Dainese Junior, B. J., Perin Gomes, E., dos Santos Batista Bonini, C., & Ferrari Putti, F. (2019). Artificial neural network modelling in the prediction of bananas' harvest. *Scientia Horticulturae*, 257, 108724. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0304423819306107> doi: <https://doi.org/10.1016/j.scienta.2019.108724>
- Didioui, A. (2014, 10). Energy-aware transceiver for energy harvesting wireless sensor networks.
- Divakar, K. M., & Sushma, K. R. (2018). Iot Technology in Smart Farming. *International Research Journal of ...*, 2043-2045. Retrieved from <https://www.academia.edu/download/58256068/IRJET-V5I5387.pdf>
- Dos Santos, U. J. L., Pessin, G., Da Costa, C. A., & Da Rosa Righi, R. (2019). Agriprediction: A proactive internet of things model to anticipate problems and improve production in agricultural crops. *Computers and Electronics in Agriculture*, 161, 202-213. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169917313856> (BigData and DSS in Agriculture) doi: <https://doi.org/10.1016/j.compag.2018.10.010>
- Ebrahimi, M. (2017, 03). Vision-based pest detection based on svm classification method.

Computers and Electronics in Agriculture.

- FAO. (2017). Organic banana production in Peru. *FAO, World Banana Forum*. Retrieved from <http://www.fao.org/world-banana-forum/projects/good-practices/organic-production-peru/en/>
- Ferentinos, K., & Tsiligiridis, T. (2007, 03). Adaptive design optimization of wireless sensor networks using genetic algorithms. *Computer Networks*, 51, 1031-1051. doi: 10.1016/j.comnet.2006.06.013
- Foughali, K., Fathallah, K., & Frihida, A. (2018). Using cloud iot for disease prevention in precision agriculture. *Procedia Computer Science*, 130, 575-582. Retrieved from <https://www.sciencedirect.com/science/article/pii/S187705091830468X> (The 9th International Conference on Ambient Systems, Networks and Technologies (ANT 2018) / The 8th International Conference on Sustainable Energy Information Technology (SEIT-2018) / Affiliated Workshops) doi: <https://doi.org/10.1016/j.procs.2018.04.106>
- Futagawa, M., Takao, H., Ishida, M., Sawada, K., & Iwasaki, T. (2009, 11). Fabrication of a multi-modal sensor with ph, ec and temperature sensing areas for agriculture application. In (p. 2013 - 2016). doi: 10.1109/ICSENS.2009.5398294
- Ganry, J., & Chillet, M. (2008). Methodology to forecast the harvest date of banana bunches. *Fruits*, 63(6), 371-373. doi: 10.1051/fruits:2008036
- Garrett, K., Dobson, A., Kroschel, J., Natarajan, B., Orlandini, S., Tonnang, H., & Valdivia, C. (2013). The effects of climate variability and the color of weather time series on agricultural diseases and pests, and on decisions for their management. *Agricultural and Forest Meteorology*, 170, 216-227. Retrieved from <https://www.sciencedirect.com/science/article/pii/S016819231200158X> (Agricultural prediction using climate model ensembles) doi: <https://doi.org/10.1016/j.agrformet.2012.04.018>
- Gehring, N., Dorneanu, B., Silupú, J. J. M., Alama, W. I., & Arellano-Garcia, H. (2020). Circular economy in banana cultivation. In S. Pierucci, F. Manenti, G. L. Bozzano, & D. Manca (Eds.), *30th european symposium on computer aided process engineering* (Vol. 48, p. 1567-1572). Elsevier. Retrieved from <https://www.sciencedirect.com/science/>

article/pii/B9780128233771502627 doi: <https://doi.org/10.1016/B978-0-12-823377-1.50262-7>

- Gill, S. S., Garraghan, P., & Buyya, R. (2019). Router: Fog enabled cloud based intelligent resource management approach for smart home iot devices. *Journal of Systems and Software*, 154, 125-138. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0164121219300986> doi: <https://doi.org/10.1016/j.jss.2019.04.058>
- Goulding, K. (2016, 06). Soil acidification and the importance of liming agricultural soils with particular reference to the united kingdom. *Soil Use and Management*, 32. doi: 10.1111/sum.12270
- Grinberg, M. (2014). *Flask Web Development: Developing Web Applications with Python*.
- Grinblat, G., Uzal, L., Larese, M., & Granitto, P. (2016, 09). Deep learning for plant identification using vein morphological patterns. *Computers and Electronics in Agriculture*, 127, 418-424. doi: 10.1016/j.compag.2016.07.003
- Gu, J., Yin, G., Huang, P., Guo, J., & Chen, L. (2017). An improved back propagation neural network prediction model for subsurface drip irrigation system. *Computers and Electrical Engineering*, 60, 58-65. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0045790617303142> doi: <https://doi.org/10.1016/j.compeleceng.2017.02.016>
- Guo, J., Liu, X., Zhang, Y., Shen, J., Han, X.-W., Zhang, W., ... Zhang, F. (2010, 02). Significant acidification in major chinese croplands. *Science (New York, N.Y.)*, 327, 1008-10. doi: 10.1126/science.1182570
- Habib, M., Yaqoob, I., Salah, K., Imran, M., Jayaraman, P. P., & Perera, C. (2019). The role of big data analytics in industrial internet of things. *Future Generation Computer Systems*, 99, 247-259. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0167739X18313645> doi: <https://doi.org/10.1016/j.future.2019.04.020>
- Hammond Wagner, C., Cox, M., & Bazo Robles, J. L. (2016). Pesticide lock-in in small scale peruvian agriculture. *Ecological Economics*, 129, 72-81. Re-

