



Metodología de caracterización del crecimiento de plantas de cannabis sativa en etapa vegetativa por distribución espectral de fotones mediante modelos predictivos de inteligencia artificial

Juan Carlos Morales Guerra

Instituto Tecnológico Metropolitano
Facultad de Ingenierías
Medellín, Antioquia
2025

Metodología de caracterización del crecimiento de plantas de cannabis sativa en etapa vegetativa por distribución espectral de fotones mediante modelos predictivos de inteligencia artificial

Juan Carlos Morales Guerra

Tesis presentada como requisito parcial para optar al título de:
Magíster en Automatización y Control Industrial

Director: Erick Estefen Reyes Vera
Director: Juan Sebastián Botero Valencia

Línea de Investigación: Internet de las Cosas
Grupo de Investigación: Automática Electrónica y Ciencias Computacionales –
Sistemas de Control y Robótica

Instituto Tecnológico Metropolitano
Facultad de Ingenierías
Medellín, Antioquia
2025

Resumen

La convergencia de la Industria 4.0, especialmente la Inteligencia Artificial (IA) y el Internet de las Cosas (IoT), con la Agricultura en Ambiente Controlado (CEA) está transformando la producción de cultivos de alto valor. Esta sinergia es fundamental en el cultivo de Cannabis sativa medicinal, donde el control preciso de las variables ambientales es indispensable para garantizar la estandarización del producto y cumplir con las rigurosas demandas de calidad y consistencia del mercado farmacéutico. A pesar de que la literatura científica ha demostrado que la modulación de la luz optimiza el rendimiento, las investigaciones actuales se han limitado a aplicar regímenes de iluminación y estudiar el crecimiento de la planta. Por lo tanto, existe una brecha crítica en el conocimiento sobre cómo las modulaciones de alta frecuencia y a escala diurna del espectro (SPD) y la intensidad (PPFD) pueden utilizarse para dirigir el crecimiento de la planta de manera específica. Además, carecemos de modelos predictivos que puedan vincular estos complejos patrones lumínicos con trayectorias de crecimiento, considerando la variabilidad genotípica entre cultivares. El objetivo de esta investigación fue desarrollar y evaluar modelos de aprendizaje automático capaces de predecir el crecimiento de plantas de Cannabis sativa en su etapa vegetativa, en función de la modulación lumínica y las variables microclimáticas.

Para ello, se diseñó e implementó un sistema de monitoreo basado en IoT que registró de forma continua datos fotométricos (PPFD, DLI), ambientales y fisiológicos de plantas sometidas a diferentes tratamientos de iluminación artificial. Posteriormente, se entrenaron y compararon cuatro modelos predictivos —ElasticNet, Huber Regressor, Random Forest y XGBoost— para determinar su precisión, robustez e interpretabilidad en la estimación de la altura de la planta en un horizonte de 20 días.

Los resultados demostraron una clara superioridad de los modelos lineales regularizados frente a los ensambles de árboles. Específicamente, el modelo ElasticNet alcanzó el desempeño más alto, logrando un error absoluto medio (MAE) de 3.27 mm y un coeficiente de determinación (R^2) de 0.9412, explicando más del 94 % de la variabilidad en el crecimiento. El análisis de interpretabilidad (SHAP y Permutación) reveló de manera consistente que las variables fotométricas, PPFD y DLI, fueron los predictores más influyentes, alineando los hallazgos del modelo con los principios fisiológicos de la fotosíntesis.

Este estudio propone una metodología robusta que integra el monitoreo IoT con la inteligencia artificial para modelar y predecir el crecimiento vegetativo de Cannabis sativa. El trabajo no solo identifica los factores lumínicos como motores clave del crecimiento, sino que también proporciona un modelo predictivo validado que constituye una herramienta de gran potencial para optimizar los protocolos de iluminación y mejorar la toma de decisiones en la agricultura de precisión.

Palabras clave: Cannabis sativa, Aprendizaje Automático, Agricultura en Ambiente Controlado, Modelado Predictivo del Crecimiento, Iluminación LED, Internet de las Cosas.

"Linux sólo es gratis si tu tiempo no tiene valor".

Jamie Zawinski

Agradecimientos

La culminación de esta tesis representa un hito importante en mi desarrollo profesional. Si bien es el resultado de un esfuerzo personal, no habría sido posible sin el apoyo, la guía y el aliento de muchas personas a quienes deseo expresar mi más profundo agradecimiento.

A mi padre, de quien aprendí que la disciplina y la constancia son los verdaderos cimientos de cualquier gran proyecto. Su ejemplo en este sentido ha sido mi principal referente y una guía constante.

A mi madre, por ser esa voz de aliento y por escucharme siempre, sobre todo cuando más lo necesité. Gracias por tu apoyo moral, que fue fundamental para recargar energías y seguir adelante en los momentos de duda.

A mi hijo, en quien veo un potencial inmenso. Ese futuro que imagino para ti es mi mayor inspiración para esforzarme y ser el ejemplo que mereces. Este logro es mi forma de mostrarte que las metas se alcanzan con dedicación.

A mis tutores, mi más sincero agradecimiento por su guía experta y su rigor académico. Valoro enormemente su paciencia, sus oportunas preguntas que me obligaron a profundizar en mi análisis y su disposición para orientarme. Su acompañamiento fue clave para llevar este trabajo a buen término.

A mis colegas y amigos, con quienes compartí este camino. Agradezco especialmente las charlas, casi siempre acompañadas de un café, que enriquecieron mi perspectiva y desatasaron ideas. El buen humor y el apoyo mutuo hicieron más ligeros los momentos de frustración.

Finalmente, un reconocimiento a mi yo del pasado, por haber asumido este reto con más determinación que certezas, y por la disciplina sostenida a lo largo de estos años para llegar hasta este día.

Tabla de Contenido

Resumen	i
1. Introducción	1
1.1. Objetivos	4
2. Marco teórico	5
2.1. Biología y fisiología de Cannabis sativa	5
2.2. Principios del cultivo hidropónico	14
2.3. Tecnologías de monitoreo y control	17
2.3.1. Internet de las cosas (IoT)	18
2.3.2. Protocolos de comunicación	18
2.3.3. Automatización y lógica de control	21
2.3.4. Sensores en agricultura controlada	22
2.3.5. Infraestructura en la nube	23
2.4. Iluminación en la fase vegetativa temprana	24
2.4.1. Fotomorfogénesis inducida por espectros lumínicos	27
2.5. Bases fisiológicas del crecimiento vegetal	28
2.5.1. Panorama actual de modelos de crecimiento aplicados a Cannabis sativa	32
2.5.2. Vacíos identificados y contribución esperada	35
3. Arquitectura IoT de monitoreo	36
3.1. Sistema de adquisición de datos	37
3.1.1. Sensores ambientales	38
3.1.1.1. Sensirion SCD40 Humedad y Temperatura	39
3.1.1.2. Sensor multiespectral (AS7265x)	41
3.1.1.3. Modelo de ajuste de datos	43
3.1.1.4. Conversión y despliegue del modelo MLP con TFLite	44
3.1.2. Diseño físico del sistema: torre de sensores	45
3.1.3. Sensores de calidad del agua	46
3.1.3.1. Sensor de pH	47
3.1.3.2. Sensor de conductividad eléctrica	48
3.1.3.3. Sensor de temperatura del agua	50
3.2. Lógica de control embebida	51
3.2.1. Control de variables ambientales	51
3.2.1.1. Actuadores	55
3.2.2. Control de calidad del agua	57
3.2.2.1. Dispositivos de dosificación y ajuste	58
3.2.2.2. Resultados del control	61

3.3.	Infraestructura de Borde (Edge Computing)	64
3.3.1.	Módulos de comunicación	65
3.3.2.	Plataforma de backend y frontend	67
3.3.3.	Base de datos e interfaz gráfica	68
4.	Evaluación espectral y crecimiento en Cannabis sativa	71
4.1.	Diseño experimental	71
4.1.1.	Configuración espectral de luz	72
4.1.2.	Condiciones de cultivo e infraestructura	75
4.1.3.	Material vegetal y manejo agronómico	78
4.2.	Variables registradas y mediciones	80
4.3.	Análisis de crecimiento y respuesta fisiológica	81
4.3.1.	Análisis estadístico (ANOVA)	85
4.3.2.	Evaluación de correlaciones y colinealidad	89
5.	Modelado predictivo	92
5.1.	Estructura y preprocesamiento del conjunto de datos	92
5.2.	Modelos	93
5.2.1.	Modelos lineales	93
5.2.1.1.	Elastic Net	93
5.2.1.2.	Huber Regressor	96
5.2.2.	Modelos basados en árboles	97
5.2.2.1.	Random Forest	97
5.2.2.2.	XGBoost	99
5.3.	Análisis de resultados	100
5.3.1.	Comparación de desempeño global	100
5.3.2.	Evaluación de la robustez	101
5.3.3.	Selección del modelo final	102
5.3.4.	Interpretabilidad del modelo	103
6.	Conclusiones y perspectivas	107
	Bibliografía	109

Índice de Tablas

2.1.	Comparación técnica entre los sistemas hidropónicos NFT y DWC	17
2.2.	Comparación entre 6LoWPAN e IPv6 sobre WiFi en redes IoT para agricultura	19
2.3.	Comparación entre MQTT y WebSocket en aplicaciones IoT para agricultura .	20
2.4.	Componentes de un sistema de automatización agrícola	21
2.5.	Tipos de sensores utilizados en agricultura controlada	23
2.6.	Comparación de espectros lumínicos en fase vegetativa de <i>Cannabis sativa</i> (primeras 3 semanas) y sus efectos reportados en altura de planta, diámetro de tallo y otros rasgos.	27
2.7.	Comparación de tecnologías de iluminación en agricultura controlada	28
2.8.	Métodos de análisis multivariable aplicados en estudios sobre crecimiento vegetal	31
2.9.	Ejemplos de modelos para estimar el crecimiento de <i>Cannabis sativa</i> basados en mediciones directas.	35
3.1.	Especificaciones técnicas de los sensores ambientales utilizados en el sistema de monitoreo.	38
3.2.	Comparación entre temperatura de control, promedio del patrón (Fluke 971) y el sensor SCD40, incluyendo el error de medición.	39
3.3.	Comparación entre valores de humedad relativa del patrón de referencia (Fluke 971) y el sensor SCD40.	40
3.4.	Especificaciones técnicas de los sensores utilizados para el monitoreo de la calidad del agua.	47
3.5.	Especificaciones técnicas y costo aproximado de los equipos de ventilación, deshumidificación y calefacción empleados.	56
3.6.	Especificaciones de la bomba peristáltica BOM-PER-12V.	58
3.7.	Resultados de las pruebas volumétricas de la bomba BOM-PER-12V (n = 5). .	60
3.8.	Parámetros de dosificación de Bionova A y B y EC final obtenida.	62
3.9.	Parámetros de dosificación de ácido fosfórico al 30 % y pH final obtenido. . .	63
4.1.	Características técnicas del sistema de iluminación Sunplus S250 4 Bars LM301H 250W.	73
4.2.	Ajuste de duty cycle para las diferentes composiciones espectrales (UV, VEG y BLOOM), valores de PPFD aproximados y referencia al espectro obtenido. . .	73
4.3.	Parámetros ambientales y nutricionales establecidos para los experimentos. . .	80
4.4.	ANOVA de dos factores (tratamiento espectral y bloque temporal) sobre la tasa relativa de crecimiento (TRC): suma de cuadrados (SC), grados de libertad (GL), estadístico F y valor p.	86
4.5.	Prueba de comparaciones múltiples de Tukey HSD para la tasa relativa de crecimiento. Se muestran las diferencias de medias entre tratamientos, sus intervalos de confianza al 95 % y el <i>p</i> -valor ajustado.	86

4.6.	Coefficientes de correlación de Pearson (r) entre las variables ambientales y morfométricas.	91
5.1.	Comparación de las métricas de desempeño claves de los modelos en el conjunto de prueba.	100
5.2.	Comparación de métricas bajo nivel de ruido del 5 % para todos los modelos. .	102

Índice de Ilustraciones

2.1.	Radiación fotosintéticamente activa PAR.	7
2.2.	Estado del fitocromo, Fuente: Elaboración propia (basada en una generación inicial con DALL·E, OpenAI).	9
2.3.	Curva de respuesta fisiológica estimada que representa el efecto de la temperatura sobre la tasa fotosintética relativa en <i>Cannabis sativa</i> . Se observa un rendimiento óptimo en torno a los 25°C, con reducciones significativas bajo condiciones térmicas subóptimas o extremas. Fuente: Los datos para graficar son obtenidos de [34][31].	11
2.4.	Mapa de calor: estimación de la eficiencia fisiológica de Cannabis sativa en función de la interacción entre temperatura y humedad relativa en etapas vegetativas. Fuente: Los datos para graficar son obtenidos de [34]	12
2.5.	VARIABLES ambientales que afectan la fisiología de Cannabis sativa.Fuente: Elaboración propia,(basado en una generación inicial con DALL-E OpenAi	13
2.6.	Esquema del sistema hidropónico NFT, Fuente: Elaboración propia, basado en una generación inicial con DALL-E, OpenAI.	15
2.7.	Esquema del sistema de cultivo hidropónico DWC. Fuente: Elaboración propia, basado en una generación inicial con DALL-E, OpenAI.	16
2.8.	Espectro solar atmosférico mostrado como SPD y SPF normalizados	25
3.1.	Esquema general de la arquitectura patrón MVC	36
3.2.	Arquitectura de conexión de sensores en el nodo de borde.	39
3.3.	Curva de calibración del sensor SCD40 para temperatura.	40
3.4.	Curva de calibración del sensor SCD40 para humedad.	41
3.5.	Comparación de las mediciones espectrales obtenidas con el sensor multiespectral AS7265x (línea verde) y el espectrofotómetro OHSP-350C (línea roja) bajo diferentes condiciones de la SPF: (a) iluminación de espectro completo, (b) espectro con incidencia roja centrada en 645 nm, (c) espectro con incidencia azul centrada en 460 nm y (d) espectro azul de baja irradiancia.	42
3.6.	Gráfico de dispersión entre las predicciones del modelo y los valores reales normalizados. La línea roja indica el ajuste ideal ($y = x$).	44
3.7.	Comparación entre espectros de referencia (OHSP-350C) y espectro ajustado con MLP embebido con Tflite.	45
3.8.	Esquema 3D de la torre de sensores(A) Cúpula difusora; (B) Cuerpo intermedio; (C) Sensor Multiespectral AS7265X; (D) Soporte estructural de sensores; (E) Sensor ambiental SCD40 ; (F) Unidad de control ESP32-S3; (G) Base de anclaje estructural	46
3.9.	Relación lineal entre el voltaje generado por el acondicionador Surveyor y el valor de pH.	48

3.10.	Verificación de la linealidad del sensor de conductividad eléctrica (EC) en tres puntos de calibración.	50
3.11.	Distribución de las lecturas del sensor PT-1000 para cada temperatura de referencia, con marcadores de desviación estándar.	51
3.12.	Esquema de la cámara de crecimiento controlada.	52
3.13.	Evolución temporal de la temperatura (línea roja) y la humedad relativa (línea azul) en el interior de la cámara de cultivo, registrada cada minuto durante un día frío (paneles a y b) y un día caluroso (paneles c y d). Las líneas punteadas representan el valor medio obtenido.	53
3.14.	Evolución temporal de la temperatura (línea roja) y la humedad relativa (línea azul) en el interior de la cámara de cultivo, registrada cada minuto durante un día frío (paneles a y b) y un día caluroso (paneles c y d). Las líneas punteadas indican los valores medios registrados. En este caso, el sistema implementó un control ON/OFF escalonado con prioridad—calefacción, extracción y deshumidificación—para mantener la temperatura entre 22–27 °C y la humedad relativa entre 60–70 %.	55
3.15.	Fotografías de los actuadores instalados al interior de la cámara de crecimiento controlada.	57
3.16.	Histograma del caudal medio y su desviación estándar para la bomba peristáltica BOM-PER-12V, medido en cinco repeticiones (n=5) con tres soluciones distintas: agua destilada, nutrientes Bionova A/B y ácido fosfórico al 30 %. Cada barra muestra el caudal promedio (mL/min) y las líneas de error indican la variabilidad observada en los ensayos.	61
3.17.	Evolución temporal de la conductividad eléctrica en los cuatro ensayos de validación del módulo “Hidro”. Cada curva muestra los cuatro ciclos de dosificación de 20 min con muestreo cada 30 s.	63
3.18.	Evolución del pH en los cuatro ensayos de validación del módulo “Hidro”. Cada curva muestra los ciclos de 20 min con muestreo cada 30 s.	64
3.19.	Arquitectura IoT; (a) Sensores en sitio; (b) Nodo Borde; (c) Nodo Backend; (d) Nodo Bases de datos; (e) Nodo Frontend.	65
3.20.	Interfaz GUI de la pestaña <i>CannaWeather</i> en Smartgrow-DataControl: visualización en tiempo real de las variables ambientales —temperatura, humedad relativa, CO ₂ , VPD, PPF y PPFd— con fecha de última actualización.	69
3.21.	Interfaz GUI de control hidroponía en Smartgrow-DataControl: (1) visualización de parámetros de calidad del agua y fecha de última actualización; (2) activación manual de válvulas de entrada y salida; (3) configuración de puntos de consigna de pH y EC.	70
4.1.	Diseño experimental BCA con bloqueo temporal.	72
4.2.	Sunplus S250 4 Bars LM301H 250W	72
4.3.	(A) Distribución de flujo fotónico espectral en banda azul (400–500 nm). (B) Distribución completa de flujo fotónico espectral (400–700 nm). (C) Distribución de flujo fotónico espectral en banda roja (600–700 nm).	74
4.4.	Matriz de densidad fotonica (PPFD) sobre el dosel de la planta. (a) Matriz de PPFd a 360 mm, (b) Matriz de PPFd a 609 mm, (c) Matriz de PPFd a 914 mm, (d) Ubicación experimental de la matriz de intensidad fotonica	75
4.5.	Diseño experimental del sistema de fertirriego hidroponico DWC.	76
4.6.	Sistema hidropónico experimental en configuración DWC	77

4.7.	Evolución temporal de los parámetros de la solución nutritiva durante un ciclo de 24 h la línea punteada roja muestra la media, además se indican los valores mínimo y máximo. (a) Variación del pH. (b) Variación de EC. (c) Variación de temperatura	78
4.8.	Material vegetal clonado (a) clones en proceso de enraizamiento para experimento, (b) Planta madre para clonación, (c) clones iniciando ciclo experimental.	79
4.9.	Diagramas de caja y bigotes de la TRC (altura relativa) por tratamiento espectral. La línea negra dentro de cada caja marca la mediana; los límites inferior y superior corresponden a los cuartiles Q_1 y Q_3 ; los bigotes se extienden hasta $1.5 \times IQR$ y los puntos aislados representan valores atípicos.	82
4.10.	Resultados de crecimiento elongación del tallo para cada distribución espectral.	84
4.11.	Resultados de crecimiento diámetro basal para cada distribución espectral . .	85
4.12.	Temperatura C° y humedad diaria RH	87
4.13.	Variabilidad temperatura	89
4.14.	Matriz de correlaciones de Pearson. Los tonos rojos indican correlaciones positivas y los azules negativas; la intensidad se corresponde con la magnitud del coeficiente.	90
5.1.	Gráfico tipo slice que muestra la relación entre los hiperparámetros alpha (a) y l1_ratio (b) frente al valor objetivo (MAE).	95
5.2.	Dispersión de las alturas reales frente a las predichas por el modelo Elastic Net en el conjunto de prueba, donde cada punto corresponde a una predicción para uno de los 20 días de horizonte y la línea diagonal indica el ajuste perfecto. . .	96
5.3.	Dispersión de las alturas reales frente a las predichas por el modelo Huber Regressor en el conjunto de prueba para un horizonte de 20 días. La línea diagonal indica el ajuste perfecto.	97
5.4.	Dispersión de las alturas reales frente a las predichas por el modelo Random Forest en el conjunto de prueba para un horizonte de 20 días.	98
5.5.	Dispersión de las alturas reales frente a las predichas por el modelo XGBoost en el conjunto de prueba para un horizonte de 20 días. La línea diagonal indica el ajuste perfecto.	100
5.6.	Importancia media absoluta de variables según SHAP para el modelo ElasticNet.	104
5.7.	Importancia de variables por permutación para el modelo ElasticNet (disminución en MAE).	105

Capítulo 1

Introducción

La Industria 4.0 representa un cambio de paradigma profundo, impulsado por la convergencia de tecnologías avanzadas que están difuminando las fronteras entre los mundos físico, digital y biológico. En su núcleo, este fenómeno se fundamenta en el aprovechamiento de herramientas como la Inteligencia Artificial (IA), el Big Data, el Internet de las Cosas (IoT, por sus siglas en inglés), la Robótica y el Blockchain para crear ecosistemas ciber-físicos. El objetivo primordial de esta integración es optimizar la producción, aumentar la eficiencia y mejorar la toma de decisiones en una amplia gama de actividades humanas. Lejos de ser un concepto futurista, esta revolución ya es una realidad en marcha, transformando operaciones y modelos de negocio en el presente [1].

Un aspecto fundamental que subyace a la transformación en todas las industrias es la relación de causa y efecto entre las tecnologías. La implementación del IoT, a través de sensores y dispositivos conectados, genera volúmenes masivos de datos en tiempo real. Esta información constituye el fundamento del Big Data, que por sí solo es una colección inmensa de datos sin procesar. Es la Inteligencia Artificial la que actúa como el motor de análisis, procesando estos datos para identificar patrones, realizar predicciones y generar conocimiento accionable. Finalmente, estos conocimientos se traducen en respuestas automáticas o acciones optimizadas, a menudo mediadas por sistemas robóticos o procesos automatizados. En este sentido, la optimización de procesos no surge de una sola tecnología, sino de la interdependencia de todo el ecosistema digital [2, 3].