- trieved from <https://www.sciencedirect.com/science/article/pii/S0921800915305577> doi: <https://doi.org/10.1016/j.ecolecon.2016.05.013>
- Henzinger, T. A., & Sifakis, J. (2007). The discipline of embedded systems design. *Computer*, 40(10), 32-40. doi: 10.1109/MC.2007.364
- Hernández-Rojas, D. (2018). Sistema de Telemetría basado en redes WSN (Wireless Sensor Network) para el Internet de las Cosas (IoT). , 1.
- Holland, J., Bennett, A., Newton, A., White, P., McKenzie, B., George, T., ... Hayes, R. (2018). Liming impacts on soils, crops and biodiversity in the uk: A review. *Science of The Total Environment*, 610-611, 316-332. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0048969717320181> doi: <https://doi.org/10.1016/j.scitotenv.2017.08.020>
- Hong, G.-Z., & Hsieh, C.-L. (2016, 12). Application of integrated control strategy and bluetooth for irrigating romaine lettuce in greenhouse. *IFAC-PapersOnLine*, 49, 381-386. doi: 10.1016/j.ifacol.2016.10.070
- Hwang, L.-C., Chen, C.-S., Ku, T.-T., & Shyu, W.-C. (2019). A bridge between the smart grid and the internet of things: Theoretical and practical roles of lora. *International Journal of Electrical Power and Energy Systems*, 113, 971-981. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0142061518330059> doi: <https://doi.org/10.1016/j.ijepes.2019.06.001>
- Höllner, J., Tsiatsis, V., Karnouskos, S., & Mulligan, C. (2018). *Internet of things: Technologies and applications for a new age of intelligence, 2nd edition*. doi: 10.1016/C2017-0-00369-5
- Ipanaqué, W., Belupú, I., Castillo, J., & Salazar, J. (2017, 10). Internet of things applied to monitoring fermentation process of cocoa at the piura's mountain range. In (p. 1-5). doi: 10.1109/CHILECON.2017.8229532
- Jarraud, M., & Steiner, A. (2014). *Summary for policymakers* (Vol. 9781107025066). doi: 10.1017/CBO9781139177245.003
- Jeger, M., Waller, J., Johanson, A., & Gowen, S. (1996). Monitoring in banana pest management. *Crop Protection*, 15(4), 391-397. Retrieved from <https://www.sciencedirect.com/science/article/pii/0261219496000117> doi: <https://doi.org/10.1016/j.cropro.1996.04.001>

.1016/0261-2194(96)00011-7

- Jha, K., Doshi, A., Patel, P., & Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2, 1-12. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2589721719300182> doi: <https://doi.org/10.1016/j.aiaa.2019.05.004>
- Jia, X., Feng, Q., Fan, T., & Lei, Q. (2012, 04). Rfid technology and its applications in internet of things (iot). *2012 2nd International Conference on Consumer Electronics, Communications and Networks, CECNet 2012 - Proceedings*. doi: 10.1109/CECNet.2012.6201508
- Kalkura, P., B, P. R., N, S. K., Surya, & Ramyashree, M. (2021). Pest control management system using organic pesticides. *Global Transitions Proceedings*, 2(2), 175-180. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2666285X21000868> (International Conference on Computing System and its Applications (ICCSA- 2021)) doi: <https://doi.org/10.1016/j.gltp.2021.08.058>
- Kamble, S. S., Gunasekaran, A., & Gawankar, S. A. (2020). Achieving sustainable performance in a data-driven agriculture supply chain: A review for research and applications. *International Journal of Production Economics*, 219, 179-194. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0925527319302038> doi: <https://doi.org/10.1016/j.ijpe.2019.05.022>
- Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2017). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, 143, 23-37. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169917301230> doi: <https://doi.org/10.1016/j.compag.2017.09.037>
- Karar, M. E., Alsunaydi, F., Albusaymi, S., & Alotaibi, S. (2021). A new mobile application of agricultural pests recognition using deep learning in cloud computing system. *Alexandria Engineering Journal*, 60(5), 4423-4432. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1110016821001642> doi: <https://doi.org/10.1016/j.aej.2021.03.009>

- Karim, F., Karim, F., & frihida, A. (2017). Monitoring system using web of things in precision agriculture. *Procedia Computer Science*, 110, 402-409. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050917312590> (14th International Conference on Mobile Systems and Pervasive Computing (MobiSPC 2017) / 12th International Conference on Future Networks and Communications (FNC 2017) / Affiliated Workshops) doi: <https://doi.org/10.1016/j.procs.2017.06.083>
- Karthik., R., M., H., Anand, S., Mathikshara, P., Johnson, A., & R., M. (2020). Attention embedded residual cnn for disease detection in tomato leaves. *Applied Soft Computing*, 86, 105933. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1568494619307148> doi: <https://doi.org/10.1016/j.asoc.2019.105933>
- Kassim, M. R. M., Harun, A. N., Yusoff, I. M., Mat, I., Kuen, C. P., & Rahmad, N. (2017). Applications of wireless sensor networks in shiitake mushroom cultivation. In *2017 eleventh international conference on sensing technology (icst)* (p. 1-6). doi: 10.1109/ICSensT.2017.8304516
- Kellengere Shankarnarayan, V., & Ramakrishna, H. (2020). Paradigm change in indian agricultural practices using big data: Challenges and opportunities from field to plate. *Information Processing in Agriculture*, 7(3), 355-368. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2214317319302264> doi: <https://doi.org/10.1016/j.inpa.2020.01.001>
- Khan, Z., & Abbasi, U. (2016, 04). Evolution of wireless sensor networks toward internet of things. In (p. 179-200). doi: 10.1201/b20085-11
- Khanna, A., & Kaur, S. (2019). Evolution of internet of things (iot) and its significant impact in the field of precision agriculture. *Computers and Electronics in Agriculture*, 157, 218-231. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169918316417> doi: <https://doi.org/10.1016/j.compag.2018.12.039>
- Kiran, S., Sandeep Kanumalli, S., Venkata Sesha Sai Rama Krishna, K., & Chandra,