La Agricultura 4.0, a menudo referida como agricultura de precisión, se basa en la aplicación inteligente de tecnologías como drones, inteligencia artificial e IoT para optimizar la producción agrícola. Su objetivo principal es claro: mejorar la eficiencia, aumentar el rendimiento de los cultivos y reducir el impacto ambiental. Este enfoque marca un cambio fundamental, alejándose de las prácticas agrícolas tradicionales basadas en la intuición o la aplicación uniforme de insumos, para adoptar un modelo impulsado por datos precisos [4].

El impacto de las tecnologías 4.0 se observa en la mejora de procesos agrícolas específicos, que ahora son más eficientes y sostenibles; Optimización de Recursos [1], predicción de Rendimientos y detección Temprana de Plagas [2] y monitoreo en Tiempo Real y Automatización [5].

Otra tecnología que ha adquirido gran protagonismo es la Agricultura en Ambiente Contro-

lado (CEA, por sus siglas en inglés); esta emerge como una solución tecnológica prometedora y una fuerza transformadora en la producción de alimentos [6]. Definida por primera vez en la década de 1960, la CEA es un enfoque intensivo que utiliza técnicas hortícolas avanzadas e innovaciones tecnológicas para controlar con precisión el crecimiento y desarrollo de las plantas [7]. Fundamentalmente, la CEA busca desacoplar la producción agrícola de las limitaciones ambientales externas, como el clima, la estacionalidad y la calidad del suelo [8]. Al crear ecosistemas meticulosamente diseñados dentro de estructuras cerradas como invernaderos, granjas verticales o fábricas de plantas, la CEA permite la manipulación y optimización de todas las variables ambientales críticas. Este control exhaustivo no solo predice con mayor fiabilidad las respuestas de las plantas, sino que también aumenta drásticamente la eficiencia de la producción, optimiza el rendimiento de los cultivos y mejora la calidad del producto final.

El verdadero potencial de la CEA se desbloquea a través de su convergencia con las tecnologías de la Industria 4.0, principalmente el Internet de las Cosas Iot y la IA. Esta integración tecnológica es el eje central que eleva a la CEA de un sistema de control estático a un ecosistema dinámico, predictivo y auto optimizado. Las redes de sensores IoT proporcionan un flujo de datos continuo y de alta resolución sobre cada aspecto del entorno de cultivo, mientras que los algoritmos de IA y *machine learning* analizan estos datos para predecir resultados, identificar problemas de forma temprana y automatizar decisiones complejas. Esta sinergia no es un mero complemento, sino un habilitador fundamental que amplifica las capacidades de la CEA tanto en la producción comercial como en la investigación, sentando las bases para una nueva era de agricultura de precisión, basada en datos y altamente productiva.

Para Cannabis sativa, una especie sujeta a una estricta regulación global y reconocida por sus valiosos perfiles medicinales, la CEA no es simplemente una alternativa, sino una plataforma indispensable para satisfacer las rigurosas demandas del mercado moderno. Al desacoplar la producción de las fluctuaciones ambientales externas, la CEA permite cosechas continuas durante todo el año y ejerce un control granular sobre cada variable que influye en el crecimiento y desarrollo de la planta. Este nivel de control es fundamental para la producción de cannabis de grado medicinal, donde la consistencia y la seguridad del producto son primordiales [9–11].

El motor económico que impulsa la adopción de la CEA en la industria del cannabis es la creciente demanda del mercado global, que se proyecta alcanzará una valoración de 651.8 mil millones de USD para 2034. Este mercado se caracteriza por una creciente sofisticación del consumidor y requisitos regulatorios estrictos, que convergen en una demanda de productos de calidad premium con perfiles de cannabinoides y terpenos específicos, potentes y, sobre todo, consistentes. La estandarización del producto final no es un mero beneficio secundario de la CEA; es su principal propuesta de valor [12]. La capacidad de producir lotes de inflorescencias con un quimiotipo predecible y reproducible es un requisito indispensable para el sector farmacéutico, que opera bajo normativas de Buenas Prácticas de Manufactura (GMP), y una ventaja competitiva decisiva en el mercado recreativo de alta gama. Esta exigencia de consistencia es lo que justifica la elevada inversión de capital inicial asociada a las instalaciones de CEA, uno de los principales desafíos del sector. La CEA, por lo tanto, representa la transición del cultivo de cannabis de una práctica agrícola sujeta a la variabilidad inherente de la naturaleza a un proceso de manufactura biológica de alta precisión, capaz de generar un material de siembra vigoroso y libre de enfermedades desde el inicio del ciclo [13].

La síntesis de la literatura científica más reciente revela un progreso sustancial en la comprensión de la fotobiología del cannabis. Se ha establecido firmemente que la manipulación de la intensidad, el espectro y el fotoperiodo puede modular significativamente el rendimiento y el perfil de metabolitos secundarios. Además, estudios pioneros [14] han demostrado de forma concluyente que la iluminación dinámica, que adapta la luz a las fases fenológicas, supera a los regímenes estáticos, y que existen interacciones cruciales entre el espectro y la intensidad que deben ser consideradas para una verdadera optimización. Sin embargo, a pesar de estos avances, la investigación actual se ha limitado a aplicar recetas dinámicas a una escala de tiempo relativamente gruesa, cambiando el espectro entre las principales fases de crecimiento que duran semanas (p. ej., un espectro para la fase vegetativa y otro para la floración) [15].

La brecha crítica en la investigación actual reside en la falta de estudios sobre regímenes de luz dinámicos que varíen no solo a lo largo del ciclo de vida del cultivo, sino también a lo largo del ciclo diario (diurno), y que estén diseñados explícitamente para dirigir la fisiología hacia una morfogénesis específica, en lugar de simplemente maximizar el rendimiento general.

La literatura actual carece de investigaciones que exploren cómo la modulación coordinada y de alta frecuencia de la Distribución espectral de energía (SPD) y la densidad de flujo de fotones fotosintéticos (PPFD) en una escala de tiempo de horas puede utilizarse para mejorar el crecimiento de la planta. No existen modelos predictivos que puedan vincular estos patrones de luz dinámicos y complejos con crecimientos específicos, y mucho menos de una manera que tenga en cuenta la variación genotípica inherente entre los diferentes cultivares de cannabis.

En un escenario donde las exigencias regulatorias, la riqueza genética del cannabis y los avances en sensores e inteligencia artificial convergen, esta tesis propone una metodología integral para estudiar y predecir el crecimiento de Cannabis sativa durante su etapa vegetativa. A partir de modelos relacionales que integran técnicas de *aprendizaje de máquina* con un sistema de monitoreo IoT, se busca capturar de manera continua y detallada las variables fisiológicas ambientales, tales como temperatura, humedad, calidad de la luz y correlacionarlas con la dinámica de crecimiento de las plantas. Para ello, en el Capítulo 2 se presenta un marco teórico acompañado de un estado del arte que permite contextualizar lo que se está haciendo actualmente en relación con este tema de estudio. En el Capítulo 3 se describe la implementación de un sistema de monitoreo IoT robusto y confiable, construido sobre una arquitectura de adquisición de datos basada en microservicios que integra sensores y dispositivos responsables de registrar continuamente las variables fisiológicas ambientales (VFA). Con esta infraestructura en funcionamiento, el Capítulo 4 describe la definición de los sujetos de prueba, las variables a medir y la caracterización de las fuentes de luz, estableciendo distribuciones espectrales específicas para cada cultivar estudiado. A partir de los datos recopilados, incluyendo el seguimiento sistemático de la tasa de crecimiento y el análisis del fototropismo como respuesta adaptativa frente a la distribución espectral de la luz, el Capítulo 5 detalla la creación de un modelo basado en inteligencia artificial que permite estimar métricas de crecimiento en función de las VFA. Finalmente, el Capítulo 6 se encarga del análisis de resultados y la discusión de conclusiones, poniendo en contexto cómo estas técnicas contribuyen al mejoramiento de cultivos y a la optimización de las prácticas agronómicas.

1.1. Objetivos

Objetivo General

Desarrollar una metodología de caracterización del crecimiento de plantas de cannabis durante la etapa vegetativa en función de la distribución espectral de fotones y variables microclimáticas de interés aplicando modelos predictivos basados en inteligencia artificial.

Objetivos específicos

- Desarrollar un sistema de monitoreo de variables microclimáticas y medidas espectrales, basado en tecnología IoT, para determinar la dinámica del crecimiento de las plantas de cannabis.
- Determinar las condiciones espectrales y características luminotécnicas de una fuente de luz artificial con las que obtener el mejor crecimiento de plantas de cannabis.
- Desarrollar un modelo de crecimiento de plantas de cannabis mediante técnicas de inteligencia artificial en función de la distribución espectral de fotones y variables microclimáticas para predecir su crecimiento en etapa vegetativa.

Capítulo 2

Marco teórico

La presente sección aborda la influencia de las VFA en la fisiología de *Cannabis sativa*, estableciendo una base conceptual para comprender su desarrollo bajo condiciones específicas. En primera instancia, se exponen aspectos fundamentales de la biología de la planta, haciendo énfasis en su comportamiento fisiológico y metabólico frente a distintos factores climáticos. Se analizan variables ambientales como la temperatura, la humedad relativa, la concentración de dióxido de carbono (CO_2), la calidad del agua y la distribución espectral de la luz, explicando cómo estas influyen en procesos clave como la fotosíntesis, la transpiración, la floración y la biosíntesis de metabolitos secundarios.

Posteriormente, se describen los principales sistemas de monitoreo y control utilizados en agricultura, destacando las tecnologías basadas en sensores y las soluciones integradas mediante IoT para el registro y supervisión de variables ambientales. Asimismo, se expone cómo el uso de servicios en la nube contribuye a optimizar los procesos de visualización, almacenamiento y análisis de datos.

Luego, se analizan las fuentes de luz artificial utilizadas en horticultura, como las lámparas LED y los sistemas de iluminación espectralmente sintonizables, y su papel en la modulación de respuestas fotobiológicas durante el cultivo. Finalmente, se presenta una revisión del estado del arte en relación con los modelos desarrollados para caracterizar la dinámica de crecimiento y las tasas de desarrollo de *Cannabis sativa*, incluyendo tanto enfoques basados en distribuciones matemáticas como metodologías sustentadas en inteligencia artificial.

2.1. Biología y fisiología de *Cannabis sativa*

Cannabis sativa L. es una especie herbácea anual de rápido crecimiento perteneciente a la familia Cannabaceae, ampliamente reconocida por su compleja biología y su capacidad para producir una diversidad de compuestos fitoquímicos de interés terapéutico, industrial y recreativo. Desde una perspectiva biológica, *Cannabis sativa* presenta una notable plasticidad fenotípica que le permite adaptarse a diversas condiciones ambientales, lo que ha facilitado su cultivo en una amplia gama de latitudes y sistemas agronómicos. Esta planta se caracteriza por poseer una morfología distintiva, un sistema de reproducción predominantemente dioico y una fisiología fuertemente influenciada por factores como el fotoperiodo, la irradiancia y las condiciones del entorno radicular. Su metabolismo secundario, especialmente en las flores

femeninas, es responsable de la síntesis de cannabinoides, terpenos y flavonoides, compuestos bioactivos que han sido objeto de creciente interés científico [16].

El *genotipo* de una planta corresponde al conjunto de alelos que porta un individuo; en *Cannabis sativa* la heterocigosidad es alta debido a su naturaleza dioica, de modo que cada semilla presenta un genotipo único [17]. El *fenotipo* es la manifestación observable de ese genotipo bajo un ambiente concreto e incluye morfología foliar, arquitectura, tiempo de floración, perfil de cannabinoides y tolerancia a estrés. Un *cultivar* (cultivated variety) agrupa individuos derivados de un genotipo estabilizado que muestran comportamiento uniforme y reproducible; en Colombia, su inscripción ante el Instituto Colombiano Agropecuario (ICA) exige la descripción de rasgos morfológicos, químicos y agronómicos [18, 19].

La interacción entre el genotipo y el ambiente da lugar a una amplia expresión fenotípica, observable tanto en rasgos morfológicos como en procesos fisiológicos clave, tales como la fotosíntesis, la floración y la producción de metabolitos secundarios. En este contexto, las condiciones de cultivo —incluyendo variables como la temperatura, la humedad, la disponibilidad de CO₂ y la calidad de la luz— juegan un papel determinante en el desarrollo y rendimiento de la planta. Cuando estos factores se desvían de sus rangos óptimos, pueden inducir distintos tipos de estrés abiótico que afectan negativamente el crecimiento y la funcionalidad del aparato fotosintético, desencadenando respuestas adaptativas que modifican la fisiología de la planta. Estas respuestas, estrechamente relacionadas con las denominadas variables fisiológicas ambientales, permiten caracterizar el comportamiento de *Cannabis sativa* frente a su entorno de cultivo. En la siguiente sección se analizará en profundidad cada una de estas variables.

Distribución Espectral de Fotones

La luz solar es la fuente principal de energía para la vida en la Tierra. Esta radiación abarca un amplio rango del espectro electromagnético, la cual, al atravesar la atmósfera, se distribuye aproximadamente en 2% de ultravioleta (UV), 45% de luz visible y 53% de infrarrojo (IR) [20]. La zona de 400–700 nm, conocida como radiación fotosintéticamente activa (PAR), constituye el 45% de esta energía y es la única absorbida eficazmente por los pigmentos de las plantas para impulsar la fotosíntesis (Figura 2.1).




Figura 2.1: Radiación fotosintéticamente activa PAR.

Dentro de la fracción ultravioleta de la radiación solar, se ha documentado que la radiación UV-B (280–315 nm) puede reducir la acumulación de biomasa y la eficiencia fotosintética; sin embargo, exposiciones controladas a bajas dosis pueden llegar a estimular la tasa fotosintética máxima. De igual forma, la radiación UV-A (315–400 nm), aplicada en breves períodos antes de la cosecha, se ha asociado con mejoras en la calidad nutricional de ciertos cultivos al favorecer la acumulación de compuestos beneficiosos [21, 22].

Dentro del PAR, las longitudes de onda azules (400–500 nm) y rojas (600–700 nm) son las más eficientes para excitar la clorofila y otros pigmentos, promoviendo la conversión de energía luminosa en energía química. La captación eficiente de esta luz no solo sustenta el crecimiento vegetal, sino que constituye la base energética de casi toda la vida en el planeta [23].

La captación de luz en las plantas es de naturaleza cuántica y se inicia en las hojas, donde los cloroplastos albergan los fotosistemas y los pigmentos necesarios para convertir fotones en energía química [24]. Estos orgánulos contienen proteínas y lípidos que organizan la clorofila, los carotenoides y otros pigmentos, optimizando la absorción de diferentes longitudes de onda. Junto a los pigmentos, las plantas disponen de fotorreceptores (fitocromos, criptocromos y fototropinas) distribuidos a lo largo de todo el tejido foliar. Estas moléculas no participan directamente en la fotosíntesis, sino que traducen información lumínica en señales bioquímicas que modulan procesos fisiológicos como la apertura estomática, la síntesis de metabolitos secundarios y el desarrollo morfológico [20].

En este contexto, la calidad de la luz para los procesos fotobiológicos puede evaluarse mediante tres parámetros fundamentales. En primer lugar, la SPF, por sus siglas en inglés describe la composición espectral de la luz dentro del rango de radiación fotosintéticamente activa, indicando qué longitudes de onda están presentes. En segundo lugar, la PPF, por sus siglas en inglés, cuantifica la cantidad de fotones PAR que inciden por unidad de área y tiempo, y se expresa en $\mu\text{mol m}^{-2} \text{s}^{-1}$. Finalmente, la integración temporal del PPF permite obtener el índice de luz diaria (DLI, por sus siglas en inglés), que representa el total de fotones

PAR recibidos por metro cuadrado por día, y se expresa en $\text{mol m}^{-2} \text{d}^{-1}$ y se calcula con la ecuación:

$$\text{DLI} = \int_0^{24\text{h}} \text{PPFD}(t) dt$$

En un estudio realizado por Azcón-Bieto (2013), se describe que la luz solar en un día despejado puede alcanzar valores de PPFD de hasta $2000 \mu\text{mol m}^{-2} \text{s}^{-1}$, mientras que una bombilla incandescente de 100 W apenas genera unos $20 \mu\text{mol m}^{-2} \text{s}^{-1}$. En otras palabras, la radiación solar puede emitir hasta 100 veces más fotones por metro cuadrado que una fuente de luz convencional [20]. Esta diferencia en PPFD resulta crucial para los procesos fotobiológicos de organismos fotosintéticos, como las plantas, que regulan su ciclo de vida desde la germinación hasta la reproducción a través de la composición espectral de la luz, la cantidad de fotones PAR incidentes y la integral diaria de dicha radiación.

A pesar de la notable diferencia entre la luz solar y la iluminación artificial en términos de intensidad y calidad espectral, se ha demostrado que las plantas pueden completar su ciclo de vida bajo fuentes artificiales de menor intensidad que la solar [24]. Esto se debe a que cada etapa del desarrollo vegetal presenta requerimientos fotobiológicos específicos, y según la especie, puede requerirse una mayor densidad de PPFD o determinadas longitudes de onda para alcanzar una alta eficiencia fotosintética.

Entre los procesos regulados por la señal lumínica, la floración es uno de los más sensibles a la calidad espectral y al fotoperiodo. *Cannabis sativa* se comporta como una especie de día corto: inicia la inducción floral cuando la noche ininterrumpida se aproxima a 12 h, mientras que fotoperiodos prolongados de 18 h o más mantienen la fase vegetativa. Esta transición está mediada por fotorreceptores del tipo fitocromo, cuya forma molecular alterna entre dos estados foto-reversibles: Pr, que absorbe fotones en torno a 660 nm (luz roja), y Pfr, que absorbe preferentemente en 730 nm (luz roja lejana) (véase Fig. 2.2). Durante la oscuridad, Pfr se reconvierte lentamente a Pr; dicho descenso en el nivel de Pfr es la señal que dispara la floración. Una breve exposición a luz roja en mitad de la noche revierte el proceso e inhibe la inducción floral, mientras que pulsos de luz roja lejana pueden restablecerla [25].

Además del cociente rojo/rojo-lejano, la cantidad diaria de fotones PAR integrada como DLI modula la tasa de crecimiento y el rendimiento floral. Estudios recientes confirman que los fotones de luz roja lejana (701–750 nm) contribuyen tanto a la fotosíntesis en condiciones de sombra como a la regulación morfofisiológica, subrayando la necesidad de equilibrar la calidad de la luz en intensidad (PPFD), DLI y composición espectral en sistemas de cultivo controlado [23].




Figura 2.2: Estado del fitocromo, Fuente: Elaboración propia (basada en una generación inicial con DALL·E, OpenAI).

En cultivos de interior, la gestión del fotoperiodo y de la intensidad lumínica es determinante para maximizar el rendimiento. Durante la fase vegetativa se emplean regímenes continuos de 18–24 h de luz, acelerando el crecimiento antes de la inducción floral. Estudios recientes concuerdan en que *Cannabis sativa* presenta una elevada demanda lumínica: el rendimiento aumenta de forma casi lineal (sin evidencia de saturación) al menos hasta $\sim 60\text{--}78 \text{ mol m}^{-2} \text{ d}^{-1}$ de DLI y valores de $\sim 1\,300\text{--}1\,800 \mu\text{mol m}^{-2} \text{ s}^{-1}$ de PPFD, siempre que CO_2 , nutrición y temperatura no sean limitantes [26, 27].

En fase vegetativa, DLIs de $20\text{--}30 \text{ mol m}^{-2} \text{ d}^{-1}$ suelen ser suficientes; al entrar en floración, valores superiores a $35 \text{ mol m}^{-2} \text{ d}^{-1}$, combinados con PPFD de $600\text{--}900 \mu\text{mol m}^{-2} \text{ s}^{-1}$ (o más), incrementan la biomasa floral y la concentración de cannabinoides [26, 27].

Una estrategia alternativa consiste en alargar ligeramente el fotoperiodo: Ahrens et al. demostraron que pasar de 12 h a 13 h de luz, con PPFD constante, eleva el DLI un 8 % y aumenta el rendimiento sin retrasar la floración [28, 29].

En síntesis, los rangos de referencia para diseñar la iluminación son:

- **Vegetativo:** $20\text{--}30 \text{ mol m}^{-2} \text{ d}^{-1}$ (DLI) y $500\text{--}700 \mu\text{mol m}^{-2} \text{ s}^{-1}$ (PPFD).
- **Floración:** $40\text{--}60 \text{ mol m}^{-2} \text{ d}^{-1}$ (DLI) y $800\text{--}1\,300 \mu\text{mol m}^{-2} \text{ s}^{-1}$ (PPFD), con posibles beneficios adicionales extendiendo el fotoperiodo una hora cuando el cultivar lo permita.

No obstante, la luz no es el único factor que condiciona el desarrollo fisiológico de las plantas; su efecto depende de otros parámetros ambientales que también regulan las funciones vitales y pueden alterar su metabolismo. Cuando cualquiera de estas variables se desvía de su rango óptimo, la planta entra en una situación de estrés abiótico. Entre los principales factores que pueden inducir este tipo de estrés se encuentran la disponibilidad de nutrientes, la temperatura, la humedad relativa y la concentración de CO_2 en el aire [30].

Dióxido de carbono CO_2

El CO_2 es un componente esencial para el proceso de fotosíntesis en las plantas, ya que actúa como sustrato en la fijación de carbono atmosférico mediante el ciclo de Calvin. Su con-

centración en el ambiente influye directamente sobre la tasa fotosintética y, por ende, sobre el crecimiento y la acumulación de biomasa. En cultivos de *Cannabis sativa*, se ha observado que el enriquecimiento con CO_2 puede aumentar significativamente la asimilación de carbono y mejorar el rendimiento general del cultivo. En condiciones controladas, concentraciones elevadas de CO_2 (por encima de 700 ppm) han mostrado incrementar la tasa fotosintética hasta en un 50% y mejorar la eficiencia en el uso del agua hasta en un 111% respecto a condiciones atmosféricas estándar [31]. Estos efectos se traducen en una mayor producción de biomasa vegetal, así como en una potenciación de la síntesis de metabolitos secundarios como cannabinoides y terpenos, especialmente durante la fase de floración. Sin embargo, el efecto del CO_2 no es independiente, ya que está modulado por variables como la temperatura, la irradiancia, la humedad relativa y la disponibilidad de nutrientes, los cuales en conjunto definen la respuesta fisiológica de la planta. Estudios recientes destacan la importancia de establecer umbrales óptimos de CO_2 para cada etapa fenológica, ya que una sobreexposición prolongada puede inducir mecanismos de aclimatación que reducen la eficiencia del proceso fotosintético a largo plazo [32]. Por ello, el monitoreo constante y la regulación automatizada de la concentración de CO_2 en ambientes controlados son prácticas esenciales en el manejo de cultivos de *Cannabis sativa*, ya que permiten maximizar la fotosíntesis y el rendimiento sin comprometer la calidad del producto final.

Temperatura

La temperatura es uno de los factores ambientales más importantes que regulan el crecimiento, el desarrollo y la actividad metabólica de las plantas. En *Cannabis sativa*, la temperatura influye directamente en procesos fisiológicos clave como la fotosíntesis, la transpiración, la respiración y la biosíntesis de compuestos secundarios. Estudios realizados bajo condiciones controladas han determinado que la tasa fotosintética máxima en *Cannabis sativa* ocurre a temperaturas cercanas a los 25 °C, mientras que valores superiores a los 35 °C provocan una disminución significativa de la eficiencia fotosintética y un aumento del estrés térmico [31]. Este tipo de estrés afecta la apertura estomática, el equilibrio hídrico, la actividad enzimática del ciclo de Calvin y la integridad de las membranas celulares. En consecuencia, se puede observar una reducción en la acumulación de biomasa, un acortamiento del ciclo vegetativo y una menor producción de metabolitos como cannabinoides y terpenos, los cuales son altamente sensibles a las condiciones térmicas durante la floración [33]. Además, las temperaturas nocturnas elevadas pueden interferir con los procesos de floración, al alterar la señalización lumínica y hormonal responsable del cambio de fase. Por otro lado, temperaturas inferiores a los 15 °C pueden ralentizar la actividad metabólica, reducir el crecimiento radicular y generar deficiencias en la absorción de nutrientes. En este contexto, mantener una temperatura en rangos óptimos y estable a lo largo del ciclo fenológico de la planta es esencial para asegurar una expresión genética eficiente y un rendimiento agronómico elevado. Por esta razón, el monitoreo continuo de la temperatura, junto con otras variables fisiológicas ambientales, es un componente fundamental en los sistemas de cultivo controlado de *Cannabis sativa*, ya que permite adaptar estrategias de manejo climático que favorezcan la productividad y la calidad del producto final.

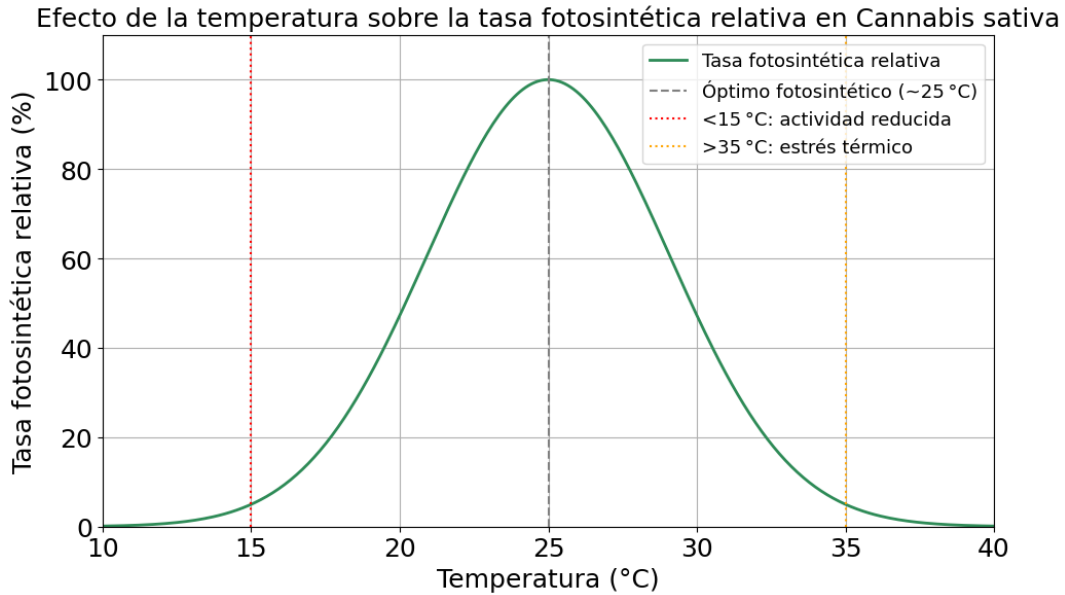


Figura 2.3: Curva de respuesta fisiológica estimada que representa el efecto de la temperatura sobre la tasa fotosintética relativa en *Cannabis sativa*. Se observa un rendimiento óptimo en torno a los 25°C, con reducciones significativas bajo condiciones térmicas subóptimas o extremas. Fuente: Los datos para graficar son obtenidos de [34][31].

Humedad

La humedad relativa del aire es una variable ambiental crítica en la fisiología de *Cannabis sativa*, ya que regula el flujo de vapor de agua entre la hoja y la atmósfera, condicionando tanto la transpiración como el intercambio gaseoso a través de los estomas. Cuando la humedad relativa es baja, la atmósfera se torna más demandante, lo que incrementa la pérdida de agua por transpiración y lleva al cierre estomático como mecanismo de defensa. Esto reduce la captación de CO₂ y, en consecuencia, limita la tasa fotosintética, el crecimiento y la acumulación de biomasa. En cambio, una humedad excesivamente alta puede restringir la transpiración y favorecer condiciones propensas a enfermedades fúngicas, especialmente durante la floración, etapa en la que los tejidos florales son altamente sensibles. Según Chaparro Suárez [34], en estudios realizados bajo condiciones de invernadero, se observó que mantener la humedad relativa en rangos óptimos (55–65 % en fase vegetativa y 45–55 % en floración) permitió no solo maximizar la eficiencia fotosintética, sino también mejorar la producción de cannabinoides como el THC y el CBD. Estos resultados confirman que la humedad no solo afecta la fisiología básica de la planta, sino también la síntesis de metabolitos secundarios, esenciales para la calidad del producto final. En el mapa de calor de la figura 2.4 se evidencia cómo la humedad relativa interactúa directamente con la temperatura; las zonas en azul oscuro indican condiciones óptimas; las zonas más claras muestran condiciones fisiológicas desfavorables. La zona entre 55 y 65 % y entre 24 y 26 °C muestra como aumenta la eficiencia fisiológica estimada.

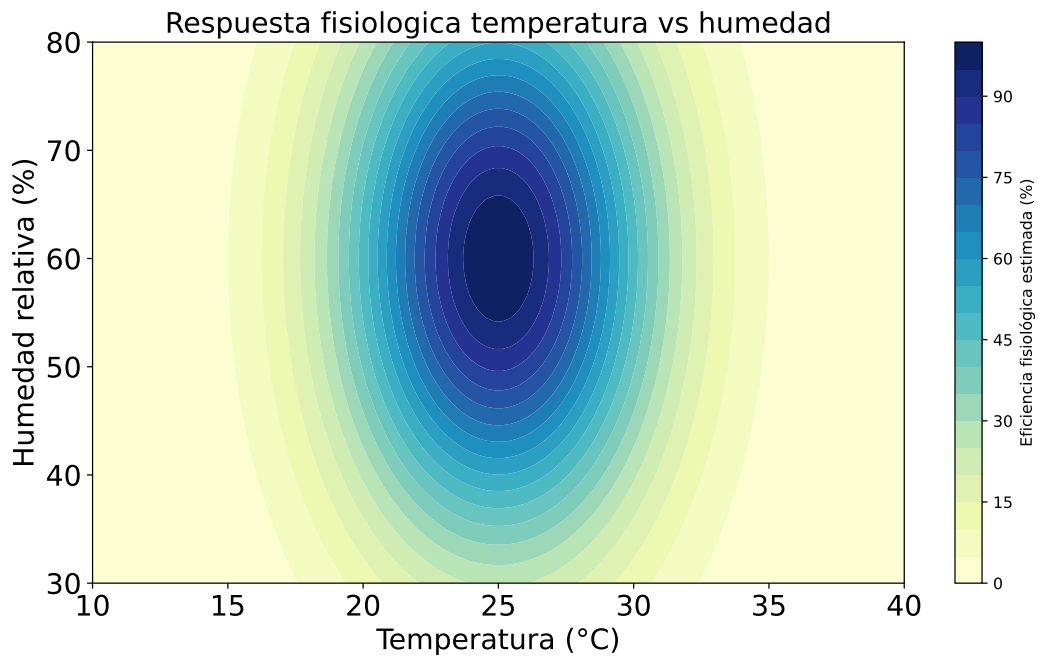


Figura 2.4: Mapa de calor: estimación de la eficiencia fisiológica de Cannabis sativa en función de la interacción entre temperatura y humedad relativa en etapas vegetativas. Fuente: Los datos para graficar son obtenidos de [34]

Calidad de agua y nutrientes

La calidad del agua y la solución nutritiva utilizada en cultivos de Cannabis sativa es un factor determinante para alcanzar un desarrollo fisiológico óptimo y una alta productividad. En cultivos hidropónicos o en sustratos inertes bajo condiciones controladas, el agua actúa como medio de transporte de nutrientes esenciales y también como regulador térmico, por lo que su composición fisicoquímica debe mantenerse dentro de rangos específicos. Uno de los parámetros fundamentales es el pH, ya que influye directamente en la disponibilidad de nutrientes y en la absorción radicular. En Cannabis sativa, se recomienda un rango de pH entre 5.5 y 6.5, dependiendo de la fase fenológica, para garantizar la solubilidad adecuada de macro y micronutrientes como nitrógeno, fósforo, potasio, hierro y manganeso [35]. Valores fuera de este rango pueden generar deficiencias o toxicidades, incluso cuando los nutrientes están presentes en concentraciones suficientes.

Otro parámetro esencial es la conductividad eléctrica (EC), que mide la concentración total de sales disueltas en la solución nutritiva. La EC es un indicador indirecto de la disponibilidad de nutrientes, y en el caso de Cannabis sativa, los valores óptimos oscilan entre 1.2 y 2.5 mS/cm, dependiendo de la etapa de desarrollo [36]. Niveles demasiado bajos pueden limitar el crecimiento por deficiencia nutricional, mientras que una EC excesiva puede causar estrés osmótico, inhibir la absorción de agua y provocar acumulación de sales en la rizosfera, lo que afecta negativamente la fisiología de la planta y reduce la calidad del producto final.

Por otro lado, la temperatura del agua también juega un papel crucial en el metabolismo vegetal. Temperaturas por debajo de los 18 °C pueden disminuir la actividad enzimática y ralentizar el transporte de nutrientes, mientras que temperaturas superiores a 25 °C favorecen el crecimiento de patógenos radiculares como *Pythium* spp., reducen la solubilidad de oxígeno y pueden inducir estrés térmico en las raíces [37]. El rango óptimo para la temperatura de la

solución nutritiva en sistemas de cultivo de *Cannabis sativa* se encuentra entre 18 y 22 °C, asegurando una adecuada oxigenación y eficiencia en la absorción de nutrientes.

Mantener un equilibrio preciso entre estos tres parámetros es fundamental para garantizar un entorno radicular saludable y una absorción eficiente de nutrientes. En este sentido, el monitoreo constante mediante sensores específicos y el uso de soluciones nutritivas ajustadas según la fase de crecimiento permiten optimizar el rendimiento y la calidad del cultivo. Además, la calidad inicial del agua de riego debe evaluarse regularmente, ya que la presencia de contaminantes, metales pesados o un exceso de bicarbonatos puede interferir con la formulación nutritiva y alterar el pH del sistema. Por lo tanto, el manejo del agua en cultivos de *Cannabis sativa* no debe considerarse un aspecto secundario, sino una pieza clave en el diseño de estrategias de nutrición vegetal de precisión.




Figura 2.5: Variables ambientales que afectan la fisiología de *Cannabis sativa*. Fuente: Elaboración propia, (basado en una generación inicial con DALL-E OpenAi)

Estas variables fisiológicas ambientales (véase Figura 2.5) actúan de manera sinérgica para regular la fotosíntesis, la transpiración y la floración en *Cannabis sativa*. Mantenerlas dentro de rangos óptimos de forma continua supone un desafío técnico. Por ello, es esencial integrar sistemas de IoT que no solo monitoreen en tiempo real todas las VFA de manera simultánea, sino que también permitan el control automatizado de actuadores para corregir inmediatamente cualquier desviación. Al combinar redes de sensores con arquitecturas de microservicios y protocolos de comunicación robustos, estos sistemas facilitan la recolección de datos ambientales, mientras que plataformas de análisis predicen desequilibrios y optimizan las estrategias agronómicas. De este modo, es posible garantizar condiciones estables y eficientes durante todo el ciclo vegetativo y reproductivo, maximizando el potencial productivo y la calidad del cultivo.

Propagación de Cannabis Sativa

El cannabis sativa puede propagarse por semilla (reproducción sexual) o de forma vegetativa mediante esquejes (clonación). La propagación por esquejes consiste en tomar porciones de la planta madre (típicamente ramas tiernas) que enraízan y generan nuevas plantas genéticamente idénticas a la madre [38]. Esta técnica ha sido fundamental en el cultivo de cannabis psicoactivo (marihuana) bajo techo, ya que muchas variedades dioicas de alto THC no cuentan con semillas genéticamente uniformes debido a la falta de líneas puras avanzadas [39]. En ausencia de semilla “true-to-type” (verdadera a la variedad), los productores han dependido tradicionalmente de esquejes de una planta madre para mantener la pureza genética y la uniformidad en el cultivo [39]. En los últimos años, con la legalización y el auge del mercado del cannabis medicinal y recreativo, se ha intensificado la investigación en métodos de propagación eficientes que garanticen consistencia en el rendimiento y la calidad de los cultivos [38].

Los esquejes producen plantas clónicamente idénticas a la madre, es decir, comparten el mismo genotipo, lo que resulta en poblaciones muy uniformes en características de crecimiento y composición química [39].

2.2. Principios del cultivo hidropónico

El cultivo hidropónico es un sistema de producción vegetal sin suelo, en el cual las raíces de las plantas crecen en una solución nutritiva rica en los elementos esenciales disueltos en agua, o en sustratos inertes como fibra de coco, perlita o lana de roca [35]. En este tipo de cultivo, el suelo es reemplazado por un sistema que suministra directamente a las raíces los nutrientes, el oxígeno y el agua en concentraciones reguladas. Esta técnica se ha expandido ampliamente en agricultura intensiva y cultivos de alto valor debido a su eficiencia en el uso del agua, el control de enfermedades del suelo y la posibilidad de producción en espacios reducidos o ambientes sin condiciones edafológicas favorables.

Una de las principales ventajas del cultivo hidropónico frente al cultivo en suelo es el mejor aprovechamiento de agua y nutrientes, lo cual reduce el desperdicio de insumos y mejora la sostenibilidad del sistema. Asimismo, al eliminar la variabilidad del suelo, se puede lograr una mayor uniformidad entre plantas. Sin embargo, estos beneficios están sujetos a un manejo técnico riguroso, ya que la ausencia de un buffer natural como el suelo vuelve al sistema más sensible a fluctuaciones en parámetros como el pH, la conductividad eléctrica o la temperatura del agua.

En el caso de Cannabis sativa, la hidroponía ha demostrado mejorar tanto el rendimiento en biomasa como el perfil de cannabinoides, permitiendo ajustes nutricionales más directos según la fase fenológica [36]. También se ha evidenciado una mayor uniformidad entre plantas, lo cual es fundamental para estándares de calidad en producción comercial y medicinal [40]. Derivado de ello, resulta pertinente describir técnicas hidropónicas empleadas en sistemas de cultivo sin suelo. Las cuales se describen a continuación:

Sistema NFT (Nutrient Film Technique)

El sistema NFT es una técnica hidropónica en la que las raíces de las plantas se desarrollan dentro de canales inclinados por los que circula una delgada lámina de solución nutritiva figura 2.6. Esta solución, enriquecida con los elementos minerales esenciales, es bombeada desde un reservorio, fluye por gravedad a lo largo de los canales y retorna al tanque de almacenamiento para su recirculación. Las raíces permanecen parcialmente sumergidas, lo que facilita el acceso simultáneo a nutrientes y oxígeno sin la necesidad de un sustrato sólido.

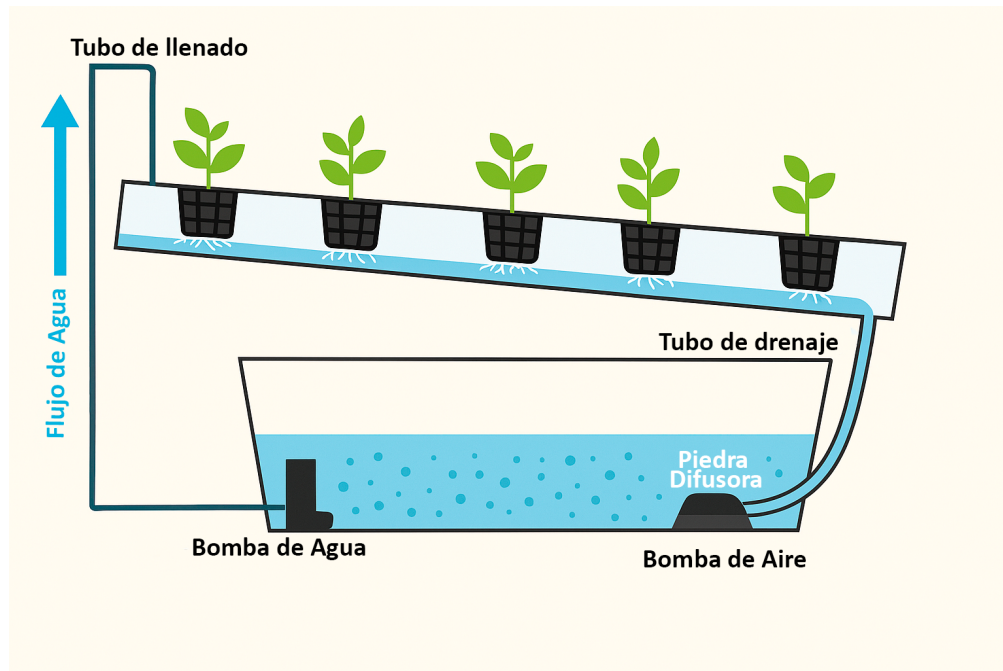


Figura 2.6: Esquema del sistema hidropónico NFT, Fuente: Elaboración propia, basado en una generación inicial con DALL-E, OpenAI.

Este tipo de sistema ha sido ampliamente utilizado en cultivos hortícolas de ciclo corto, como lechuga, rúgula y espinaca, debido a su estructura modular y al uso eficiente de recursos. En el caso de *Cannabis sativa*, el sistema NFT ha sido empleado para estudiar la absorción de nutrientes y su relación con la concentración de metabolitos secundarios bajo condiciones de cultivo controladas [41]. En estos entornos, el NFT permite la medición directa de parámetros como el pH, la conductividad eléctrica y la temperatura de la solución, variables relevantes para evaluar la respuesta fisiológica de las plantas.

Las condiciones de operación de este sistema dependen de la continuidad del flujo de solución nutritiva, ya que la falta de retención hídrica en los canales hace que las raíces sean sensibles a interrupciones prolongadas. La morfología del canal, la inclinación, la velocidad de flujo y la aireación de la solución son factores que influyen en la funcionalidad del sistema.

Sistema DWC (Deep Water Culture)

El sistema DWC es una modalidad hidropónica en la cual las raíces de las plantas se sumergen directamente en una solución nutritiva aireada. Esta solución se mantiene en tanques o recipientes, y se oxigena de manera continua mediante el uso de bombas de aire y difuso-

res, con el objetivo de evitar condiciones anaeróbicas y favorecer el metabolismo radicular. Las plantas se sostienen en estructuras flotantes o tapas con perforaciones donde se insertan macetas o soportes. La figura 2.7 muestra un esquema básico de DWC.