- N. (2021). Internet of things integrated smart agriculture for weather predictions and preventive mechanism. *Materials Today: Proceedings*. Retrieved from <https://www.sciencedirect.com/science/article/pii/S221478532038682X> doi: <https://doi.org/10.1016/j.matpr.2020.11.081>
- Kochhar, A., & Kumar, N. (2019, 07). Wireless sensor networks for greenhouses: An end-to-end review. *Computers and Electronics in Agriculture*, 163. doi: 10.1016/j.compag.2019.104877
- Koley, D. S. (2014, 02). Machine learning for soil fertility and plant nutrient management using back propagation neural networks. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2, 292-297.
- Ku, M.-L., Li, W., Chen, Y., & Ray Liu, K. J. (2016). Advances in energy harvesting communications: Past, present, and future challenges. *IEEE Communications Surveys and Tutorials*, 18(2), 1384-1412. doi: 10.1109/COMST.2015.2497324
- Kumar, P., & Ashok, G. (2021). Design and fabrication of smart seed sowing robot. *Materials Today: Proceedings*, 39, 354-358. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2214785320355425> (International Conference on Advanced Materials and Modern Manufacturing) doi: <https://doi.org/10.1016/j.matpr.2020.07.432>
- Kurkovsky, S. (2008, 01). Pervasive computing: Past, present and future. In (p. 65 - 71). doi: 10.1109/ITICT.2007.4475619
- Li, W., & Kara, S. (2017, 12). Methodology for monitoring manufacturing environment by using wireless sensor networks (wsn) and the internet of things (iot). *Procedia CIRP*, 61, 323-328. doi: 10.1016/j.procir.2016.11.182
- Li, W., Zheng, T., Yang, Z., Li, M., Sun, C., & Yang, X. (2021). Classification and detection of insects from field images using deep learning for smart pest management: A systematic review. *Ecological Informatics*, 66, 101460. Retrieved from <https://www.sciencedirect.com/science/article/pii/S157495412100251X> doi: <https://doi.org/10.1016/j.ecoinf.2021.101460>
- Liao, M.-S., Chen, S.-F., Chou, C.-Y., Chen, H.-Y., Yeh, S.-H., Chang, Y.-C., & Jiang, J.-A. (2017, 04).

- On precisely relating the growth of phalaenopsis leaves to greenhouse environmental factors by using an iot-based monitoring system. *Computers and Electronics in Agriculture*, 136, 125-139. doi: 10.1016/j.compag.2017.03.003
- Liberg, O., Sundberg, M., Wang, Y.-P. E., Bergman, J., Sachs, J., & Wikström, G. (2020). Chapter 17 - technical enablers for the iot. In O. Liberg, M. Sundberg, Y.-P. E. Wang, J. Bergman, J. Sachs, & G. Wikström (Eds.), *Cellular internet of things (second edition)* (Second Edition ed., p. 709-730). Academic Press. Retrieved from <https://www.sciencedirect.com/science/article/pii/B9780081029022000170> doi: <https://doi.org/10.1016/B978-0-08-102902-2.00017-0>
- Lixuan, W., Hong, S., Minzan, L., Meng, Z., & Yi, Z. (2015, 12). An on-line monitoring system of crop growth in greenhouse. In (p. 627-637). doi: 10.1007/978-3-319-19620-6_70
- Low, C., Chen, Y., & Wu, M. (2011, 08). Understanding the determinants of cloud computing adoption. *Industrial Management and Data Systems*, 111. doi: 10.1108/02635571111161262
- López Martínez, J., Blanco, J. L., Pérez Alonso, J., & Callejón Ferre, J. (2018, 02). Distributed network for measuring climatic parameters in heterogeneous environments: Application in a greenhouse. *Computers and Electronics in Agriculture*, 145, 105-121. doi: 10.1016/j.compag.2017.12.028
- López Riquelme, J. A., Soto, F., Suardiáz Muro, J., Sanchez, P., Iborra, A., & Vera, J. (2009, 08). Wireless sensor networks for precision horticulture in southern spain. *Computers and Electronics in Agriculture*, 68, 25-35. doi: 10.1016/j.compag.2009.04.006
- M S, H., R, S., & M, R. (2021). Block chain based agricultural supply chain-a review. *Global Transitions Proceedings*, 2(2), 220-226. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2666285X21000698> (International Conference on Computing System and its Applications (ICCSA- 2021)) doi: <https://doi.org/10.1016/j.gltp.2021.08.041>
- Maes, W., & Steppe, K. (2018, 12). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in Plant Science*, 24. doi: 10.1016/j.tplants.2018.11.007