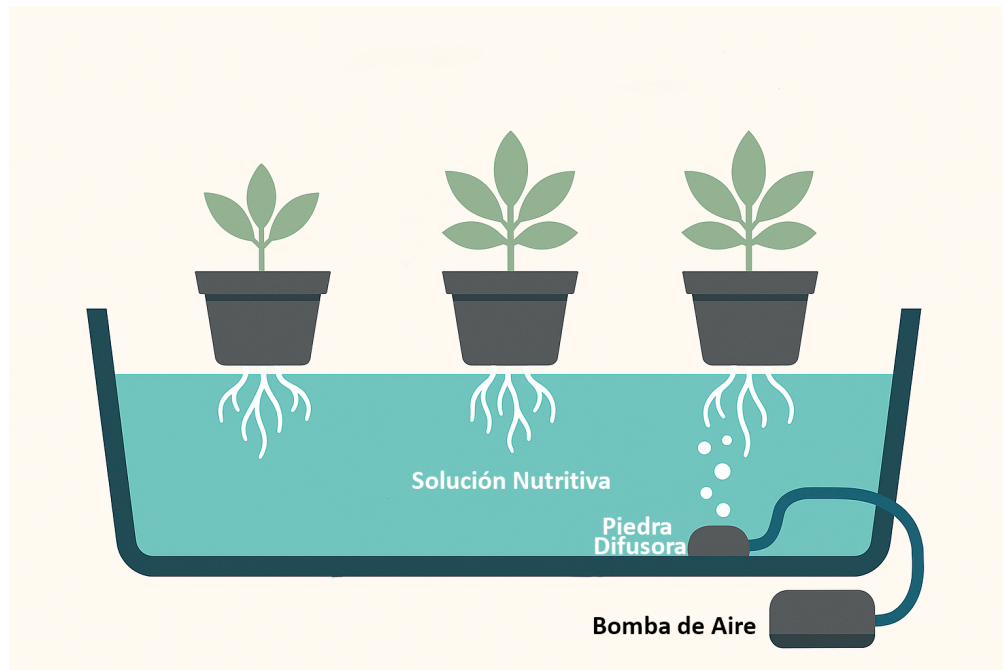


Figura 2.7: Esquema del sistema de cultivo hidropónico DWC. Fuente: Elaboración propia, basado en una generación inicial con DALL-E, OpenAI.

El sistema DWC ha sido implementado en la producción de cultivos de hoja como lechuga, acelga y mostaza, y se ha utilizado también en estudios experimentales con *Cannabis sativa* para analizar el comportamiento fisiológico de las plantas en distintas etapas fenológicas [42]. Este sistema permite un acceso constante a nutrientes disueltos, y su configuración facilita el muestreo y la manipulación de la solución para análisis de variables fisicoquímicas.

Entre los parámetros críticos de operación en sistemas DWC se encuentran el pH, la conductividad eléctrica y la temperatura de la solución nutritiva. Se ha documentado que la temperatura influye directamente en la solubilidad del oxígeno disuelto en el agua, un factor esencial para la salud radicular. Temperaturas elevadas disminuyen la solubilidad del oxígeno, lo que puede favorecer condiciones anaeróbicas y facilitar la proliferación de microorganismos patógenos como *Pythium* spp., especialmente en soluciones estancadas o mal oxigenadas. Gracias a su diseño, el sistema DWC facilita el control y muestreo frecuente de estas variables fisicoquímicas, razón por la cual ha sido ampliamente empleado tanto en entornos de cultivo comercial como en investigaciones fisiológicas con *Cannabis sativa* y otros cultivos de hoja [43].

A partir del análisis de las características operativas y aplicaciones experimentales de los sistemas NFT y DWC, se presenta a continuación una tabla comparativa que resume sus principales diferencias y similitudes en términos de configuración, manejo de variables fisicoquímicas y aplicabilidad en cultivos de *Cannabis sativa*.

Tabla 2.1: Comparación técnica entre los sistemas hidropónicos NFT y DWC

Criterio	NFT	DWC
Principio de funcionamiento	Flujo continuo de una lámina delgada de solución nutritiva sobre raíces parcialmente expuestas	Raíces suspendidas en solución nutritiva aireada de forma continua
Medio de soporte	Canales inclinados sin sustrato (raíces libres)	Recipientes con plantas en cestas; raíces sumergidas
Oxigenación	Aérea parcial; oxigenación facilitada por exposición al aire y flujo	Requiere oxigenación activa mediante bomba de aire y difusor
Uso en cannabis	Evaluación de nutrición y control de variables en ambiente controlado [44]	Evaluación de fases vegetativa y reproductiva, manejo nutricional [40]
Cultivos frecuentes	Lechuga, rúcula, hierbas de ciclo corto	Lechuga, mostaza, cannabis, tomate
Monitoreo necesario	Flujo, pH, EC, temperatura de solución	Oxígeno disuelto, pH, EC, temperatura
Sensibilidad a fallos	Alta; interrupción del flujo puede deshidratar raíces rápidamente	Media; fallo en oxigenación puede causar hipoxia en raíces
Ventajas	Bajo uso de agua y nutrientes, recirculación sencilla	Configuración simple, contacto continuo con nutrientes
Limitaciones	Requiere flujo constante; diseño hidráulico preciso	Requiere control estricto de oxigenación y temperatura del agua

El análisis evidencia que el sistema de mejor desempeño para esta especie es el DWC, dado que el uso de cestas en tanques permite un desarrollo radicular libre y más robusto. Además, este sistema resulta particularmente adecuado para plantas en etapa reproductiva, siempre que se garantice un control más estricto de la oxigenación y de la temperatura del agua en comparación con su homólogo NFT.

2.3. Tecnologías de monitoreo y control

Dado que las VFA condicionan directamente la respuesta fisiológica de *Cannabis sativa*, es fundamental contar con mecanismos que permitan su monitoreo continuo y confiable. En este sentido, el uso de tecnologías para la recolección sistemática de datos ambientales se ha vuelto una práctica común en agricultura. El sistema de monitoreo más común en agricultura, así como en aplicaciones meteorológicas y de control ambiental, es el uso de data loggers. Estos dispositivos destacan por su alta autonomía energética, al funcionar mediante baterías o sistemas fotovoltaicos, y por su capacidad para registrar variables ambientales de forma local sin necesidad de conectividad continua. Gracias a su memoria interna, pueden almacenar datos durante largos periodos, y su naturaleza programable permite ajustar la frecuencia de muestreo según los requerimientos del estudio. Estas características los hacen ideales para investigaciones retrospectivas y análisis históricos en ciencia de datos, especialmente en sistemas de cultivo donde la trazabilidad y la estabilidad ambiental son críticas [45].

A pesar de su amplia adopción, los sistemas basados en data loggers presentan limitaciones que condicionan su aplicabilidad en escenarios agrícolas donde se requiere una supervisión constante. Su funcionamiento desconectado impide el monitoreo en tiempo real, dificultando la detección temprana de fallos técnicos o eventos críticos en el entorno de cultivo. Además, la necesidad de descargar manualmente los datos y el riesgo de pérdida de información por saturación de memoria representan desafíos operativos relevantes en contextos donde la continuidad de los registros es esencial [45].

Ante estas restricciones, las tecnologías basadas en IoT son una alternativa emergente y disruptiva para la recolección automatizada de datos en sistemas agrícolas. Aunque su implementación enfrenta retos importantes en términos de conectividad, interoperabilidad, gestión energética y seguridad, su arquitectura distribuida y su capacidad para generar flujos de datos continuos abren nuevas posibilidades para el análisis avanzado. En particular, el IoT permite capturar grandes volúmenes de datos multivariantes que resultan fundamentales para la aplicación de modelos estadísticos, análisis predictivos y técnicas de aprendizaje profundo (deep learning) orientadas a la comprensión del crecimiento vegetal. En este contexto, la siguiente sección aborda los componentes, principios de funcionamiento y aplicaciones del IoT en cultivos de Cannabis sativa, con énfasis en su integración a sistemas de monitoreo ambiental y fenotipado computacional.

2.3.1. Internet de las cosas (IoT)

El IoT representa un paradigma tecnológico que permite la interconexión de dispositivos físicos mediante redes de comunicación, facilitando la recopilación, transmisión y procesamiento continuo de datos en tiempo real. En el ámbito agrícola, esta tecnología ha dado lugar al desarrollo de sistemas inteligentes de monitoreo y control que integran sensores, actuadores, unidades de procesamiento y plataformas en la nube para supervisar variables ambientales clave. Aplicado a la agricultura, el IoT permite registrar y gestionar todo tipo de parámetros relevantes en ese contexto, con una granularidad temporal que no es posible alcanzar con sistemas tradicionales. Además, su arquitectura distribuida facilita la implementación de algoritmos de automatización para el ajuste dinámico de condiciones de cultivo, lo cual resulta particularmente relevante en ambientes controlados, donde la estabilidad fisiológica de la planta depende de pequeños márgenes de variación.

2.3.2. Protocolos de comunicación

En el contexto agrícola, la arquitectura de comunicación del IoT permite la integración de dispositivos físicos como sensores, actuadores y sistemas de control, conectados mediante protocolos específicos que operan en diferentes capas de red. Esta pila de protocolos, estructurada desde la capa física hasta la aplicación, es fundamental para garantizar el flujo confiable de datos desde el entorno de cultivo hasta las plataformas de análisis en la nube. En la capa física, se utilizan tecnologías de transmisión como LoRa, ZigBee, Wi-Fi y NB-IoT, que determinan el alcance, la velocidad de transmisión y el consumo energético de los nodos sensores. La elección de la tecnología depende de factores como la topografía del cultivo, la densidad de sensores y la necesidad de autonomía energética [46].

En la capa de enlace de datos, protocolos como IEEE 802.15.4 (utilizado en ZigBee) o enlaces punto a punto gestionan el acceso al medio compartido y corrigen errores de transmisión.

Esta capa es crítica para asegurar que los datos capturados por sensores de temperatura, humedad, CO₂ o conductividad eléctrica no se pierdan o corrompan antes de llegar al siguiente nivel. La capa de red, por su parte, es responsable de enrutar los paquetes hacia el destino adecuado, y se basa principalmente en IPv6 en soluciones modernas, permitiendo una dirección única para cada nodo sensor, lo cual es esencial para sistemas de gran escala en ambientes agrícolas controlados [47].

En la Tabla 2.2 se presenta una comparación entre las dos principales tecnologías utilizadas para la transmisión de datos en redes de sensores con soporte para IPv6: 6LoWPAN y WiFi. Si bien WiFi ofrece una implementación más directa y mayor velocidad de transmisión, 6LoWPAN se adapta mejor a entornos agrícolas de bajo consumo y gran escala, gracias a su eficiencia energética y capacidad de formar redes en malla.

Tabla 2.2: Comparación entre 6LoWPAN e IPv6 sobre WiFi en redes IoT para agricultura

Característica	6LoWPAN (sobre IEEE 802.15.4)	WiFi (IEEE 802.11)
Soporte para IPv6	Requiere compresión de encabezado y adaptación del protocolo mediante 6LoWPAN	Soporte nativo de IPv6 sin necesidad de compresión
Consumo energético	Muy bajo (ideal para dispositivos a batería en campo)	Alto (menos eficiente para nodos energéticamente limitados)
Alcance típico	10–100 m (con posibilidad de formar redes en malla)	30–100 m (dependiente de obstáculos y potencia de transmisión)
Tasa de datos	Hasta 250 kbps	Desde 1 Mbps (WiFi b/g/n)
Topología de red	Redes malladas con enrutamiento RPL	Estrella (cliente–punto de acceso)
Complejidad de implementación	Mayor (requiere stack 6LoWPAN, RPL y border router)	Menor (conexión directa a red IPv6)
Escalabilidad	Alta para redes densas de sensores	Limitada por el número de conexiones simultáneas al punto de acceso
Costo del hardware	Bajo (módulos IEEE 802.15.4 económicos)	Medio (WiFi integrado en módulos como ESP32)
Entornos ideales	Cultivos extensivos, invernaderos grandes, monitoreo distribuido	Cámaras de crecimiento, laboratorios, invernaderos pequeños

La capa de transporte utiliza generalmente protocolos como UDP (User Datagram Protocol), que favorece la eficiencia energética al no requerir establecimiento de conexión, aunque en algunos casos se emplea TCP (Transmission Control Protocol) cuando se prioriza la fiabilidad en la transmisión. En la capa de sesión y presentación, se gestionan tareas como la compresión de datos, la autenticación y la codificación, facilitando la interoperabilidad

entre diferentes dispositivos y plataformas. Finalmente, en la capa de aplicación, destacan protocolos como MQTT (Message Queuing Telemetry Transport) y CoAP (Constrained Application Protocol), que permiten una comunicación ligera y asíncrona entre nodos sensores y servidores remotos, adecuados para redes con limitaciones de ancho de banda y potencia de cómputo [47].

En sistemas de monitoreo ambiental aplicados a la agricultura de precisión, es común la implementación de protocolos de comunicación a nivel de aplicación que permitan la transmisión eficiente de datos entre dispositivos y plataformas remotas. MQTT y WebSocket representan dos enfoques diferenciados. MQTT emplea un modelo de comunicación basado en publicación y suscripción mediado por un broker, lo que permite la decoupling entre productores y consumidores de datos. Su diseño contempla el uso de paquetes con cabeceras reducidas y soporte para niveles de calidad de servicio (QoS), lo cual favorece su implementación en redes con restricciones de ancho de banda y dispositivos con capacidades computacionales limitadas. En contraste, WebSocket establece una conexión persistente y bidireccional entre cliente y servidor sobre TCP, permitiendo el intercambio continuo de mensajes sin la necesidad de solicitudes repetidas. Esta característica es aprovechada principalmente en sistemas que requieren sincronización en tiempo real entre interfaces de usuario y fuentes de datos. La Tabla 2.3 resume las principales diferencias entre ambos protocolos en el contexto de redes IoT agrícolas.

Tabla 2.3: Comparación entre MQTT y WebSocket en aplicaciones IoT para agricultura

Característica	MQTT	WebSocket
Modelo de comunicación	Publicación-suscripción (broker central)	Cliente-servidor (conexión directa bidireccional)
Consumo de recursos	Bajo (ideal para sensores con CPU y RAM limitadas)	Medio-alto (requiere más recursos)
Eficiencia en red	Alta, mensajes ligeros con bajo overhead	Moderada, requiere cabeceras más grandes y conexión persistente
Latencia	Muy baja, especialmente con QoS	Baja, adecuado para aplicaciones en tiempo real
Uso típico	Telemetría, sensores IoT, redes LPWAN o WiFi	Interfaces web interactivas, dashboards en tiempo real
Persistencia de conexión	No persistente; puede reconectarse automáticamente	Conexión persistente TCP
Soporte nativo en navegadores	No, requiere librerías específicas del lado cliente	Sí, ampliamente soportado en navegadores modernos

La correcta integración de esta pila de comunicación en sistemas IoT agrícolas permite capturar grandes volúmenes de datos ambientales con alta frecuencia, lo cual es esencial para el modelado fisiológico de cultivos como Cannabis sativa. Variables como temperatura, humedad relativa, concentración de CO₂, pH, electroconductividad y espectro lumínico pueden ser registradas y analizadas en tiempo real, facilitando estrategias avanzadas de manejo

climático, control nutricional y evaluación del estrés abiótico. Además, la estandarización de protocolos y la implementación de modelos de comunicación jerárquicos (edge-cloud) permiten reducir la latencia y distribuir la carga computacional entre nodos locales y servidores remotos, potenciando aplicaciones basadas en inteligencia artificial para la predicción del crecimiento vegetal y la optimización de insumos agrícolas.

2.3.3. Automatización y lógica de control

La automatización y el control en la agricultura moderna constituyen pilares fundamentales en la transición hacia sistemas de producción más eficientes, sostenibles y precisos. Estos conceptos, tradicionalmente asociados a la industria, han encontrado una creciente aplicación en el sector agropecuario gracias al desarrollo de tecnologías accesibles como la microelectrónica, la robótica y el IoT. Automatizar un proceso agrícola implica dotarlo de la capacidad de operar sin intervención humana directa, mientras que el control se refiere a la regulación activa de variables críticas (como temperatura, humedad, luz o nutrientes) mediante la retroalimentación de datos sensorizados. Un sistema de automatización agrícola se compone de sensores que registran variables relevantes, un PLC o microcontrolador encargado de ejecutar algoritmos de decisión, actuadores que llevan a cabo las acciones físicas correspondientes y sistemas de comunicación que permiten la transmisión de datos entre sensores, actuadores o hacia plataformas en la nube [48]. La tabla 2.4 presenta la descripción de cada componente y su función dentro de un sistema de automatización agrícola.

Tabla 2.4: Componentes de un sistema de automatización agrícola

Componente	Función
Sensores	Capturan variables ambientales o fisiológicas como temperatura, humedad, luminosidad, CO ₂ o estado hídrico del sustrato.
PLC o microcontrolador (Ej: Arduino, ESP32)	Unidad de control que ejecuta el algoritmo de decisión. Recibe datos de sensores, los procesa y activa actuadores según parámetros definidos.
Actuadores	Dispositivos que ejecutan acciones físicas como válvulas (riego), relés (luz o ventilación), bombas o motores.
Sistema de comunicación	Transfiere datos entre sensores, controlador y/o interfaz de usuario. Puede ser por cable (I2C, RS-485) o inalámbrico (Wi-Fi, LoRa).

En el contexto del cultivo de *Cannabis sativa*, el cual exige un manejo riguroso de las condiciones ambientales para optimizar tanto el crecimiento como la calidad del producto final, los sistemas automatizados han demostrado ser herramientas altamente efectivas [49]. Diversos estudios recientes han implementado soluciones de automatización como parte de estrategias de monitoreo y optimización, demostrando su aplicabilidad práctica y el valor de integrar tecnologías de control inteligente en entornos agrícolas [50–52].

Magagnini et al demostraron que pequeñas variaciones en el espectro y la intensidad de la luz afectan significativamente la morfología y el contenido cannabinoide de *Cannabis sativa*.

Su estudio empleó tres tratamientos lumínicos controlados por sistemas automatizados, lo que permitió mantener condiciones constantes de fotoperiodo y PPFD durante todo el ciclo de crecimiento [53]. Adicionalmente, Rossi et al. (2022) desarrollaron una plataforma basada en visión computacional 3D y sensores ambientales para ajustar dinámicamente el riego en cultivos de tomate. Su algoritmo de control consideraba el estado hídrico del suelo y la morfología de la planta, permitiendo una respuesta diferenciada en tiempo real. Este enfoque puede ser adaptado al cultivo de cannabis para gestionar variables como volumen de riego o aporte de fertilizantes en función del crecimiento efectivo [54].

2.3.4. Sensores en agricultura controlada

En la agricultura de ambiente controlado, los sensores juegan un papel fundamental al permitir la recolección continua de datos ambientales y fisiológicos relevantes para el desarrollo del cultivo. Variables como la temperatura, la humedad relativa, el CO₂, el pH, la conductividad eléctrica y la intensidad de luz pueden ser monitoreadas en tiempo real para asegurar condiciones óptimas en entornos como invernaderos o cultivos hidropónicos [55]. En el cultivo de *Cannabis sativa*, el control preciso del pH y la EC es crítico para mantener el equilibrio nutricional a lo largo de las fases vegetativa y reproductiva [47].

Asimismo, los sensores de radiación PAR, que utilizan fotodiodos calibrados, permiten evaluar la eficiencia de la iluminación artificial, especialmente en cultivos donde se emplean tecnologías LED con espectros ajustables [56]. Este control espectral es especialmente relevante para *Cannabis*, donde el espectro de luz influye directamente en la acumulación de metabolitos secundarios como los cannabinoides [57].

En investigaciones más recientes se han incorporado sensores ópticos avanzados, como los basados en cámaras multiespectrales o hiperespectrales para el monitoreo no invasivo del estado fisiológico de la planta. Estas tecnologías permiten detectar respuestas al estrés abiótico y cambios en la composición bioquímica del tejido vegetal sin dañar la planta [58]. En el caso de sensores montados en hoja, como los propuestos en entornos de agricultura de precisión, se puede evaluar en tiempo real la transpiración y el estado hídrico, mejorando la toma de decisiones en sistemas automatizados [55].

Finalmente, la integración de esta infraestructura sensorica con plataformas IoT y modelos de inteligencia artificial permite la implementación de sistemas de control adaptativos y predictivos, fundamentales para la gestión climática de precisión en cultivos de alto valor como el cannabis medicinal [47].

En la tabla 2.5 se presenta un listado de los sensores más empleados en agricultura controlada, junto con el principio de funcionamiento en el que se basan. Esta información facilita la identificación de las ventajas y limitaciones de cada dispositivo, así como una interpretación más precisa de los datos obtenidos en condiciones específicas de cultivo.

Tabla 2.5: Tipos de sensores utilizados en agricultura controlada

Variable medida	Tipo de sensor	Tecnología utilizada
Temperatura y HR	Sensor combinado (DHT22, SHT31)	Sensor capacitivo y digital de semiconductores
CO ₂	Sonda de infrarrojo no dispersivo (NDIR)	Sensor electroquímico óptico (NDIR)
pH	Sonda de pH digital	Electrodos de vidrio sensibles a H ⁺
Conductividad eléctrica (EC)	Sonda EC	Electrodos de acero inoxidable o grafito
Luz PAR	Sensor cuántico o multiespectral	Fotodiodos calibrados en 400–700 nm
Oxígeno disuelto	Sonda óptica DO	Fluorescencia óptica (luminescencia)
Estado hídrico / transpiración	Sensor flexible en hoja	Microelectrónica impresa / hidrogel / sensores capacitivos

2.3.5. Infraestructura en la nube

El uso de sensores avanzados y dispositivos portátiles permite monitorear de forma continua parámetros ambientales como la temperatura, la humedad, la calidad del aire y la iluminación. El éxito de este tipo de monitoreo depende de varios factores clave para su funcionamiento, siendo los servicios en la nube uno de los más relevantes.

El almacenamiento eficiente de los datos se vuelve un desafío cuando se manejan múltiples conexiones y grandes volúmenes de información. Dado que el análisis y la toma de decisiones en agricultura de precisión dependen en gran medida de estos datos, contar con una solución robusta de gestión es esencial.

Los servicios en la nube ofrecen soluciones escalables y flexibles, como la Infraestructura como Servicio (IaaS), donde un proveedor privado suministra recursos de infraestructura tecnológica (TI) que pueden emplearse para gestionar conexiones, procesar, almacenar y visualizar datos, simplemente mediante una conexión a internet. Estos sistemas pueden ir desde implementaciones básicas, como un servidor montado sobre una Raspberry Pi, hasta infraestructuras complejas que integran máquinas virtuales con alta capacidad de procesamiento y almacenamiento, como Amazon Web Services (AWS) u otras plataformas similares.

La forma en que se estructuran los datos influye directamente en la eficiencia de las arquitecturas dedicadas a su gestión. Ya sea mediante bases de datos con tablas relacionales o con estructuras no relacionales, la modularización del sistema basada en microservicios permite escalar y mantener la solución de forma más efectiva a lo largo del tiempo. Los microservicios son unidades funcionales independientes que ejecutan tareas específicas dentro de aplicaciones más amplias. A diferencia de las arquitecturas monolíticas, los sistemas basados en microservicios son más fáciles de mantener y actualizar, ya que cada componente puede desarrollarse, desplegarse o modificarse de forma independiente. Estos servicios se comunican

entre sí a través de distintos protocolos, que abarcan desde capas físicas como TCP/IP, capas de transporte como TCP o UDP, hasta capas de aplicación como WebSocket o MQTT, de gran interés en sistemas IoT.

Dentro de esta arquitectura, las bases de datos cumplen un rol fundamental al actuar como servicios especializados para el almacenamiento y recuperación de información. Cada microservicio puede gestionar su propia base de datos, optimizada según su función particular, lo que refuerza la independencia de los componentes y mejora la eficiencia general del sistema. Dependiendo de los requerimientos, se pueden emplear bases de datos relacionales, como MySQL o PostgreSQL, o bases de datos NoSQL, como MongoDB, especialmente útiles para manejar estructuras de datos heterogéneas, de gran volumen o de series temporales, como las que se generan a partir de sensores y plataformas de monitoreo agrícola.

2.4. Iluminación en la fase vegetativa temprana

La luz es uno de los factores ambientales más determinantes durante las primeras semanas vegetativas de *Cannabis sativa*, etapa en la que se definen la arquitectura inicial y el potencial de rendimiento del cultivo [53, 59]. En sistemas *indoor* se acostumbra trabajar con fotoperiodos extendidos (18 h luz / 6 h oscuridad) y niveles de intensidad moderados–altos, típicamente entre 200 y 600 $\mu\text{mol m}^{-2}\text{s}^{-1}$ de PPFD [60], con el fin de acelerar el establecimiento y aumentar el número de nudos por planta.

Para evaluar y diseñar dicha iluminación es necesario cuantificar no solo la energía irradiada, sino también la cantidad de fotones efectivos para la fotosíntesis. La magnitud de partida es la distribución de potencia espectral, SPD ($\text{W m}^{-2}\text{nm}^{-1}$), que describe la potencia radiante por unidad de superficie y por longitud de onda. A partir de ella se obtiene el flujo fotónico espectral, SPF ($\mu\text{mol m}^{-2}\text{s}^{-1}\text{nm}^{-1}$), dividiendo la potencia E_λ por la energía de un fotón y normalizando a moles:

$$\Phi_{p,\lambda} = \frac{E_\lambda \lambda}{h c N_A} \times 10^6, \quad (2.1)$$

donde λ es la longitud de onda en metros, h la constante de Planck, c la velocidad de la luz y N_A el número de Avogadro [61]. Integrando $\Phi_{p,\lambda}$ entre 400 y 700 nm se obtiene la densidad de flujo fotónico fotosintético (PPFD):

$$\text{PPFD} = \int_{400}^{700} \Phi_{p,\lambda} d\lambda = 0.008359 \int_{400}^{700} E_\lambda \lambda d\lambda, \quad (2.2)$$

ecuación que condensa las constantes físicas en el factor 0.008359 para un paso de 1 nm [62]. A diferencia de su análogo fotométrico el lumen o la iluminancia, que pondera la radiación con la curva de respuesta visual $V(\lambda)$, PPFD cuenta fotones sin sesgo espectral, de modo que dos lámparas con igual lux pueden diferir hasta un 50 % en PPFD. Esta discrepancia justifica el uso de métricas fotónicas en agronomía y fisiología vegetal.

La Figura 2.8 ilustra esta diferencia mostrando el espectro solar extra-atmosférico expresado como SPD y como SPF: al multiplicar por λ en la ecuación (2.1), los fotones rojos ganan peso relativo y la curva fotónica se desplaza hacia longitudes de onda mayores. Por ello, fuen-

tes con alta proporción de rojo generan PPFD relativamente superiores aun manteniendo la misma energía total.

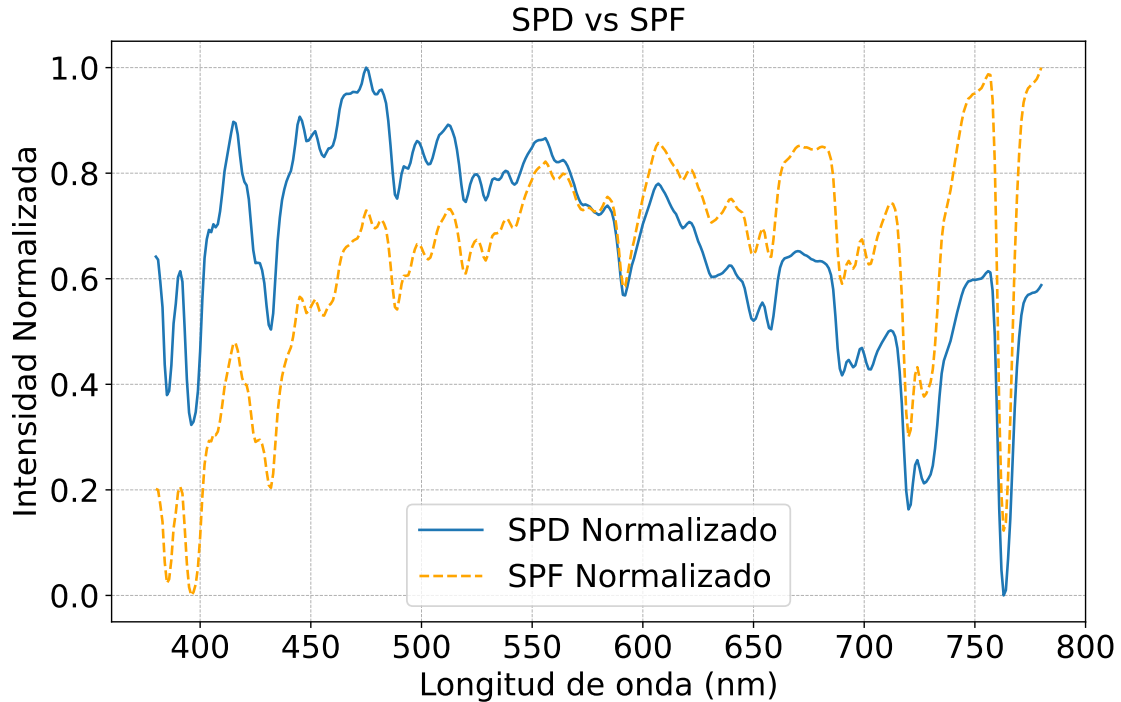


Figura 2.8: Espectro solar atmosférico mostrado como SPD y SPF normalizados

En el contexto del cannabis sativa, diversos estudios académicos han evaluado cómo la calidad espectral (longitudes de onda específicas) de la luz artificial influye en la morfología de plántulas durante sus primeros 20 días de fase vegetativa:

- Lámparas de espectro amplio vs. espectro estrecho: Magagnini et al. (2018) compararon luz tradicional de sodio de alta presión (HPS) con dos espectros LED de amplio espectro (modelos AP673L y NS1 de Valoya) durante 21 días de vegetación [53]. Encontraron diferencias claras en la arquitectura. De hecho, bajo HPS las plantas fueron significativamente más altas y esbeltas, mientras que bajo los LED (con mayor proporción de azul y rojo que con las HPS) las plantas crecieron más bajas y compactas [53]. No hubo diferencias significativas entre ambos espectros LED, pero sí frente a HPS. Estos resultados concuerdan con estudios previos que indican que la luz HPS (pobre en azul y con bajo cociente rojo) produce elongación excesiva de tallos y hojas [53]. La causa es doble, ya que por un lado, el bajo contenido de azul en HPS reduce la inhibición de elongación que normalmente provoca la luz azul; por otro lado, un bajo cociente R:FR (mucho rojo lejano relativo al rojo) bajo HPS desencadena respuestas de sombra vía fitocromos, elevando los niveles de auxinas que aceleran el crecimiento longitudinal [53]. En contraste, los espectros LED probados emitían más azul y un R:FR más alto, limitando la elongación y dando plantas robustas.
- Proporción de rojo a azul: Estudios más recientes han profundizado en la proporción óptima de LEDs rojos y azules. Wei et al. (2021) evaluaron seis tratamientos LED con

diferentes relaciones R:B y densidades de fotones, hallando que ciertas combinaciones mantuvieron un crecimiento similar o superior al de [59]. En particular, un espectro moderadamente balanceado (R:B ≈ 1.6) y otro muy rico en rojo (R:B ≈ 16.8) lograron sostener la altura de planta, diámetro de tallo y número de hojas comparable a HPS, a la vez que aumentaron el contenido de CBD en tejidos [59]. Esto demuestra que es posible manipular la relación rojo:azul para optimizar simultáneamente morfología y fitoquímica en Cannabis. Por otro lado, Morello et al. (2022) estudiaron espectros monocromáticos y mixtos en cannabis (‘Babbas Erkle Cookies’) y reportaron que una alta fracción de luz azul produce las plantas más bajas (efecto enanizante), mientras que espectros dominantes en rojo o ámbar inducen mayor crecimiento vertical [59]. Es sabido que la luz azul activa fotorreceptores (criptocromos) que frenan la elongación del tallo, en tanto que la luz roja (al no activar tanto esos receptores y al estimular fitocromos en estado activo P_{fr}) tiende a incrementar la altura e internodos más largos [59]. De hecho, el “dwarfing” (enanismo) bajo luz azul dominante en Cannabis concuerda con observaciones en otros cultivos [59], mientras que la dominancia de rojo acelera el alargamiento de tallos [59].

- Inclusión de la luz roja lejana (FR) y otras bandas: Además del rojo y azul, se ha investigado el efecto de agregar luz roja lejana (700–750 nm) en la etapa vegetativa. Kotiranta et al. (2024) cultivaron cáñamo (quimiotipo fibra) bajo diferentes cocientes R:FR y niveles de radiación de onda corta (azul/UV) [63]. Encontraron que un cociente R:FR bajo (≈ 1), es decir, con abundante rojo lejano, provocó plantas significativamente más altas (activando una fuerte respuesta de evitación de sombra), acompañadas de menor densidad de follaje y reducción en rendimiento final [63]. En cambio, aumentar la proporción de luz azul/UV en el espectro no afectó notablemente la morfología ni el rendimiento en ese experimento, aunque sí incrementó ciertos metabolitos secundarios [63]. Esto sugiere que, durante la fase vegetativa temprana, la luz roja lejana tiene un efecto morfogénico más pronunciado (estiramiento) que agregar pequeñas dosis de UV-A/azul extra, al menos dentro de rangos moderados. Por su parte, la luz verde/ámbar ha recibido menos atención en esta fase; algunos reportes indican que proporciones moderadas de verde pueden contribuir a mayor penetración de luz en el dosel sin alterar drásticamente la morfología, e incluso potenciar ciertos pigmentos como carotenoides [64], pero el control principal del arquitecturado sigue recayendo en las bandas azul, roja y lejano-rojo.
- Fluorescentes vs. LEDs en propagación: Tradicionalmente, se usaban tubos fluorescentes para plántulas y esquejes por su espectro relativamente blanco y baja irradiancia. Estudios comparativos recientes, como Moher et al. (2023), han mostrado que los LEDs pueden reemplazar con éxito a los fluorescentes en la propagación de Cannabis, ofreciendo espectros ajustables sin detrimento en el enraizamiento [60]. En ensayos con esquejes clónicos, estos autores probaron varios tratamientos LED (distintas proporciones de azul:rojo, con o sin pulsos de UV-A) frente a un control fluorescente, manteniendo PPF $\approx 200 \mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ por 16 h diarias [60]. Los resultados indicaron poca diferencia en tasas de enraizamiento (todos los espectros lograron más del 90 % de esquejes enraizados), aunque sí hubo efectos sutiles en la morfología inicial. Por ejemplo, tratamientos con azul elevado produjeron tallos más gruesos en los primeros 15 días comparados con luz blanca o rojo dominante [60]. Asimismo, la adición de una dosis de UV-A ligera mejoró modestamente el índice de raíces formadas [60]. Sin embargo, tras otros 21 días de

crecimiento vegetativo estándar post-transplante, las diferencias iniciales entre espectros no persistieron en la biomasa aérea [60]. Esto indica que, al menos para el establecimiento de plántulas, variar el espectro (dentro de rangos usuales) tiene un impacto limitado y transitorio en la morfología, en comparación con factores como la intensidad lumínica total o el genotipo. No obstante, en condiciones controladas de crecimiento vegetativo, sí se han observado diferencias consistentes en altura y forma de planta debidas a la calidad de luz, como se resume en la siguiente sección.

2.4.1. Fotomorfogénesis inducida por espectros lumínicos

A continuación en la tabla 2.6 se presenta una compilación de condiciones espectrales evaluadas en la literatura para etapas vegetativas tempranas de *Cannabis sativa*, indicando el tipo de fuente lumínica, rango de longitudes de onda o picos principales, la composición o proporción espectral, y los efectos observados en la morfología (altura de planta, grosor de tallo u otros indicadores).

Tabla 2.6: Comparación de espectros lumínicos en fase vegetativa de *Cannabis sativa* (primeras 3 semanas) y sus efectos reportados en altura de planta, diámetro de tallo y otros rasgos.

Composición espectral (aprox.)	Efectos morfológicos observados
Azul $\sim 8\%$, Verde $\sim 68\%$, Rojo $\sim 21\%$, Lejano-rojo $\sim 3\%$ (R:FR ≈ 2.8) [53]	Plantas más altas y de entrenudos largos bajo 18/6; morfología desbalanceada por elongación excesiva de tallos y hojas [53]. El bajo azul y bajo R:FR de HPS inducen respuesta de sombra (auxinas elevadas) y estiramiento rápido [53].
Azul $\sim 24\%$, Verde $\sim 37\%$, Rojo $\sim 33\%$, Lejano-rojo $\sim 4\%$ (R:FR ≈ 10) [53]	Plantas compactas y más bajas vs. HPS [53]. El mayor azul y alto R:FR restringen la elongación; se observa arquitectura equilibrada (tallos más cortos, follaje denso). Sin diferencias marcadas vs. otros LEDs de espectro amplio similares [53].
$\sim 67\%$ azul : 33% rojo (ej. proporción 2:1 B:R) [59]	Enanismo inducido por azul: plantas muy bajas, internodos cortos [59]. La alta fracción azul activa criptocromos que frenan el crecimiento vertical [59], resultando en tallos más gruesos y robustos pero menor altura [59].
$\sim 10\%$ azul : 90% rojo (ej. proporción 1:10 B:R) [59]	Estiramiento por rojo dominante: plantas más altas que con más azul, con entrenudos más largos y tallos más delgados [59]. La escasez de azul y predominio de rojo favorecen mayor tasa de elongación vertical (fotomorfogénesis de luz roja) [59].
Rojo:Lejano-rojo $\approx 1:1$ (R:FR = 1) [65]	Respuesta de sombra pronunciada: plantas extremadamente altas y espigadas en poco tiempo [65]. El exceso de FR relativo activa la vía de evitación de sombra, aumentando altura a expensas de menor grosor de tallo y menor densidad de hojas. Ejemplo: R:FR = 1 incrementó altura pero redujo biomasa de inflorescencias en cáñamo [65].

En la tabla 2.7 se presenta un análisis comparativo de las ventajas y desventajas de tres fuentes de luz empleadas en CEA. A partir de este análisis, para el presente proyecto se optó por el uso de lámparas LED, debido a la capacidad de esta tecnología para modular y controlar el espectro lumínico, así como por su fácil integración al sistema de automatización propuesto.

Tabla 2.7: Comparación de tecnologías de iluminación en agricultura controlada

Tecnología	Ventajas principales	Desventajas principales
HPS (Sodio de Alta Presión)	<ul style="list-style-type: none"> – Alta intensidad lumínica – Favorece la floración – Bajo costo inicial 	<ul style="list-style-type: none"> – Espectro limitado (predominio del rojo) – Alta emisión de calor – Baja eficiencia energética
LEC (Halogenuros Metálicos Cerámicos)	<ul style="list-style-type: none"> – Espectro más balanceado (incluye azul y UV) – Mejora el desarrollo vegetativo 	<ul style="list-style-type: none"> – Consumo energético elevado – Generación considerable de calor – Espectro no ajustable
LED	<ul style="list-style-type: none"> – Alta eficiencia energética – Baja emisión de calor – Control espectral preciso – Larga vida útil – Integración con sistemas automatizados 	<ul style="list-style-type: none"> – Costo inicial más alto – Requiere configuración específica para cada cultivo

2.5. Bases fisiológicas del crecimiento vegetal

Según Azcón-Bieto, el análisis del crecimiento vegetal constituye una aproximación cuantitativa que, a partir de datos básicos y accesibles, permite describir e interpretar el desarrollo de las plantas bajo condiciones naturales, seminaturales o controladas [20]. Este análisis cobra especial relevancia en cultivos como *Cannabis sativa*, donde el crecimiento está altamente influenciado por el genotipo, el estado fenológico, las condiciones ambientales y el manejo agronómico. La variabilidad genética y fenotípica entre cultivares de cannabis implica que cada individuo puede responder de manera diferencial a un mismo entorno, lo que demanda métodos de evaluación precisos y repetibles.

Para estimar el crecimiento se emplean métricas directas como la altura de la planta, el

diámetro del tallo, el número de hojas, el área foliar (FA), y las masas fresca y seca de órganos específicos (raíz, tallo, hojas, inflorescencias), siendo estas últimas críticas para cuantificar la biomasa acumulada. Además, se utilizan métricas fisiológicas indirectas que permiten caracterizar la eficiencia del crecimiento en relación con la estructura y la función de la planta:

- **Tasa de Crecimiento Relativo (RGR)**: estima el incremento de biomasa por unidad de biomasa inicial en un intervalo de tiempo, y se expresa como

$$\text{RGR} = \frac{\ln W_2 - \ln W_1}{t_2 - t_1}$$

donde W representa la masa seca.

- **Tasa de Asimilación Neta (NAR)**: relaciona la ganancia de biomasa con el área foliar responsable de la fotosíntesis, es decir, la eficiencia fotosintética de la planta por unidad de hoja.
- **Tasa de Crecimiento del Cultivo (CGR)**: expresa la productividad por unidad de superficie de terreno, siendo especialmente útil en contextos agronómicos o en cultivos de alta densidad.
- **Índice de Área Foliar (LAI)**: cuantifica la superficie foliar por unidad de superficie del suelo, lo que permite evaluar la intercepción de luz y la capacidad fotosintética del dosel.
- **Índice de Peso Específico de la Hoja (SLA)**: relaciona el área foliar con su masa seca, siendo un indicador del grosor o densidad foliar.
- **Índice de Tasa de Expansión Foliar (LER)**: útil en estudios de arquitectura vegetal y dinámica de crecimiento de hojas.

Observación

Para la caracterización y estimación del crecimiento de una planta, es necesario implementar un enfoque metodológico que integre la observación fenotípica, la cuantificación morfométrica y el análisis multivariable. El primer paso consiste en recolectar datos mediante mediciones directas o imágenes digitales, con el fin de obtener métricas clave como la altura de la planta, el área foliar, el diámetro del tallo y la biomasa acumulada.

En el trabajo presentado por Li et al. (2020), se desarrolló un método de estimación no destructiva del crecimiento vegetal mediante imágenes capturadas con smartphone en agricultura de ambiente controlado. Estimaron el área foliar y calcularon la tasa de crecimiento relativo (RGR), obteniendo una correlación de ($R^2 \approx 0.98$) con respecto a las mediciones destructivas de biomasa seca [66]. Chen y Yin (2024) implementaron un sistema automatizado de monitoreo utilizando cámaras RGB con el objetivo de calcular la longitud diaria de las plantas a partir de imágenes bidimensionales y reconstrucciones tridimensionales. La evaluación del sistema incluyó comparaciones con mediciones manuales y análisis de sensibilidad frente a la resolución, el ruido y el ángulo de captura [67]. Por otro lado, Wen et al. (2023) analizaron la aplicación de cámaras térmicas en plataformas terrestres y aéreas para la recolección de datos de temperatura foliar y del dosel. Mediante análisis térmico y modelos de aprendizaje automático, se estimaron

variables como biomasa, contenido hídrico y rendimiento, además de indicadores fisiológicos como el índice de estrés hídrico (CWSI) y la conductancia estomática. El enfoque térmico permitió monitorear simultáneamente el crecimiento y la respuesta a estrés abiótico y biótico. Las metodologías empleadas incluyeron redes neuronales convolucionales, regresión por máquinas de soporte vectorial y validación mediante coeficientes de determinación ($R^2 \approx 0.99$), tasas de clasificación y análisis estadísticos multivariados [68].