- Mancuso, M., & Bustaffa, F. (2006, 01). A wireless sensors network for monitoring environmental variables in a tomato greenhouse. *IEEE International Workshop on Factory Communication Systems - Proceedings, WFCS*. doi: 10.1109/WFCS.2006.1704135
- Manrique-Silupu, J., Campos, J. C., Paiva, E., & Ipanaqué, W. (2021). Thrips incidence prediction in organic banana crop with machine learning. *Heliyon*, 7(12), e08575. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2405844021026785> doi: <https://doi.org/10.1016/j.heliyon.2021.e08575>
- Maohua, W. (2001, 02). Possible adoption of precision agriculture for developing countries at the threshold of the new millennium. *Computers and Electronics in Agriculture*, 30, 45-50. doi: 10.1016/S0168-1699(00)00154-X
- McGuire, A. V., & Northfield, T. D. (2021). Identification and evaluation of endemic metarhizium strains for biological control of banana rust thrips. *Biological Control*, 162, 104712. Retrieved from <https://www.sciencedirect.com/science/article/pii/S104996442100181X> doi: <https://doi.org/10.1016/j.biocontrol.2021.104712>
- Mekki, M., Abdallah, O., Amin, M. B. M., Eltayeb, M., Abdalfatah, T., & Babiker, A. (2015). Greenhouse monitoring and control system based on wireless sensor network. In *2015 international conference on computing, control, networking, electronics and embedded systems engineering (iccneee)* (p. 384-387). doi: 10.1109/ICCNEEE.2015.7381396
- Mell, P., & Grance, T. (2011). The nist definition of cloud computing. technical report. *NIST, Gaithersburg, MD, United States*, 2, 800-145.
- Miles, B., Bourenane, E.-B., Boucherkha, S., & Chikhi, S. (2020). A study of lorawan protocol performance for iot applications in smart agriculture. *Computer Communications*, 164, 148-157. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0140366420319575> doi: <https://doi.org/10.1016/j.comcom.2020.10.009>
- Mohanraj, I., Ashokumar, K., & Naren, J. (2016). Field monitoring and automation using iot in agriculture domain. *Procedia Computer Science*, 93, 931-939. Re-

- trieved from <https://www.sciencedirect.com/science/article/pii/S1877050916315216> (Proceedings of the 6th International Conference on Advances in Computing and Communications) doi: <https://doi.org/10.1016/j.procs.2016.07.275>
- Mohd Kassim, M. R., Mat, I., & Harun, A. N. (2014). Wireless sensor network in precision agriculture application. In *2014 international conference on computer, information and telecommunication systems (cits)* (p. 1-5). doi: 10.1109/CITS.2014.6878963
- Moshou, D., Bravo, C., West, J., Wahlen, T., McCartney, A., & Ramon, H. (2004, 09). Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. *Computers and Electronics in Agriculture*, 44, 173-188. doi: 10.1016/j.compag.2004.04.003
- Muangprathub, J., Boonnam, N., Kajornkasirat, S., Lekbangpong, N., Wanichsombat, A., & Nil-laor, P. (2019). lot and agriculture data analysis for smart farm. *Computers and Electronics in Agriculture*, 156, 467-474. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169918308913> doi: <https://doi.org/10.1016/j.compag.2018.12.011>
- Muhuri, P. K., Shukla, A. K., & Abraham, A. (2019). Industry 4.0: A bibliometric analysis and detailed overview. *Engineering Applications of Artificial Intelligence*, 78, 218-235. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0952197618302458> doi: <https://doi.org/10.1016/j.engappai.2018.11.007>
- Muteba, F., Djouani, K., & Olwal, T. (2019, 01). A comparative survey study on lpwa iot technologies: Design, considerations, challenges and solutions. *Procedia Computer Science*, 155, 636-641. doi: 10.1016/j.procs.2019.08.090
- Nord, J., Koohang, A., & Paliszkievicz, J. (2019, 05). The internet of things: Review and theoretical framework. *Expert Systems with Applications*, 133. doi: 10.1016/j.eswa.2019.05.014
- Nyombi, K., van Asten, P., Corbeels, M., Taulya, G., Leffelaar, P., & Giller, K. (2010). Mineral fertilizer response and nutrient use efficiencies of east african highland banana (*musa spp.*, aaa-eahb, cv. kisansa). *Field Crops Research*, 117(1), 38-

50. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0378429010000316> doi: <https://doi.org/10.1016/j.fcr.2010.01.011>
- O'Grady, M., Langton, D., & O'Hare, G. (2019). Edge computing: A tractable model for smart agriculture? *Artificial Intelligence in Agriculture*, 3, 42-51. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2589721719300339> doi: <https://doi.org/10.1016/j.aiia.2019.12.001>
- O'Grady, M. J., & O'Hare, G. M. (2017). Modelling the smart farm. *Information Processing in Agriculture*, 4(3), 179-187. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2214317316301287> doi: <https://doi.org/10.1016/j.inpa.2017.05.001>
- Oliveira, C., Auad, A., Mendes, S., & Frizzas, M. (2014). Crop losses and the economic impact of insect pests on brazilian agriculture. *Crop Protection*, 56, 50-54. Retrieved from <https://www.sciencedirect.com/science/article/pii/S026121941300269X> doi: <https://doi.org/10.1016/j.cropro.2013.10.022>
- Oliveira, L., & Rodrigues, J. (2011, 04). Wireless sensor networks: A survey on environmental monitoring. *JCM*, 6, 143-151. doi: 10.4304/jcm.6.2.143-151
- Orozco-Santos, M., Orozco-Romero, J., Pérez-Zamora, O., Manzo-Sánchez, G., Farías-Larios, J., & Moraes, W. D. S. (2008). Prácticas culturales para el manejo de la Sigatoka negra en bananos y plátanos. *Tropical Plant Pathology*, 33(3), 189-196. doi: 10.1590/S1982-56762008000300003
- Pahuja, R., Verma, H., & Uddin, M. (2013). A wireless sensor network for greenhouse climate control. *IEEE Pervasive Computing*, 12(2), 49-58. doi: 10.1109/MPRV.2013.26
- Panigrahi, N., Thompson, A. J., Zobelzu, S., & Knox, J. W. (2021). Identifying opportunities to improve management of water stress in banana production. *Scientia Horticulturae*, 276, 109735. Retrieved from <https://www.sciencedirect.com/science/article/pii/S030442382030563X> doi: <https://doi.org/10.1016/j.scienta.2020.109735>
- Pantazi, X., Tamouridou, A. A., Alexandridis, T., Lagopodi, A., Kashefi, J., & Moshou, D. (2017, 06). Evaluation of hierarchical self-organising maps for weed mapping using uas

- multispectral imagery. *Computers and Electronics in Agriculture*, 139, 224-230. doi: 10.1016/j.compag.2017.05.026
- Pawar, D., Dingre, S., & Bhoi, P. (2017, 02). Productivity and economics of drip irrigated banana (*musa spp.*) under different planting and fertigation techniques in sub tropical india. *Communications in Soil Science and Plant Analysis*, 48. doi: 10.1080/00103624.2017.1282505
- Pawlowski, A., Guzmán, J., Rodriguez, F., Berenguel, M., Sanchez, J., & Dormido, S. (2009, 01). Simulation of greenhouse climate monitoring and control with wireless sensor network and event-based control. *Sensors (Basel, Switzerland)*, 9, 232-52. doi: 10.3390/s90100232
- Peper, F., Noda, H., & Shirazi, M. N. (2002). 35 - determination of principal components in data. In C. T. Leondes (Ed.), *Expert systems* (p. 1199-1258). Burlington: Academic Press. Retrieved from <https://www.sciencedirect.com/science/article/pii/B978012443880450079X> doi: <https://doi.org/10.1016/B978-012443880-4/50079-X>
- Pivoto, D., Waquil, P., Talamini, E., Spanhol, C., Corte, V., & Mores, G. (2017, 12). Scientific development of smart farming technologies and their application in brazil. *Information Processing in Agriculture*, 5. doi: 10.1016/j.inpa.2017.12.002
- Ploetz, R., Kema, G., & Ma, L.-J. (2015, 05). Impact of diseases on export and smallholder production of banana. *Annual review of phytopathology*, 53. doi: 10.1146/annurev-phyto-080614-120305
- Poe, W., & Schmitt, J. (2009, 01). Node deployment in large wireless sensor networks: Coverage, energy consumption, and worst-case delay. In (p. 77-84). doi: 10.1145/1711113.1711127
- Pyati, M., D G, N., & Kengond, S. (2020). Energy-efficient and dynamic consolidation of virtual machines in openstack-based private cloud. *Procedia Computer Science*, 171, 2343-2352. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050920312461> (Third International Conference on Computing and Network Communications (CoCoNet'19)) doi: <https://doi.org/10.1016/>

j.procs.2020.04.254

- Queralta, J. P., Gia, T., Zou, Z., Tenhunen, H., & Westerlund, T. (2019). Comparative study of lpwan technologies on unlicensed bands for m2m communication in the iot: beyond lora and lorawan. *Procedia Computer Science*, 155, 343-350. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050919309639> (The 16th International Conference on Mobile Systems and Pervasive Computing (MobiSPC 2019),The 14th International Conference on Future Networks and Communications (FNC-2019),The 9th International Conference on Sustainable Energy Information Technology) doi: <https://doi.org/10.1016/j.procs.2019.08.049>
- Quynh, T., Manh, N., & Nguyen, K. (2015, 06). Multipath rpl protocols for greenhouse environment monitoring system based on internet of things. In (p. 1-6). doi: 10.1109/ECTICon.2015.7207135
- Raheemah, A., Sabri, N., Salim, M., Ehkan, P., & Ahmad, R. B. (2016). New empirical path loss model for wireless sensor networks in mango greenhouses. *Computers and Electronics in Agriculture*, 127, 553-560. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169916304987> doi: <https://doi.org/10.1016/j.compag.2016.07.011>
- RAI, A., DAS, N. N., & SINGH, R. P. (1967). *Smart Agriculture: Emerging Pedagogies of Deep Learning, Machine Learning and Internet of Things*.
- Raj, M., Gupta, S., Chamola, V., Garg, T., Elhence, A., Atiquzzaman, M., & Niyato, D. (2021, 08). A survey on the role of internet of things for adopting and promoting agriculture 4.0. *Journal of Network and Computer Applications*, 187, 1-29.
- Ramos, P., Prieto, F., Montoya, E., & Oliveros, C. (2017, 05). Automatic fruit count on coffee branches using computer vision. *Computers and Electronics in Agriculture*, 137, 9-22. doi: 10.1016/j.compag.2017.03.010
- Ray, D. K., Gerber, J. S., Macdonald, G. K., & West, P. C. (2015). Climate variation explains a third of global crop yield variability. *Nature Communications*, 6, 1-9. doi: 10.1038/ncomms6989
- Rehman, T. U., Mahmud, M. S., Chang, Y. K., Jin, J., & Shin, J. (2019). Current