Cuantificación

La cuantificación morfométrica consiste en la medición objetiva de características estructurales de las plantas, con el fin de describir y analizar su crecimiento, arquitectura y desarrollo funcional. Esta aproximación permite registrar variables como la altura, el diámetro del tallo, el número de hojas, el área foliar, el volumen y la geometría del dosel vegetal. Estas mediciones pueden obtenerse mediante herramientas manuales como reglas, cintas métricas, calibres o medidores de área foliar, así como a través de técnicas basadas en visión artificial que emplean algoritmos para extraer dichas métricas a partir de imágenes digitales RGB, multispectrales o reconstrucciones tridimensionales. Ambas estrategias pueden implementarse de forma complementaria para generar registros precisos y representativos. Las variables morfométricas cuantificadas constituyen la base para calcular índices fisiológicos como la RGR, el LAI o la NAR, y son fundamentales para la construcción de modelos orientados a la estimación de biomasa, eficiencia fotosintética o rendimiento agrícola.

En el estudio de Li, se aplicó segmentación digital para estimar el área foliar proyectada y se utilizó la fórmula del RGR basada en el logaritmo natural de la biomasa seca en dos puntos temporales. El método se validó mediante regresión lineal, alcanzando un coeficiente de determinación de $R^2 \approx 0.98$ [66]. Chen y Yin implementaron un algoritmo de búsqueda en anchura (BFS) para segmentar estructuras vegetales y calcular la longitud diaria de crecimiento. Validaron su modelo comparando los resultados generados automáticamente con mediciones manuales y evaluaron la sensibilidad del algoritmo frente a variaciones en la resolución y condiciones de imagen [69]. Wen describieron múltiples enfoques para calcular variables como biomasa, índice de estrés hídrico (CWSI) y contenido hídrico, aplicando modelos de regresión parcial de mínimos cuadrados, máquinas de soporte vectorial y redes neuronales convolucionales, validadas mediante coeficientes de determinación de hasta $R^2 \approx 0.99$ y tasas de clasificación superiores al 95 % [68]. En una tesis desarrollada por Kumar, se propusieron modelos de regresión lineal y bayesiana para predecir biomasa a partir de área foliar estimada, temperatura, humedad y espectro lumínico. La validación se realizó con gráficos de dispersión entre valores reales y estimados, además de pruebas de robustez ante variaciones ambientales [70]. Por su parte, Sun empleó análisis de regresión polinómica para modelar la relación entre biomasa fresca y combinaciones de temperatura e iluminación, y utilizó análisis de clústeres K-means para agrupar patrones de respuesta vegetal [71]. Los modelos fueron evaluados mediante ANOVA para identificar efectos significativos de las variables ambientales ($p < 0.05$).

Analisis Multivariable

El análisis multivariable puede emplearse en el desarrollo de modelos estadísticos y predictivos aplicados a la estimación del crecimiento vegetal. Tal como se resume en la Tabla 2.8, estos modelos pueden construirse mediante enfoques paramétricos, como la regresión lineal múltiple o polinómica, así como mediante técnicas no paramétricas basadas en algoritmos de aprendizaje automático, incluyendo regresores por bosques aleatorios (Random Forest), máquinas de soporte vectorial (SVM) o redes neuronales artificiales. En ambos casos, se busca establecer funciones que relacionen variables independientes —tales como temperatura, humedad, radiación fotosintéticamente activa o área foliar— con variables dependientes como biomasa seca, tasa de crecimiento o rendimiento. La formulación de estos modelos implica la selección de variables relevantes, así como la aplicación de métodos de validación interna, que incluyen la partición del conjunto de datos (entrenamiento y prueba), validación cruzada y la evaluación del error mediante métricas como el coeficiente de determinación (R^2), la raíz del error cuadrático medio (RMSE, por sus siglas en inglés) o el error absoluto medio (MAE, por sus siglas en inglés). A través de estos procedimientos es posible explorar patrones de comportamiento multivariable y estimar variables de interés a partir de datos experimentales obtenidos en condiciones controladas o en campo.

Tabla 2.8: Métodos de análisis multivariable aplicados en estudios sobre crecimiento vegetal

Estudio	Métodos utilizados	Variables consideradas	Propósito del análisis
Wen et al. (2023) [68]	PLSR, SVM, Random Forest, CNN	Biomasa, temperatura foliar, contenido hídrico, índice de estrés (CWSI), rendimiento	Predicción y clasificación de variables fisiológicas y morfométricas
Kumar (2024) [70]	Regresión lineal múltiple, regresión bayesiana	Área foliar estimada, temperatura, humedad, espectro lumínico	Modelado predictivo de biomasa en sistemas hidropónicos
Sun (2024) [71]	Regresión polinómica, ANOVA multifactorial, clústeres (K-means)	Temperatura, duración de luz, intensidad de luz, biomasa seca, altura, número de hojas	Evaluación del efecto combinado de variables ambientales y agrupación de patrones de respuesta

Modelos de estimación

Una vez identificadas las relaciones entre variables mediante análisis multivariable, es posible construir modelos de estimación que permitan predecir el crecimiento vegetal a partir de variables fisiológicas, morfométricas o ambientales. Estos modelos pueden estar basados en enfoques estadísticos, como la regresión lineal múltiple o polinómica, o en métodos de aprendizaje automático, como máquinas de soporte vectorial, bosques aleatorios o redes neuronales. En el trabajo de Kumar y compañía, se desarrollaron modelos de regresión lineal y bayesiana para estimar la biomasa de cultivos hidropónicos,

utilizando variables como área foliar, temperatura, humedad y espectro lumínico, con validación mediante gráficos de dispersión y análisis de sensibilidad [70]. Sun y compañía implementaron modelos polinómicos para relacionar biomasa con combinaciones de temperatura e intensidad de luz, y aplicó análisis de clústeres para identificar agrupaciones de comportamiento fisiológico [71]. Wen et al recopilaron modelos predictivos aplicados al fenotipado por imagen térmica, empleando algoritmos como regresión parcial de mínimos cuadrados, máquinas de soporte vectorial y redes neuronales convolucionales, con coeficientes de determinación de hasta $R^2 \approx 0.99$ en predicción de biomasa, contenido hídrico y estrés fisiológico [68].

2.5.1. Panorama actual de modelos de crecimiento aplicados a *Cannabis sativa*

El cultivo industrial y medicinal de *Cannabis sativa* ha impulsado en los últimos años el desarrollo de metodologías más sofisticadas para describir y predecir su tasa de crecimiento. Tradicionalmente, los agrónomos recurrieron a ecuaciones empíricas o técnicas de regresión clásicas para estimar variables como altura, biomasa y rendimiento. Sin embargo, el advenimiento de la inteligencia artificial y el aprendizaje automático ha permitido ir más allá, integrando datos de sensores en tiempo real (por ejemplo, temperatura, humedad, flujo de fotones) con mediciones directas de la planta (altura, número de hojas, diámetro de tallo) e incluso con imágenes aéreas y multiespectrales captadas por drones o cámaras hiperespectrales. De manera similar, la IA se ha consolidado como una herramienta clave en ámbitos tan diversos como la medicina de precisión, la optimización de cultivos y el diseño de sistemas de ingeniería complejos, mejorando diagnósticos, predicciones y eficiencia operativa [52, 72, 73]. Estas estrategias no solo explotan series históricas para afinar la predicción de la evolución futura, sino que también facilitan la detección temprana de desviaciones de salud o estrés en el cultivo. En las siguientes páginas se presenta un estado del arte estructurado: se describen los principales tipos de modelos (desde regresiones lineales penalizadas hasta redes neuronales profundas), las variables predictoras más empleadas, la naturaleza y el volumen de datos requeridos, los niveles de precisión alcanzados en estudios recientes y, finalmente, las limitaciones y retos pendientes para su aplicación efectiva en campo.

Modelos Basados en Mediciones Directas (Datos Numéricos)

Los primeros intentos para modelar el crecimiento del cannabis emplearon relaciones matemáticas simples. Por ejemplo, se ha utilizado la regresión lineal para vincular el tiempo o factores ambientales con el crecimiento de la planta [74]. Asumiendo crecimiento exponencial, una transformada logarítmica de los datos de altura en el tiempo produce una relación lineal que permite estimar la tasa de crecimiento. Del mismo modo, las curvas logísticas se han aplicado para reflejar el crecimiento sigmoideal típico de muchas plantas. Estos modelos son sencillos y ofrecen interpretabilidad, pero a menudo no capturan efectos no lineales ni interacciones complejas entre variables.

Regresiones multivariadas con factores agronómicos

Investigaciones más recientes incorporan múltiples variables como predictores del rendimiento o la biomasa. Un estudio en cultivo de cáñamo para semilla de Frankowski y colaboradores empleó regresión lineal múltiple con variables como precipitación total, temperatura media, dosis de fertilizante y biomasa de tallo ("paja") para predecir el rendimiento de semilla [75]. Ese modelo lineal alcanzó un coeficiente de determinación de $R^2 \approx 0.91$ en sus datos de prueba, indicando buena capacidad predictiva. No obstante, su precisión dependía de un conjunto limitado de variables y condiciones de ensayo. Las limitaciones incluyen supuestos de linealidad y la dificultad para generalizar a condiciones muy distintas sin recalibración.

Redes neuronales artificiales (RNA)

Para superar relaciones no lineales, se han introducido modelos de aprendizaje automático. En un estudio reciente de Sieracka et al se entrenaron en el uso de varias redes neuronales para predecir el rendimiento de semilla de cáñamo a partir de un conjunto ampliado de variables de cultivo. En esa investigación se probaron arquitecturas de perceptrón multicapa (MLP) y redes de base radial (RBF), entre otras. Las mejores fueron las redes RBF, logrando una precisión muy alta (calidad de predicción del 97–98 %). Este desempeño superó tanto a las RNAs de estudios previos en otros cultivos (por ejemplo, caña de azúcar con $\approx 83\%$ como a modelos tradicionales en cáñamo. Vale destacar que en el trabajo de Frankowski et al mencionado anteriormente, las RNA RBF con un conjunto de datos ampliado superaron significativamente al modelo lineal previo (incremento de R^2 de ≈ 0.91 a ≈ 0.98). Estas RNA utilizaron variables climáticas, de manejo agronómico y morfológicas como entradas, mostrando el poder de combinar múltiples indicadores de crecimiento. Como limitación, las RNA requieren conjuntos de datos suficientemente grandes para evitar sobreajuste; los autores señalan la necesidad de continuar entrenando con datos de más temporadas para robustecer el modelo [75].

Máquinas de soporte vectorial y ensambles

Otros algoritmos de aprendizaje automático también han sido explorados. Por ejemplo, en contextos controlados de laboratorio, se modeló el crecimiento de callos celulares de *Cannabis sativa* (cultivo in vitro) variando reguladores de crecimiento en el medio de cultivo. En ese caso, se usaron SVM y Random Forests para predecir atributos morfológicos del callo, encontrando que la SVM resultó más precisa que el Random Forest. Al vincular la mejor SVM con un algoritmo genético, se pudo optimizar la combinación de fitohormonas para maximizar el crecimiento del callo, y las predicciones fueron validadas experimentalmente con gran acierto. Este enfoque híbrido (SVM + optimización global) logró identificar condiciones óptimas de crecimiento in vitro de manera más eficiente que la experimentación exhaustiva tradicional [76].

Redes neuronales especializadas y neuro-difusas

En micropropagación de cannabis se han comparado distintos tipos de modelos de inteligencia artificial. Pepe et al. (2021) evaluaron una red neuronal de regresión generalizada (GRNN), una RNA de perceptrón multicapa y un sistema neuro-difuso adaptativo

(ANFIS) para predecir parámetros de crecimiento in vitro (longitud de brote, número de nudos, longitud de raíz, área de copa) en función de variables de luz (espectro e intensidad) y concentración de sacarosa. La GRNN obtuvo el mejor desempeño con R^2 altos en todos los rasgos (por ejemplo, $R^2 > 0.96$ en longitud de brote, superando el $R^2 \approx 0.95$ del MLP y $\gg 0.58$ del ANFIS). También presentó los menores RMSE, indicando alta exactitud de predicción. Estos resultados demuestran el potencial de las RNA para capturar las relaciones complejas entre factores ambientales y crecimiento del cannabis en entornos controlados. Una limitación es que tales modelos in vitro se enfocan en estadios iniciales (microbrotes, callos) bajo condiciones muy distintas al campo; sin embargo, sientan bases metodológicas que pueden trasladarse a escalas mayores[77].

Modelos estadísticos convencionales vs. ML

La adopción de técnicas de inteligencia artificial se justifica porque los métodos estadísticos convencionales pueden quedarse cortos ante la complejidad del crecimiento vegetal. Factores como la calidad de luz o las interacciones multivariadas suelen introducir no linealidades difíciles de capturar con regresiones simples, a menudo derivando en sobreajuste o conclusiones engañosas [77]. De hecho, hasta hace poco no existían sistemas objetivos y fáciles de usar para predecir el rendimiento del cáñamo; las estimaciones se basaban en promedios históricos por variedad y prácticas, sin considerar las condiciones específicas de cada ciclo. La reciente literatura demuestra que los modelos de ML (redes neuronales, SVM, random forest, etc.) ofrecen mayor precisión y capacidad de generalización al estimar el crecimiento de Cannabis sativa, aunque con la salvedad de requerir suficientes datos de entrenamiento representativos. En este contexto, los enfoques basados en mediciones directas han evolucionado desde regresiones lineales simples hacia modelos multivariados no lineales altamente precisos, incorporando numerosas variables predictoras (clima, nutrientes, morfología) para estimar la biomasa o rendimiento con alta exactitud.

Precisión y limitaciones generales: Los mejores modelos numéricos reportados para Cannabis alcanzan coeficientes de determinación muy altos ($R^2 > 0.95$) en condiciones controladas o conjuntos de datos limitados [77]. Por ejemplo, con RNA es posible predecir la producción de semillas con 97–98% de exactitud en ensayos locales [75]. Sin embargo, estas precisiones pueden reducirse al aplicar el modelo en escenarios nuevos (otro clima, otra variedad) si el modelo no ha visto datos similares. La generalización es un desafío clave: los modelos entrenados con datos de un cultivar podrían no funcionar igual de bien con genotipos muy distintos o en condiciones de campo abiertas. Asimismo, variables no incluidas (p.ej. plagas, enfermedades, eventos extremos) pueden afectar el crecimiento real y escapar a la predicción. Por ello, muchos autores señalan la necesidad de ampliar los conjuntos de datos (multi-año, multi-cultivar) y de explorar enfoques híbridos que combinen conocimiento agronómico con ML para lograr modelos más robustos [75].

En la Tabla 2.9 se sintetizan ejemplos representativos de modelos basados en mediciones directas para Cannabis sativa, indicando el tipo de modelo, variables de entrada, tipo de datos, precisión lograda y principales limitaciones reportadas.

Tabla 2.9: Ejemplos de modelos para estimar el crecimiento de *Cannabis sativa* basados en mediciones directas.

Modelo (Referencia)	VARIABLES PREDICTORAS	Tipo de datos	Precisión	Limitaciones
Regresión lineal múltiple [75]	Precipitación, temperatura, fertilización, biomasa vegetativa	Numéricos de campo (parcelas)	$R^2 \approx 0.91$	Supone relaciones lineales; pocas variables
Red neuronal (RBF) [75]	Clima, manejo agronómico, morfología de planta	Numéricos de campo multi- anuales	$R^2 \sim 0.98$	Riesgo de sobreajuste con datos limitados
Red neuronal (GRNN) [77]	Intensidad de luz (roja, azul, etc.) y % sacarosa	Laboratorio (in vitro)	$R^2 > 0.95$	Aplicable sólo a micro-propagación
SVM + Alg. genético [76]	Hormonas de crecimiento + imágenes	In vitro (callo)	Precisión alta, superior a RF	Enfocado en callo; no generaliza a planta entera
ANFIS [77]	Luz y sacarosa	In vitro	$R^2 \sim 0.6-0.7$	Menor precisión frente a RNA
Modelo clásico logístico/exponencial [74]	Tiempo (días desde siembra)	Altura periódica	Ajuste visual aceptable	No considera ambiente ni genética

Nota: RNA = red neuronal artificial; GRNN = red neuronal de regresión generalizada; SVM = máquina de vectores de soporte; RF = random forest; ANFIS = sistema neurodifuso adaptativo.

2.5.2. Vacíos identificados y contribución esperada

En síntesis, aunque existen modelos numéricos con altos niveles de precisión bajo condiciones controladas, la literatura actual no ha explorado con suficiente profundidad la influencia de regímenes de iluminación modulados entre SPD, PPFD y DLI, sobre trayectorias específicas de crecimiento en *Cannabis sativa*. Tampoco se han desarrollado modelos predictivos que incorporen simultáneamente variables espectrales, fisiológicas y microclimáticas de forma coordinada, ni que consideren la variabilidad genotípica de cultivares específicos. Este vacío en la modelación integradora, orientada no solo a rendimiento, sino a morfogénesis dirigida, constituye la base de la presente tesis. En ella se propone un enfoque experimental y computacional para diseñar y evaluar modelos predictivos que relacionen DLI, SPD y PPFD con patrones de crecimiento en etapa vegetativa, integrando sensores IoT y técnicas de inteligencia artificial en cultivares de *Cannabis Sativa* de la genética Rosa Andina del banco de semillas Colombia Breeders.

Capítulo 3

Arquitectura IoT de monitoreo

El diseño del sistema de monitoreo basado en una arquitectura IoT constituye el eje central del presente estudio, ya que integra los subsistemas de adquisición, transmisión y gestión de datos, los cuales son requeridos para caracterizar el entorno de cultivo y realizar un seguimiento dinámico del crecimiento vegetal. Adicionalmente, esta arquitectura permite la interoperabilidad entre sensores, actuadores y plataformas digitales, facilitando así un flujo de información continuo y estructurado desde el entorno físico del sistema propuesto hasta la interfaz de usuario.




Figura 3.1: Esquema general de la arquitectura patrón MVC

En este trabajo se integran dos patrones arquitectónicos complementarios: el modelo Vista–Controlador (MVC) y el modelo en capas. El patrón MVC permite separar la lógica del sistema en tres componentes claramente definidos, tal como se ilustra en la Figura 3.1.

En el borde, el controlador gestiona las entradas del sistema, coordinando la comunicación con sensores y actuadores y ejecutando la lógica de control en los microcontroladores. El backend encapsula la interfaz de programación de aplicaciones (API) y el acceso a los datos. El frontend se encarga de la presentación de la información y de la interacción con el usuario.

Por su parte, el modelo en capas organiza la arquitectura en niveles jerárquicos de abstracción, de modo que cada capa asume una función específica. Así, desde la adquisición de datos hasta su procesamiento, presentación y almacenamiento, cada estrato aporta una visión clara de responsabilidades y facilita tanto el desarrollo como el mantenimiento del sistema. De este modo, la combinación de MVC y el enfoque en capas garantiza

una estructura modular, escalable y fácilmente extensible.

La Figura 3.1 ilustra el flujo de comunicación del sistema propuesto. En primera instancia, una red de sensores distribuidos dentro del invernadero registra continuamente variables ambientales (temperatura, humedad relativa, concentración de CO₂) y parámetros fisiológicos del cultivo (pH del sustrato, nivel de EC, irradiancia lumínica). Estos sensores envían sus lecturas a un microcontrolador de borde que no solo agrupa y filtra la información, sino que también ejecuta algoritmos básicos de validación y detección de anomalías. Acto seguido, los datos depurados se transmiten de forma segura mediante protocolos MQTT/TLS hacia la infraestructura en la nube (backend), donde se almacenan en una base de datos relacional.

Una vez en el backend, la información se dispone para su consulta y análisis. A su vez, esta capa distribuye las visualizaciones interactivas al frontend, diseñado con interfaces intuitivas que permiten al usuario final monitorizar en tiempo real el estado del cultivo y los indicadores de rendimiento. Desde esa misma interfaz, el usuario puede ajustar parámetros de consigna (set points) —por ejemplo, definir umbrales de riego y enviar comandos de control al backend, que a su vez los reenvía al nodo de borde para su ejecución local.

Para completar el ciclo de automatización, el nodo de borde también coordina la activación de los actuadores, tales como válvulas de riego, ventiladores de recirculación, luminarias LED de espectro ajustable y sistemas de dosificación de nutrientes. Gracias a la interconexión entre sensores y actuadores, la arquitectura garantiza una regulación continua y adaptativa del entorno de cultivo, minimizando el estrés vegetal y maximizando los rendimientos.

3.1. Sistema de adquisición de datos

El sistema de adquisición de datos constituye el primer nivel de interacción entre el sistema y el entorno físico del cultivo. Está compuesto por un conjunto de sensores diseñados para monitorear las variables fisiológicas ambientales descritas en la sección 2.3. Estos sensores permiten obtener información clave sobre las condiciones del microclima en el invernadero y la calidad del agua que representa la disponibilidad de nutrientes; además, sus mediciones son fundamentales para caracterizar el entorno de cultivo y alimentar el sistema de control automatizado.

Para optimizar la gestión de datos y simplificar el desarrollo, se adoptó una separación funcional entre los sensores ambientales y los sensores destinados al monitoreo de la calidad del agua. En la siguiente sección se describen en detalle los sensores climáticos instalados en el invernadero, sus rangos de operación y su trazabilidad metrológica. Más adelante, se presentará el conjunto de sensores hidrométricos, así como las estrategias de calibración y sincronización temporal que garantizan la coherencia de las mediciones

en todo el sistema.

3.1.1. Sensores ambientales

En esta subsección se detalla el sistema diseñado para la adquisición de variables ambientales críticas para el cultivo de Cannabis. La Tabla 3.1 recoge las especificaciones técnicas de cada sensor, seleccionados por su alta precisión, compatibilidad con microcontroladores embebidos y capacidad de operar en condiciones de invernadero controlado. El sensor SCD40 de Sensirion, por ejemplo, integra mediciones de temperatura, humedad relativa y dióxido de carbono con precisiones de ± 0.8 °C, ± 5 % RH y $\pm(50$ ppm + 5 %) respectivamente. Por su parte, el espectrómetro AS7265x de SparkFun/AMS cubre dieciocho bandas entre 410 nm y 940 nm con una precisión de ± 12 %.

Tabla 3.1: Especificaciones técnicas de los sensores ambientales utilizados en el sistema de monitoreo.

Variable	Sensor	Rango de medición	Precisión (Accuracy)	Fabricante
Temperatura	SCD40	-10 a 60 °C	± 0.8 °C	Sensirion
Humedad relativa	SCD40	0 a 100 % RH	± 5 % RH	Sensirion
CO ₂	SCD40	400 a 2000 ppm	$\pm(50$ ppm + 5 %)	Sensirion
Espectro de luz	AS7265x	410–940 nm	± 12 % (según banda espectral)	SparkFun/AMS

La Figura 3.2 ilustra la arquitectura de conexión de estos sensores en el nodo de borde. Todos los dispositivos se comunican con el microcontrolador principal mediante un bus I2C (Inter-Integrated Circuit por sus siglas en inglés) compartido, en el que cada sensor dispone de una dirección única, lo que simplifica la sincronización de las lecturas y reduce el cableado. Esta configuración modular permite escalar fácilmente el sistema añadiendo nuevos sensores o reemplazando componentes sin alterar la lógica de adquisición fundamental.




Figura 3.2: Arquitectura de conexión de sensores en el nodo de borde.

3.1.1.1. Sensirion SCD40 Humedad y Temperatura

Una parte fundamental cuando empleamos sistemas de sensado, está asociada a la calibración de los mismos. Por ello, el primer paso fue crear un protocolo de calibración del sensor Sensirion SCD40 para las variables de temperatura y humedad relativa, con el fin de garantizar la confiabilidad y precisión de las lecturas en el entorno controlado. La calibración se llevó a cabo utilizando un patrón de referencia Fluke 971, estableciendo puntos de control en condiciones estables de humedad o temperatura, según corresponda.

Para la calibración de temperatura, se seleccionaron cuatro puntos de referencia a 15 °C, 20 °C, 30 °C y 40 °C, mientras se mantenía constante la humedad al 50 %. En cada punto se registraron dos lecturas con intervalos de dos minutos, calculándose el promedio de cada par de mediciones (véase tabla 3.2). Los resultados obtenidos evidencian una desviación máxima de +0.63 °C entre el promedio del patrón y el sensor SCD40. Así mismo, la repetibilidad del primer punto fue verificada con una medición adicional bajo las mismas condiciones. En este caso, los resultados revelaron una variación de tan solo 0.1 °C.

Tabla 3.2: Comparación entre temperatura de control, promedio del patrón (Fluke 971) y el sensor SCD40, incluyendo el error de medición.

Control (°C)	Promedio Patrón (°C)	Promedio SCD40 (°C)	Corrección (°C)
15	15.49	15.19	+0.30
20	19.95	19.72	+0.23
30	29.63	29.18	+0.46
40	39.07	38.44	+0.63

Para corregir el sesgo sistemático, se ajustó la salida del SCD40 mediante regresión

lineal, obteniendo la siguiente relación:

$$T_{\text{corr}} = a T_{\text{raw}} + b,$$

donde los coeficientes hallados fueron

$$a = 1.02808, \quad b = -0.91717, \quad R^2 = 0.99971.$$

La Figura 3.3 compara la respuesta cruda y la respuesta corregida del sensor frente al patrón, evidenciando una excelente concordancia tras el ajuste.

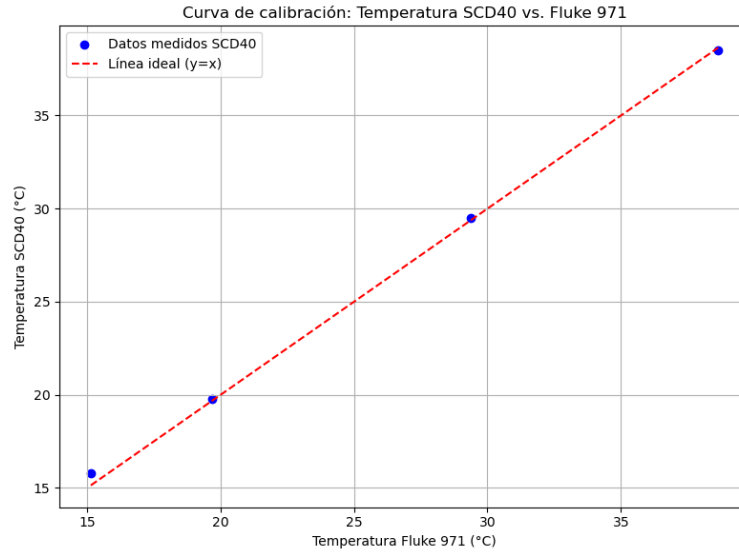


Figura 3.3: Curva de calibración del sensor SCD40 para temperatura.

De forma análoga, se llevó a cabo el proceso de calibración del sensor para la variable humedad relativa. En este caso, el protocolo incluyó cinco puntos de calibración a una temperatura constante igual a 25°C: 30 %, 50 %, 60 %, 70 % y 78 % RH (tabla 3.3). El análisis reveló una subestimación creciente del sensor a partir del 50 % RH, con diferencias de hasta -5.6% en el extremo bajo y -1.1% en el extremo alto. La repetibilidad en cada punto se mantuvo dentro de 0.1 % RH, lo que confirma la estabilidad del sensor elegido para nuestro desarrollo.

Tabla 3.3: Comparación entre valores de humedad relativa del patrón de referencia (Fluke 971) y el sensor SCD40.

Control (%HR)	Patrón (%HR)	SCD40 (%HR)	Corrección (%HR)
30	31.1	36.7	-5.6
50	51.6	54.4	-2.9
60	61.9	64.3	-2.4
70	72.2	73.8	-1.6
78	79.8	80.9	-1.1

Para el ajuste de la medición de la humedad relativa se realizó una regresión lineal sobre los datos obtenidos:

$$RH_{\text{cal}} = a RH_{\text{filt}} + b,$$

con

$$a = 1.0984, \quad b = -8.8028, \quad R^2 = 0.99954.$$

Estos ajustes en la corrección de las desviaciones de las lecturas, especialmente en niveles elevados de humedad relativa, mejoraron la precisión de los datos registrados por el sistema y se integraron directamente en el código del microcontrolador, tal como se ilustra en la Figura 3.4.

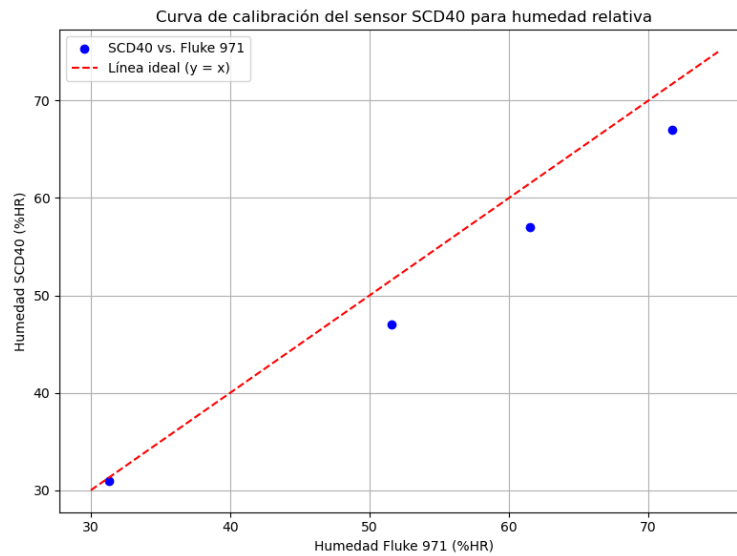


Figura 3.4: Curva de calibración del sensor SCD40 para humedad.

3.1.1.2. Sensor multiespectral (AS7265x)

El AS7265x es un módulo multiespectral, el cual integra tres sensores independientes (AS72651, AS72652 y AS72653) en una sola placa, facilitando la adquisición simultánea de 18 bandas espectrales discretas en el rango 410 – 940 nm, distribuidas de la siguiente manera:

- **AS72651:** 410, 435, 460, 485, 510 y 535 nm
- **AS72652:** 560, 585, 610, 645, 680 y 705 nm
- **AS72653:** 730, 760, 810, 860, 900 y 940 nm

Para adaptarse a distintos niveles de iluminación y optimizar la relación señal/ruido el sistema cuenta con control de tiempo de integración y ganancia digital programable.

El sensor AS7265x se integró al sistema mediante su interfaz I²C, configurando el submódulo AS72651 como maestro para coordinar la adquisición simultánea de los tres subcomponentes. En el contexto de este experimento, se requería evaluar la confiabilidad del sensor y obtener la SPF.

Para este propósito, se utilizó un espectrofotómetro de referencia HoppoColor OHSP-350C [78], el cual entrega mediciones espectrales en unidades radiométricas de irradiancia espectral, expresadas en $\mu\text{W} \cdot \text{cm}^{-2} \cdot \text{nm}^{-1}$. Estas unidades representan la cantidad de energía radiante por unidad de área y por unidad de longitud de onda, dentro de un rango espectral de 380 a 780 nm.

Se diseñó un experimento empleando como fuente una lámpara de espectro ajustable SunPlus Sundro S250 [79], con el objetivo de validar el desempeño del AS7265x frente a una luz artificial optimizada para horticultura. Para ello, se realizaron ensayos comparativos bajo cinco configuraciones espectrales distintas sintonizadas en la lámpara Sundro.

Durante cada nivel de atenuación, el AS7265x muestreó sus 14 canales cada 500 ms con una ganancia de $\times 16$, mientras que el OHSP-350C registró simultáneamente un espectro continuo de 401 canales. La Figura 3.5 superpone los espectros obtenidos en cuatro condiciones representativas: espectro completo (a), pico rojo a 645 nm (b), pico azul a 460 nm (c) y azul de baja irradiancia (d). Se observaron desviaciones sistemáticas en los picos de emisión, con sobrestimaciones o subestimaciones de hasta $\pm 0,5$, atribuibles tanto a la resolución discreta del AS7265x como a la respuesta espectral de sus filtros Fabry-Pérot.

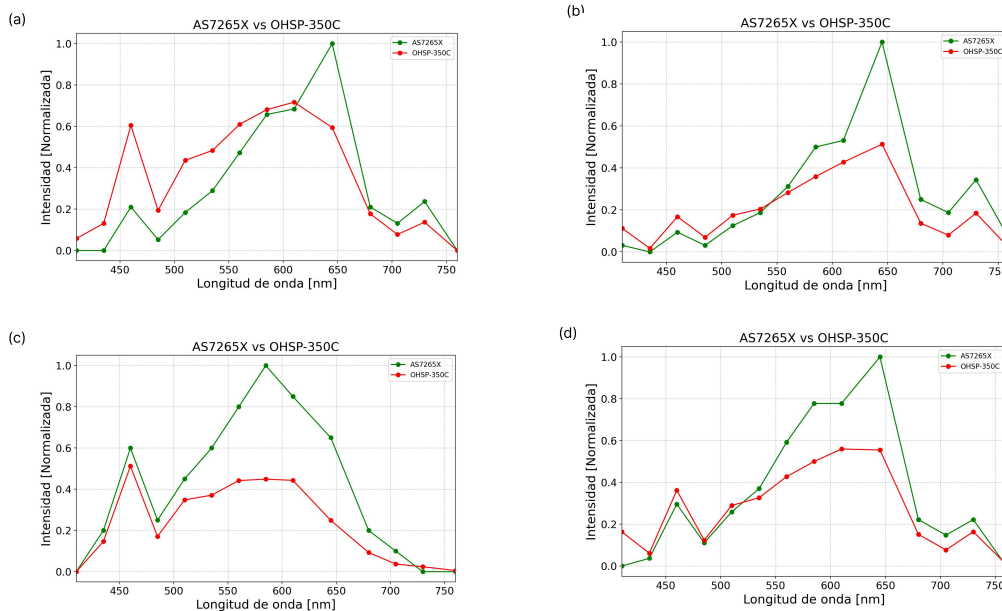


Figura 3.5: Comparación de las mediciones espectrales obtenidas con el sensor multispectral AS7265x (línea verde) y el espectrofotómetro OHSP-350C (línea roja) bajo diferentes condiciones de la SPF: (a) iluminación de espectro completo, (b) espectro con incidencia roja centrada en 645 nm, (c) espectro con incidencia azul centrada en 460 nm y (d) espectro azul de baja irradiancia.

Para evaluar la desviación del sensor AS7265x frente al OHSP-350C, se hizo una normalización de los datos y se empleó el RMSE como función de pérdida, ya que proporciona

la magnitud promedio del error en la misma escala que los datos. Además, se calculó la desviación estándar de los residuos para analizar la estabilidad del sensor en diferentes mediciones.

El RMSE calculado es de 0.35, lo que sugiere que el sensor AS7265x presenta desviaciones significativas en comparación con el espectrofotómetro de referencia OHSP-350C. Además, la desviación estándar de los residuos 0.16 revela que la variabilidad en los errores no es uniforme en todo el espectro, lo que podría estar relacionado con diferencias en la respuesta espectral de los filtros ópticos del AS7265x, y la resolución limitada de sus 18 canales discretos. Estos resultados resaltan la importancia de implementar un modelo de corrección espectral para reducir la discrepancia entre el AS7265x y el espectrofotómetro patrón.

3.1.1.3. Modelo de ajuste de datos

Para estimar la distribución espectral continua a partir de las 14 bandas del sensor AS7265x, se entrenó un modelo de red neuronal multicapa (MLP, por sus siglas en inglés) multisalida, implementado con la biblioteca TensorFlow Keras. Cada espectro fue normalizado individualmente en el rango de 0 a 1, preservando así su forma relativa. Esta estrategia se adoptó debido a que la relación entre los canales espectrales no es lineal ni constante entre muestras, por lo cual una normalización global por columna podría distorsionar los patrones propios de cada espectro.

Se definió una función objetivo para optimizar los hiperparámetros del modelo mediante el framework Optuna (versión 3.6.1). Los hiperparámetros evaluados incluyeron el número de capas ocultas (`n_hidden`), el número de unidades por capa (`units`), la tasa de abandono (`dropout_rate`) y la tasa de aprendizaje del optimizador Adam (`lr`). El espacio de búsqueda se restringió a valores realistas y eficientes para despliegue embebido, considerando entre una y dos capas ocultas, entre 80 y 110 neuronas por capa, una tasa de abandono entre 0.05 y 0.15, y una tasa de aprendizaje entre 10^{-3} y 3×10^{-3} en escala logarítmica.

El proceso de optimización se ejecutó durante 50 iteraciones, utilizando el error absoluto medio (MAE) como métrica de evaluación. Con los mejores hiperparámetros encontrados:

- `n_hidden` = 1
- `units` = 107
- `dropout_rate` = 0.075
- `lr` = 0.00126

se entrenó un modelo final sobre el conjunto completo de datos de entrenamiento. El rendimiento del modelo se evaluó calculando las métricas por espectro individual y luego promediándolas para obtener una estimación global del desempeño:

- MAE promedio: 0.0284
- RMSE promedio: 0.0397
- Coeficiente de determinación promedio (R^2): 0.9850

El MAE promedio de 0.0284 indica que, en promedio, la diferencia entre los valores predichos y los reales fue inferior al 3 % en una escala normalizada de 0 a 1. El RMSE de 0.0397 sugiere que los errores más grandes fueron poco frecuentes y no dominaron el comportamiento general del modelo. Por último, el coeficiente de determinación promedio ($R^2 = 0.9850$) indica que el modelo logró explicar el 98.5 % de la variabilidad total de los espectros reales a partir de las mediciones del sensor AS7265x, lo que valida su capacidad para realizar una reconstrucción precisa y generalizable.

La Figura 3.6 presenta la gráfica de dispersión entre los valores predichos y reales para todos los canales, evidenciando la alta correlación obtenida por el modelo.




Figura 3.6: Gráfico de dispersión entre las predicciones del modelo y los valores reales normalizados. La línea roja indica el ajuste ideal ($y = x$).

3.1.1.4. Conversión y despliegue del modelo MLP con TFLite

Con el objetivo de realizar inferencia directamente en un microcontrolador ESP32 Sparkfun Thing Plus con memoria flash de 16 Mb y SRAM de 520 KB, se integró el modelo MLP previamente entrenado a través de la herramienta TensorFlow Lite for Microcontrollers (TFLM). A continuación, se describe el procedimiento llevado a cabo para su implementación en el dispositivo:

1. Conversión del modelo: Una vez entrenado el modelo MLP, se procedió a convertirlo a formato `.tflite` utilizando la API `TFLiteConverter` de TensorFlow. Se aplicó cuantización entera completa (integer quantization) con el objetivo de reducir el tamaño del modelo y hacerlo compatible con el entorno de ejecución TFLM. Para ello, se definió un conjunto de datos representativo necesario para calibrar la cuantización, asegurando que el rango de activaciones y pesos se ajustara a enteros de 8 bits.
2. Configuración del convertidor: Se especificó el uso exclusivo de operaciones enteras con la directiva `TFLITE_BUILTINS_INT8`, y se dejó explícitamente indicada la

intención de utilizar `tf.int8` como tipo de dato tanto para entradas como salidas. Esta configuración resultó clave para garantizar la compatibilidad con el compilador `xxd` y con el entorno de desarrollo de TensorFlow Lite for Microcontrollers.

3. Resultado de la conversión: El modelo fue convertido, con un tamaño final de 5.2Kb. Al inspeccionar el gráfico de operaciones mediante la herramienta `visualize.py`, se constató que el modelo contiene únicamente dos operaciones `FULLY_CONNECTED`, lo que garantiza eficiencia computacional y bajo consumo de memoria en ejecución.
4. Compilación y despliegue: El archivo `.tflite` fue convertido a formato C byte array mediante el comando `xxd -i`, y posteriormente fue embebido dentro del código fuente del firmware del ESP32-S2. El modelo fue cargado en memoria flash y ejecutado usando la librería `micro_interpreter` de TensorFlow Lite. La inferencia se realiza tomando como entrada un vector de 14 bandas normalizado previamente en el mismo rango que los datos de entrenamiento.
5. Validación en el dispositivo: Se realizaron inferencias en tiempo real con datos provenientes del sensor AS7265x (ganancia de $16\times$ y tiempo de integración de 500 ms) conectados al microcontrolador ESP32-S2. Paralelamente, se adquirieron mediciones comparativas con el espectrofotómetro de referencia OHSP-350C. Se verificó que las salidas del modelo MLP reproducen fielmente los espectros reconstruidos, manteniendo tiempos de inferencia en el orden de los milisegundos. La Figura 3.7 ilustra la superposición entre los espectros reales (OHSP-350C) y los reconstruidos por el modelo en cuatro condiciones de iluminación representativas, confirmando la alta capacidad del sistema para operar de forma embebida sin pérdida significativa de precisión.

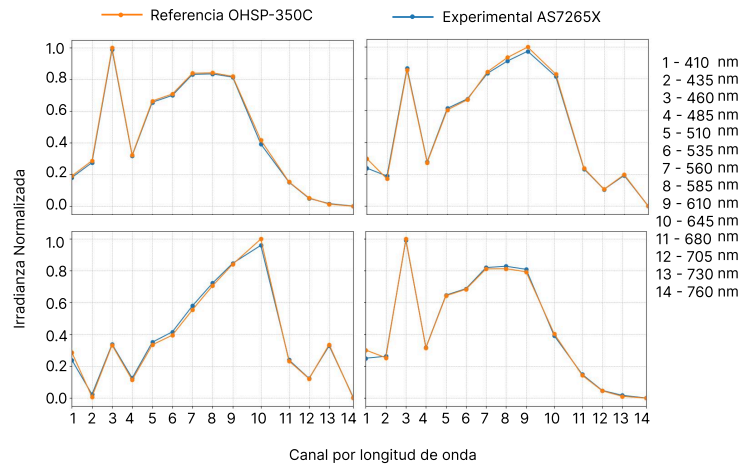


Figura 3.7: Comparación entre espectros de referencia (OHSP-350C) y espectro ajustado con MLP embebido con Tflite.

3.1.2. Diseño físico del sistema: torre de sensores

El montaje físico de los sensores ambientales se implementó como una torre modular impresa en 3D. La Figura 3.8 muestra una vista isométrica del conjunto. La estructura, de altura total 282 mm y diámetro de base 21.34 mm, se diseñó para mantener una

separación vertical de 19.0 cm entre los sensores espectrales y térmicos. Esto evita el solapamiento de campos de medición y minimiza la radiación reflejada de forma cruzada. En su parte superior, una cúpula difusora anti-UV (A) protege el sensor AS7265x de la incidencia directa de la luz y homogeneiza el espectro incidente; debajo de ella, un cuerpo intermedio acoge el espectrómetro multiespectral (C) montado sobre un soporte. Más abajo, en un nivel separado por 32.3 mm, se sitúa el sensor SCD40 (E), el cual se encarga de medir la temperatura y la humedad, protegido por un difusor de partículas y polvo.




Figura 3.8: Esquema 3D de la torre de sensores (A) Cúpula difusora; (B) Cuerpo intermedio; (C) Sensor Multiespectral AS7265X; (D) Soporte estructural de sensores; (E) Sensor ambiental SCD40 ; (F) Unidad de control ESP32-S3; (G) Base de anclaje estructural

La estructura se diseñó utilizando software de modelado 3D paramétrico Autodesk Fusion 360. La impresión se realizó usando la impresora 3D Reality K1C y filamento de ASA, materiales seleccionados por su resistencia térmica, baja higroscopicidad y compatibilidad con ambientes controlados. En la sección media, alojamientos plugin para el microcontrolador ESP32-S3 (F) y los módulos de comunicación (Wi-Fi/BLE) facilitan el acceso para mantenimiento o actualización de firmware. La base de anclaje (G) incorpora huecos para fijación con tornillos y pasacables, garantizando la estabilidad mecánica, la integridad del tendido eléctrico y la disipación de calor. Todos los bordes interiores cuentan con radios de curvatura mínimos de 2 mm para reducir acumulación de polvo y facilitar la limpieza.