- and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Computers and Electronics in Agriculture*, 156, 585-605. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169918304289> doi: <https://doi.org/10.1016/j.compag.2018.12.006>
- Rogers, E. M., Singhal, A., & Quinlan, M. M. (2019). *Diffusion of innovations*. doi: 10.4324/9780203710753-35
- Romero. (1998). El control de la sigatoka en producción de banano orgánico. In: *Memorias del taller internacional: Producción de banano orgánico y/o ambientalmente amigable*. Rosales FE, Tripon SC, Cerna J (Eds). INIBAP, CIID, EARTH. Guácimo, Costa Rica., 173-179.
- Roukh, A., Fote, F. N., Mahmoudi, S. A., & Mahmoudi, S. (2020). Big data processing architecture for smart farming. *Procedia Computer Science*, 177, 78-85. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050920322791> (The 11th International Conference on Emerging Ubiquitous Systems and Pervasive Networks (EUSPN 2020) / The 10th International Conference on Current and Future Trends of Information and Communication Technologies in Healthcare (ICTH 2020) / Affiliated Workshops) doi: <https://doi.org/10.1016/j.procs.2020.10.014>
- Sabarina, K., & Priya, N. (2015). Lowering data dimensionality in big data for the benefit of precision agriculture. *Procedia Computer Science*, 48, 548-554. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050915006432> (International Conference on Computer, Communication and Convergence (ICCC 2015)) doi: <https://doi.org/10.1016/j.procs.2015.04.134>
- Sabri, N., Aljunid, S., Ahmad, R., Yahya, A., Kamaruddin, R., & Salim, M. (2011, 12). Wireless sensor actor network based on fuzzy inference system for greenhouse climate control. *Journal of Applied Sciences*, 11. doi: 10.3923/jas.2011.3104.3116
- Sadowski, S., & Spachos, P. (2020). Wireless technologies for smart agricultural monitoring using internet of things devices with energy harvesting capabilities. *Computers and Electronics in Agriculture*, 172, 105338. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169919318381> doi: <https://doi.org/10>

.1016/j.compag.2020.105338

- Said Mohamed, E., Belal, A., Kotb Abd-Elmabod, S., El-Shirbeny, M. A., Gad, A., & Zahran, M. B. (2021). Smart farming for improving agricultural management. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3, Part 2), 971-981. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1110982321000582> doi: <https://doi.org/10.1016/j.ejrs.2021.08.007>
- Salekdeh, G. H., Reynolds, M., Bennett, J., & Boyer, J. (2009). Conceptual framework for drought phenotyping during molecular breeding. *Trends in Plant Science*, 14(9), 488-496. Retrieved from <https://www.sciencedirect.com/science/article/pii/S136013850900171X> doi: <https://doi.org/10.1016/j.tplants.2009.07.007>
- Salvacion, A. R. (2020). Effect of climate on provincial-level banana yield in the philippines. *Information Processing in Agriculture*, 7(1), 50-57. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2214317318304311> doi: <https://doi.org/10.1016/j.inpa.2019.05.005>
- Semtech Corporation. (2013). SX1272/3/6/7/8 LoRa Modem Design Guide, AN1200.13. (July), 9. Retrieved from <https://www.rs-online.com/>
- Seneviratne, P. (2019). *Beginning lora radio networks with arduino: Build long range, low power wireless iot networks*. doi: 10.1007/978-1-4842-4357-2
- Sharma, R., Kamble, S. S., & Gunasekaran, A. (2018). Big gis analytics framework for agriculture supply chains: A literature review identifying the current trends and future perspectives. *Computers and Electronics in Agriculture*, 155, 103-120. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169918311311> doi: <https://doi.org/10.1016/j.compag.2018.10.001>
- Shor, R., & Weldon, R. (2018). *Crop Production and Management*.
- Singh, J., Singh, P., & Gill, S. S. (2021). Fog computing: A taxonomy, systematic review, current trends and research challenges. *Journal of Parallel and Distributed Computing*, 157, 56-85. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0743731521001349> doi: <https://doi.org/10.1016/j.jpdc.2021.06.005>

- Sinha, R., Yiqiao, W., & Hwang, S.-H. (2017, 03). A survey on lpwa technology: Lora and nb-iot. *ICT Express*, 3. doi: 10.1016/j.icte.2017.03.004
- Smithson, P., McIntyre, B., Gold, C. S., Ssali, H., & Kashaija, I. (2001, 05). Nitrogen and potassium fertilizer vs. nematode and weevil effects on yield and foliar nutrient status of banana in uganda. *Nutrient Cycling in Agroecosystems*, 59, 239-250. doi: 10.1023/A:1014462923539
- Soatti, G., Savazzi, S., Nicoli, M., Alvarez, M. A., Kianoush, S., Rampa, V., & Spagnolini, U. (2019). Distributed signal processing for dense 5g iot platforms: Networking, synchronization, interference detection and radio sensing. *Ad Hoc Networks*, 89, 9-21. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1570870519301428> doi: <https://doi.org/10.1016/j.adhoc.2019.02.006>
- Song, Y., Gong, C., Feng, Y., Ma, J., & Zhang, X. (2011, 12). Design of greenhouse control system based on wireless sensor networks and avr microcontroller. *JNW*, 6, 1668-1674. doi: 10.4304/jnw.6.12.1668-1674
- Sunhare, P., Chowdhary, R., & Chattopadhyay, M. (2020, 07). *Internet of things and data mining: An application oriented survey*. doi: 10.1016/j.jksuci.2020.07.002
- Suprem, A., Mahalik, N., & Kim, K. (2013, 06). A review on application of technology systems, standards and interfaces for agriculture and food sector. *Computer Standards and Interfaces*, 35, 355-364. doi: 10.1016/j.csi.2012.09.002
- Talavera, J. M., Tobón, L. E., Gómez, J. A., Culman, M. A., Aranda, J. M., Parra, D. T., ... Garreta, L. E. (2017). Review of iot applications in agro-industrial and environmental fields. *Computers and Electronics in Agriculture*, 142, 283-297. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169917304155> doi: <https://doi.org/10.1016/j.compag.2017.09.015>
- Talaviya, T., Shah, D., Patel, N., Yagnik, H., & Shah, M. (2020). Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*, 4, 58-73. Retrieved from <https://www.sciencedirect.com/science/article/pii/S258972172030012X> doi: <https://doi.org/10.1016/j.aiia.2020.04.002>

- Tarendra, L., Ghedira, H., Temimi, M., Sengupta, M., Khanbilvardi, R., & Reginald, B. (2009, 03). Non-parametric methods for soil moisture retrieval from satellite remote sensing data. *Remote Sensing*, 1. doi: 10.3390/rs1010003
- Terengia Materu, S., Tambo, S., Mbilinyi, B., Kadigi, I., Nakalembe, C., & Justice, C. (2016, 12). Pa11b-1960: Electronic field data collection in support of satellite-based food security monitoring in tanzania find similar..
- Thakur, D., Kumar, Y., Kumar, A., Singh, P., & Singh, V. (2018, 01). Real time monitoring of valeriana jatamansi plant for growth analysis. *Procedia Computer Science*, 132, 507-517. doi: 10.1016/j.procs.2018.05.003
- Tohidyan Far, S., & Rezaei-Moghaddam, K. (2017, 09). Impacts of the precision agricultural technologies in iran: An analysis experts' perception and their determinants. *Information Processing in Agriculture*, 5. doi: 10.1016/j.inpa.2017.09.001
- Torky, M., & Hassanein, A. E. (2020). Integrating blockchain and the internet of things in precision agriculture: Analysis, opportunities, and challenges. *Computers and Electronics in Agriculture*, 178, 105476. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0168169919324329> doi: <https://doi.org/10.1016/j.compag.2020.105476>
- Turner, D. W., Fortescue, J. A., & Thomas, D. S. (2007). Environmental physiology of the bananas (*Musa spp.*). *Brazilian Journal of Plant Physiology*, 19(4), 463-484. doi: 10.1590/S1677-04202007000400013
- Turner D.W., L. E. (1983). The growth of banana plants in relation to temperature. *Australian Journal of Plant Physiology*, 7(10), 43-53. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2214317318304311> doi: <https://doi.org/10.1071/PP9830043>
- Tzounis, A., Katsoulas, N., Bartzanas, T., & Kittas, C. (2017, 12). Internet of things in agriculture, recent advances and future challenges. *Biosystems Engineering*, 164, 31-48. doi: 10.1016/j.biosystemseng.2017.09.007
- Ukhurebor, K. E., Adetunji, C. O., Olugbemi, O. T., Nwankwo, W., Olayinka, A. S., Umezuruike, C., & Hefft, D. I. (2022). Chapter 6 - precision agriculture:

- Weather forecasting for future farming. In A. Abraham, S. Dash, J. J. Rodrigues, B. Acharya, & S. K. Pani (Eds.), *Ai, edge and iot-based smart agriculture* (p. 101-121). Academic Press. Retrieved from <https://www.sciencedirect.com/science/article/pii/B9780128236949000086> doi: <https://doi.org/10.1016/B978-0-12-823694-9.00008-6>
- Van Asten, P., Fermont, A., & Taulya, G. (2011). Drought is a major yield loss factor for rainfed east african highland banana. *Agricultural Water Management*, 98(4), 541-552. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0378377410003264> doi: <https://doi.org/10.1016/j.agwat.2010.10.005>
- Varma, V., & Bebbber, D. (2019, 10). Climate change impacts on banana yields around the world. *Nature Climate Change*, 9, 1-6. doi: 10.1038/s41558-019-0559-9
- Vosselen, V. (2005). Assessing water consumption of banana: traditional versus modelling approach. *Agricultural Water Management*, 74(3), 201-218. <https://eurekamag.com/research/004/048/004048703.php>.
- Wang, N., Zhang, N., & Wang, M. (2006, 11). Wireless sensors in agriculture and food industry—recent development and future perspective. *Computers and Electronics in Agriculture*, 50, 1-14. doi: 10.1016/j.compag.2005.09.003
- Wang, Q., Zhu, X., Ni, Y., Gu, L., & Zhu, H. (2020). Blockchain for the iot and industrial iot: A review. *Internet of Things*, 10, 100081. Retrieved from <https://www.sciencedirect.com/science/article/pii/S254266051930085X> (Special Issue of the Elsevier IoT Journal on Blockchain Applications in IoT Environments) doi: <https://doi.org/10.1016/j.iot.2019.100081>
- Wang, X., Jiang, D., & Lang, X. (2017). Future extreme climate changes linked to global warming intensity. *Science Bulletin*, 62(24), 1673-1680. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2095927317305583> doi: <https://doi.org/10.1016/j.scib.2017.11.004>
- Wang, Y.-M., Wang, Y.-S., & Yang, Y.-F. (2010, 06). Understanding the determinants of rfid adoption in the manufacturing industry. *Technological Forecasting and Social Change* -

- TECHNOL FORECAST SOC CHANGE*, 77, 803-815. doi: 10.1016/j.techfore.2010.03.006
- Weiss, U., Biber, P., Laible, S., Bohlmann, K., & Zell, A. (2010, 12). Plant species classification using a 3d lidar sensor and machine learning. In (p. 339-345). doi: 10.1109/ICMLA.2010.57
- Welbourne, E., Battle, L., Cole, G., Gould, K., Rector, K., Raymer, S., ... Borriello, G. (2009, 05). Building the internet of things using rfid: The rfid ecosystem experience. *IEEE Internet Computing*, 13, 48-55. doi: 10.1109/MIC.2009.52
- White, J. W., & Hoogenboom, G. (2010). Crop response to climate: ecophysiological models..
- Willig, A. (2008). Recent and emerging topics in wireless industrial communications: A selection. *IEEE Transactions on Industrial Informatics*, 4(2), 102-124. doi: 10.1109/TII.2008.923194
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming - a review. *Agricultural Systems*, 153, 69-80. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0308521X16303754> doi: <https://doi.org/10.1016/j.agsy.2017.01.023>
- Wunder, S. (2001, 01). Ecuador goes bananas: incremental technological change and forest loss. In (p. 167-194). doi: 10.1079/9780851994512.0167
- Xiao, P. (2019). *Practical Java programming for IOT, AI, and Blockchain* (Vol. 59).
- Xiu, F., Lu, Y., Qi, Y., Wang, Y., & He, J. (2021). Ultrasensitive and practical chemiluminescence sensing pesticide residue acetamiprid in agricultural products and environment: Combination of synergistically coupled co-amplifying signal and smart interface engineering. *Talanta*, 235, 122811. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0039914021007323> doi: <https://doi.org/10.1016/j.talanta.2021.122811>
- Yoon, C., Lim, D., & Park, C. (2020a). Factors affecting adoption of smart farms: The case of korea. *Computers in Human Behavior*, 108, 106309. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0747563220300637> doi: <https://doi.org/10.1016/j.chb.2020.106309>
- Yoon, C., Lim, D., & Park, C. (2020b, 02). Factors affecting adoption of smart farms: The case

- of korea. *Computers in Human Behavior*, 108, 106309. doi: 10.1016/j.chb.2020.106309
- Yu, P., Yong, X., & Xi-yuan, P. (2011, 05). Gems: A wsn-based greenhouse environment monitoring system. *Conference Record - IEEE Instrumentation and Measurement Technology Conference*, 1-6. doi: 10.1109/IMTC.2011.5944132
- Zamora-Izquierdo, M. A., Santa, J., Martínez, J. A., Martínez, V., & Skarmeta, A. F. (2019). Smart farming iot platform based on edge and cloud computing. *Biosystems Engineering*, 177, 4-17. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1537511018301211> (Intelligent Systems for Environmental Applications) doi: <https://doi.org/10.1016/j.biosystemseng.2018.10.014>
- Zhang, J., Li, B., Zhang, J., Christie, P., & Li, X. (2020). Organic fertilizer application and Mg fertilizer promote banana yield and quality in an Udic Ferralsol. *PLoS ONE*, 15(3), 1-19. Retrieved from <http://dx.doi.org/10.1371/journal.pone.0230593> doi: 10.1371/journal.pone.0230593
- Zhang, M., Li, C., & Yang, F. (2017, 06). Classification of foreign matter embedded inside cotton lint using short wave infrared (swir) hyperspectral transmittance imaging. *Computers and Electronics in Agriculture*, 139, 75-90. doi: 10.1016/j.compag.2017.05.005
- Zhang, M., Sun, F., & Cheng, X. (2012, 10). Architecture of internet of things and its key technology integration based-on rfid. In (Vol. 1, p. 294-297). doi: 10.1109/ISCID.2012.81
- Zhu, H., Wu, J., Huang, D., Zhu, Q., Liu, S., Su, Y.-R., ... Li, Y. (2010, 06). Improving fertility and productivity of a highly-weathered upland soil in subtropical china by incorporating rice straw. *Plant and Soil*, 331, 427-437. doi: 10.1007/s11104-009-0263-z
- Zou, W., Yao, F., Zhang, B., He, C., & Guan, Z. (2017, 03). Verification and predicting temperature and humidity in a solar greenhouse based on convex bidirectional extreme learning machine algorithm. *Neurocomputing*, 249. doi: 10.1016/j.neucom.2017.03.023
- Čolaković, A., & Hadžialić, M. (2018). Internet of things (iot): A review of enabling technologies, challenges, and open research issues. *Computer Networks*, 144, 17-39. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1389128618305243> doi: <https://doi.org/10.1016/j.comnet.2018.07.017>