3.1.3. Sensores de calidad del agua

El módulo “Hidro” se diseñó como el eje central de la solución IoT para cultivo hidropónico, encargándose de la monitorización continua y el ajuste automático de la disolución nutritiva. En un circuito cerrado, tres magnitudes fisicoquímicas críticas—pH, EC y temperatura—se muestrean en tiempo real y, mediante un lazo de control, se activan bombas peristálticas que dosifican nutrientes o correctores hasta restablecer los valores de consigna. Para garantizar robustez y exactitud, este subsistema combina

sensores electroquímicos de grado industrial con actuadores de dosificación fina, todos interconectados al nodo de borde (ESP32-S3) mediante buses I2C, UART (Universal Asynchronous Receiver/Transmitter por sus siglas en inglés) y líneas GPIO (Entrada/-Salida de Propósito General) dedicadas. La arquitectura resultante se organiza en tres bloques funcionales: i) adquisición de variables mediante sensores de alta resolución, ii) algoritmos de control y lógica de decisión embebidos en el microcontrolador, y iii) red hidráulica y manifold de tuberías que distribuyen la solución tratada al sistema radicular de las plantas. Las secciones siguientes profundizan en el diseño y la selección de sensores, en la estrategia de control basada en umbrales adaptativos y en la configuración mecánica del circuito de tuberías que conecta el depósito con los goteros de cultivo.

Para garantizar un control preciso de la solución nutritiva, el módulo hidro incorpora una *cadena de instrumentación de grado industrial* capaz de muestrear, con alta frecuencia y baja deriva, los tres parámetros fisicoquímicos críticos del agua en cultivos hidropónicos: pH, EC y temperatura. Cada variable se mide mediante un transductor especializado de la línea *EZO/Surveyor™* de Atlas Scientific, cuya configuración compacta facilita la integración directa en el nodo de borde a través de buses UART/I²C y conectores SMA/BNC. Los criterios de selección incluyeron:

1. Resolución suficiente para detectar variaciones discretas que influyan en la absorción de nutrientes.
2. Precisión certificada que asegure la reproducibilidad experimental exigida en investigación aplicada.
3. Compatibilidad electrotécnica con los algoritmos de compensación de temperatura y las rutinas de calibración multipunto embebidas en el microcontrolador.

En los apartados siguientes se describen las características específicas de cada transductor y se resumen sus especificaciones clave en la Tabla 3.4.

Tabla 3.4: Especificaciones técnicas de los sensores utilizados para el monitoreo de la calidad del agua.

Sensor	Magnitud	Rango de medición	ón	Fabricante
Sonda de pH (grado consumidor)	Potencial hidrógeno (pH)	0–14	±0.25 pH	Atlas Scientific
Sonda de conductividad K 1.0	Conductividad eléctrica (EC)	5 μ S/cm – 200,000 μ S/cm	±2 %	Atlas Scientific
Sonda de temperatura PT-1000	Temperatura del agua	–10 °C a 100 °C	±0.1 °C	Atlas Scientific

*Precisión declarada por el fabricante bajo condiciones de laboratorio a 25 °C.

3.1.3.1. Sensor de pH

La medición de pH se realizó con un electrodo de vidrio con membrana de silicato sodocálcico permeable a iones H⁺, acoplado a un acondicionador analógico Surveyor

que genera un voltaje lineal en el rango de 0–3.3 V. Estos potenciales se relacionan con el pH mediante la ecuación:

$$pH = -5.6548 \times V + 15.509 \quad (3.1)$$

donde V representa el voltaje en voltios leído por el ADC. Cada potencial medido corresponde así a un valor de pH, como se muestra en la Figura 3.9.

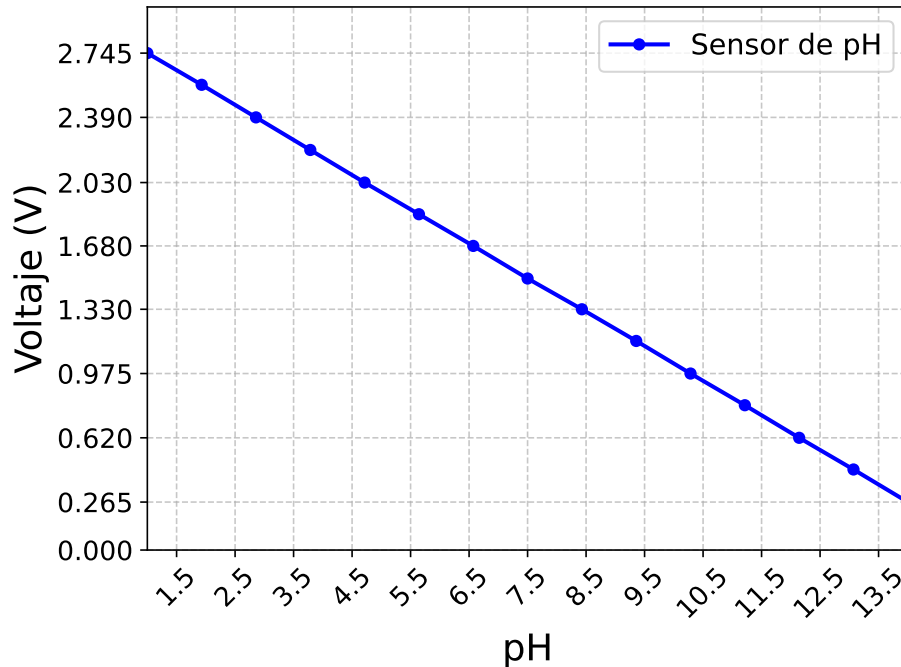


Figura 3.9: Relación lineal entre el voltaje generado por el acondicionador Surveyor y el valor de pH.

Para garantizar la exactitud y trazabilidad de las mediciones de pH, el electrodo se calibró mediante un protocolo multipunto utilizando tres soluciones tampón certificadas de referencia (pH 4.00, pH 7.00 y pH 10.00). El sensor Surveyor™ Analog pH genera potenciales eléctricos proporcionales a la actividad iónica del hidrógeno, los cuales fueron leídos mediante un microcontrolador. El ajuste del sensor se realizó directamente mediante el envío de comandos tipo AT a través del monitor serial, ejecutando un script en el framework de Arduino. Para cada punto de calibración se utilizaron los comandos: Cal,mid,7.00, Cal,low,4.00 y Cal,high,10.00.

3.1.3.2. Sensor de conductividad eléctrica

Se utilizó una celda de conductividad Mini EC K=1.0 fabricada en grafito y PVC, que mide la conductividad aplicando AC entre dos electrodos. El módulo EZO-EC procesa la señal, realiza compensación térmica y comunica lecturas en $\mu\text{S}/\text{cm}$, TDS y salinidad mediante UART/I2C con comandos ASCII.

La calibración multipunto del sensor de conductividad (EC) se realizó siguiendo el protocolo oficial recomendado por Atlas Scientific. Para esto se emplearon dos soluciones patrón certificadas, con valores de $12.880 \mu\text{S}/\text{cm}$ y $80.000 \mu\text{S}/\text{cm}$ a $25 \text{ }^\circ\text{C}$. El módulo EZO-EC aplica por defecto una compensación automática de temperatura ajustada a $25 \text{ }^\circ\text{C}$, razón por la cual la calibración se llevó a cabo en condiciones controladas mediante un termostato de 35 W , estabilizando la temperatura en $25.2 \text{ }^\circ\text{C}$.

Al igual que con el sensor de pH, se utilizó un script Arduino que permitió ingresar los comandos ASCII (tipo AT) necesarios para la calibración. La rutina de calibración se ejecutó en el siguiente orden:

- CAL,clear ($0 \mu\text{S}/\text{cm}$): Realizado en agua destilada para eliminar cualquier calibración previa.
- CAL,mid,12880 ($12.880 \mu\text{S}/\text{cm}$): Solución patrón intermedia para ajustar la pendiente de la curva de respuesta.
- CAL,high,80000 ($80.000 \mu\text{S}/\text{cm}$): Solución patrón alta para definir el extremo superior del rango de medición.

Antes de cada paso de calibración, la celda de conductividad fue cuidadosamente enjuagada con la misma solución patrón que se utilizaría a continuación, eliminando así posibles residuos que pudieran afectar la precisión de la lectura. Una vez ejecutado cada comando, se esperó hasta que la señal del sensor se estabilizara (variación inferior al 1% durante al menos 10 segundos), garantizando así la repetibilidad y exactitud de los datos obtenidos.

Tras completar estos pasos, se verificó la linealidad de la respuesta midiendo no solo los tres puntos de calibración, sino también un estándar adicional de control. En todos los casos, el error máximo observado fue de $\pm 1.3 \%$ en el rango operativo (véase Figura 3.10).




Figura 3.10: Verificación de la linealidad del sensor de conductividad eléctrica (EC) en tres puntos de calibración.

3.1.3.3. Sensor de temperatura del agua

La medición de la temperatura del agua se realizó con un detector de temperatura de platino PT-1000 (RTD), cuyo valor de resistencia crece casi linealmente con la temperatura a razón de $0.385 \Omega/^{\circ}\text{C}$ en torno a 0°C . Según el modelo de Callendar–Van Dusen [80], la relación entre resistencia y temperatura viene dada por:

$$R(T) = R_0 (1 + \alpha T + \beta T^2), \quad (3.2)$$

donde para la clase B PT-1000 $R_0=1000 \Omega$ y la no linealidad queda por debajo del 0,3 % en el rango -50°C a 150°C .

El kit EZO-RTD aplica una excitación de corriente constante de 1 mA y mide la caída de tensión con un ADC de 24 bits. Gracias a esta combinación, el sistema alcanza una resolución teórica de 0.001°C y una estabilidad a largo plazo derivada de la alta pureza del filamento de platino y del encapsulado cerámico vítreo, que reduce tensiones mecánicas y minimiza efectos termoelectrónicos indeseados.

Para asegurar la exactitud, el RTD se contrastó frente a un calibrador Fluke 714B (incertidumbre $\pm 0.025^{\circ}\text{C}$) en un termostato de agua de 2 L. El proceso consistió en estabilizar el baño sucesivamente a cuatro temperaturas de referencia: 15°C (ambiente), 20°C , 25°C y 30°C . En cada punto, se tomaron 30 muestras a intervalos de 1 minuto y se calculó el promedio para mitigar el ruido de medida. Los resultados se ilustran en

la Figura 3.11.

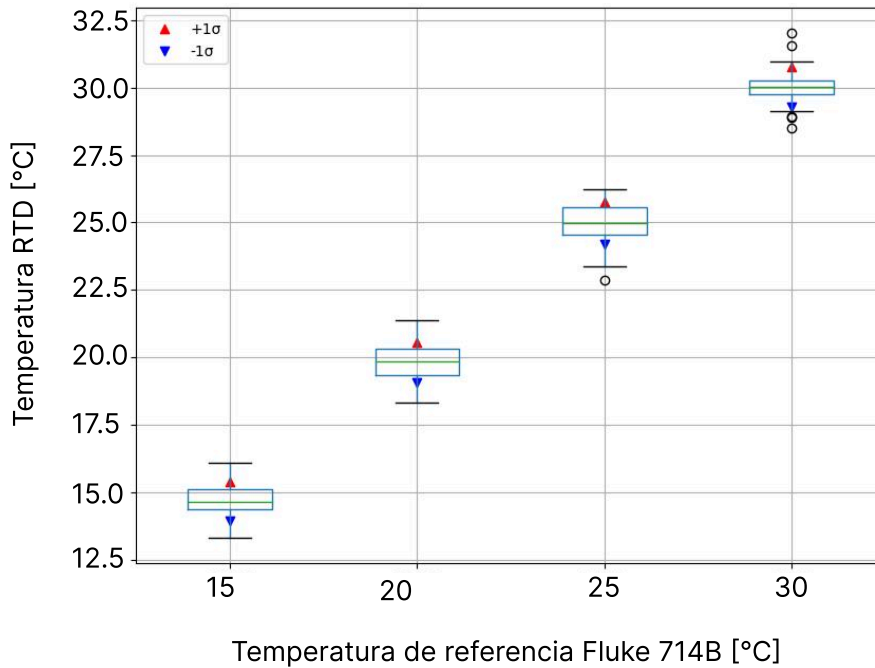


Figura 3.11: Distribución de las lecturas del sensor PT-1000 para cada temperatura de referencia, con marcadores de desviación estándar.

Dicha figura presenta un diagrama de cajas para cada grupo de mediciones, donde se visualiza la distribución de los 30 valores obtenidos por el RTD a cada temperatura de referencia. Las cajas resumen la mediana, el rango intercuartílico y posibles valores atípicos. Además, se incluyen marcadores adicionales correspondientes a la desviación estándar: los triángulos rojos y azules indican, respectivamente, una desviación estándar por encima y por debajo del valor medio. Esta representación permite evaluar la repetibilidad de las mediciones en cada punto y cuantificar la dispersión en torno al valor medio, proporcionando una estimación visual de la precisión del sensor en condiciones controladas. El patrón de dispersión observado es consistente con un comportamiento estable del RTD en el rango de operación, aunque con ligeras desviaciones sistemáticas respecto al valor nominal.

$$T_{\text{ref}} = 0.9838 T_{\text{RTD}} + 0.3398 \quad (R^2 = 0.9999)$$

3.2. Lógica de control embebida

3.2.1. Control de variables ambientales

El siguiente paso consistió en identificar las condiciones del entorno real en el cual se instalarían los sistemas de sensado. La cámara de cultivo empleada tiene dimensiones:

$$L = 1.4 \text{ m}, \quad A = 1.4 \text{ m}, \quad H = 2.0 \text{ m},$$

por lo que su volumen total de la cámara de cultivo en este caso es igual a:

$$V = L \times A \times H = 1.4 \text{ m} \times 1.4 \text{ m} \times 2.0 \text{ m} = 3.92 \text{ m}^3.$$

Dado que durante la fase vegetativa de Cannabis es recomendable renovar completamente el aire cada minuto, el caudal volumétrico mínimo necesario en nuestro caso se calculó como:

$$Q = \frac{V}{\Delta t} = \frac{3.92 \text{ m}^3}{1 \text{ min}} = 3.92 \text{ m}^3/\text{min}.$$

Expresado en m^3/h estaría dado por:

$$Q = 3.92 \frac{\text{m}^3}{\text{min}} \times 60 \frac{\text{min}}{\text{h}} = 235.2 \text{ m}^3/\text{h}.$$

Para poder garantizar este caudal, se instaló un extractor VIVOSUN R4 (720 CFM, conducto de 4") en la zona superior y un intractor VIVOSUN D4 (195 CFM, conducto de 4") en la parte inferior de la cámara de cultivo (Figura 3.15).




Figura 3.12: Esquema de la cámara de crecimiento controlada.

Las mediciones preliminares, realizadas con cuatro plantas en fase vegetativa y un foto-

periodo de 18 h de luz / 6 h de oscuridad, se llevaron a cabo en una sala térmicamente aislada donde la temperatura exterior oscila entre 11 °C y 25 °C. Aun así, los registros internos mostraron variaciones de 16 °C a 27 °C en temperatura y de 60 % a 95 % en humedad relativa. La Figura 3.13 compara un día caluroso y uno frío: cuando la temperatura aumenta, la humedad relativa desciende por debajo del 70 % (gráficas c y d). Sin embargo, en las gráficas a y b se observan descensos bruscos de humedad relativa (aproximadamente entre 10 y 25 puntos porcentuales en pocos minutos) sin disminución térmica equivalente, lo que sugiere que el extractor renueva el aire pero no basta para evacuar la humedad acumulada. Además, la temperatura máxima no alcanzó los 25 °C, lo que indica la necesidad de añadir un sistema de calefacción con termostato para elevar aproximadamente 1.5 °C la temperatura durante los períodos de luz apagada y cumplir con el valor de consigna establecido.

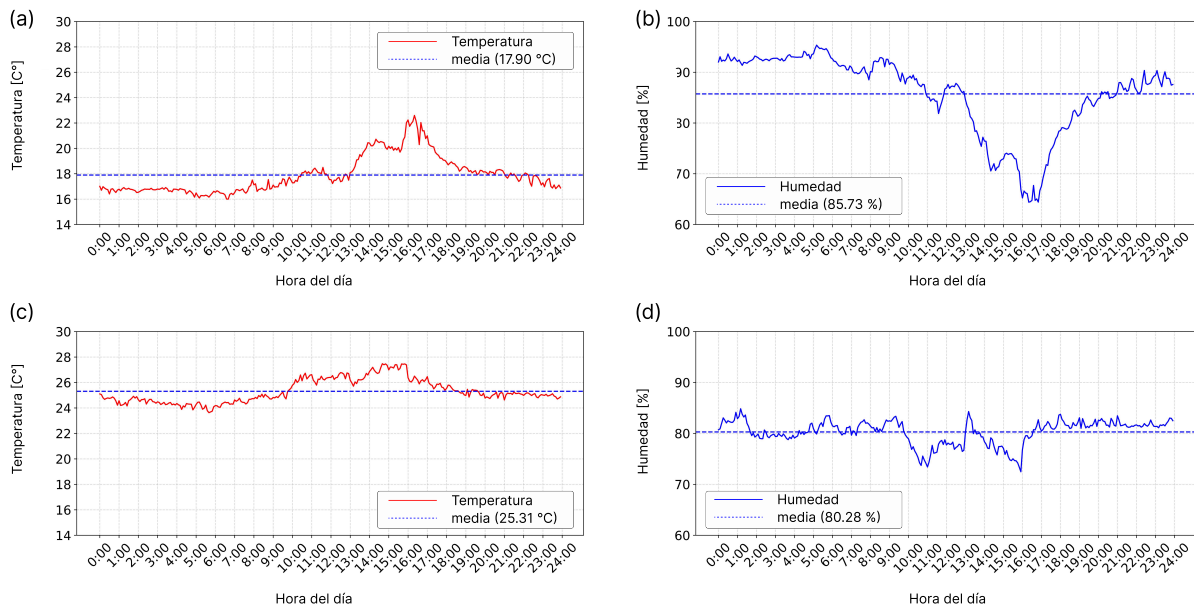


Figura 3.13: Evolución temporal de la temperatura (línea roja) y la humedad relativa (línea azul) en el interior de la cámara de cultivo, registrada cada minuto durante un día frío (paneles a y b) y un día caluroso (paneles c y d). Las líneas punteadas representan el valor medio obtenido.

La estrategia de regulación implementada para dar solución a este problema se basó en un control ON/OFF escalonado con un esquema de prioridades para garantizar la estabilidad del microclima dentro del rango de 22–27 °C para la temperatura y 60–70 % para la humedad relativa. En primer lugar, se priorizó el aporte de calor; a continuación, la extracción de aire; y, finalmente, la deshumidificación. El algoritmo realizaba lecturas en tiempo real de temperatura y humedad relativa cada minuto. Cuando la temperatura descendía por debajo de 24.5 °C, el calefactor se activaba automáticamente y permanecía encendido hasta alcanzar 25.5 °C. Por otro lado, si la humedad relativa superaba el 70 % o la temperatura excedía los 26 °C, se encendía el extractor, asistido de forma continua por un intractor de caudal fijo, deteniéndose únicamente cuando la humedad relativa caía por debajo de 65 % y la temperatura volvía a situarse por debajo de 25 °C.

En los casos en que la humedad relativa continuaba elevada (por encima del 75 %) pero la temperatura no justificaba la extracción, entraba en funcionamiento un deshumidificador cuyo controlador interno está programado para mantener el valor objetivo en 65 %.

Para evitar ciclos de conmutación excesivos y prolongar la vida útil de los equipos, a cada dispositivo se le asignó una histéresis mínima ($\pm 0,5$ °C para el calefactor y ± 5 % HR para los sistemas de extracción y deshumidificación) y un tiempo mínimo de encendido/apagado (≥ 2 min para calefactor y extractor; ≥ 5 min para el deshumidificador). Esta combinación de umbrales y temporización garantizó que la respuesta del sistema fuera ágil ante variaciones críticas, pero evitó activaciones precipitadas ante fluctuaciones transitorias. Además, la lógica de prioridad aseguró que la corrección térmica se ejecutara antes de proceder a la extracción de calor o al secado del aire, y sólo cuando estas acciones no restablecían el microclima en el rango deseado (22–27 °C y 60–70 % HR), se llevaba a cabo la deshumidificación, optimizando el consumo energético y manteniendo condiciones óptimas para el desarrollo vegetativo de las plantas de Cannabis.

La Figura 3.14 muestra el desempeño del control ON/OFF escalonado durante un ciclo de 24 h con un registro por minuto. La temperatura interna se mantuvo entre 24.0 y 27.5 °C con una media de 25.3 °C; amplitud diaria < 3.5 °C. El calefactor sostuvo el mínimo nocturno cerca de 24 °C, mientras que el extractor limitó el ascenso causado por la iluminación LED y las ganancias térmicas vespertinas. De forma analoga, la humedad relativa se mantuvo en el intervalo 59–69 % (promedio de 65.3 %). Los pulsos del extractor y del deshumidificador impidieron que la humedad relativa superara el 70 %, aunque se observaron descensos rápidos a 59 % alrededor de las 11:00 y 15:30. En conjunto, el sistema propuesto converge al intervalo climático requerido y mantiene una variabilidad aceptable.

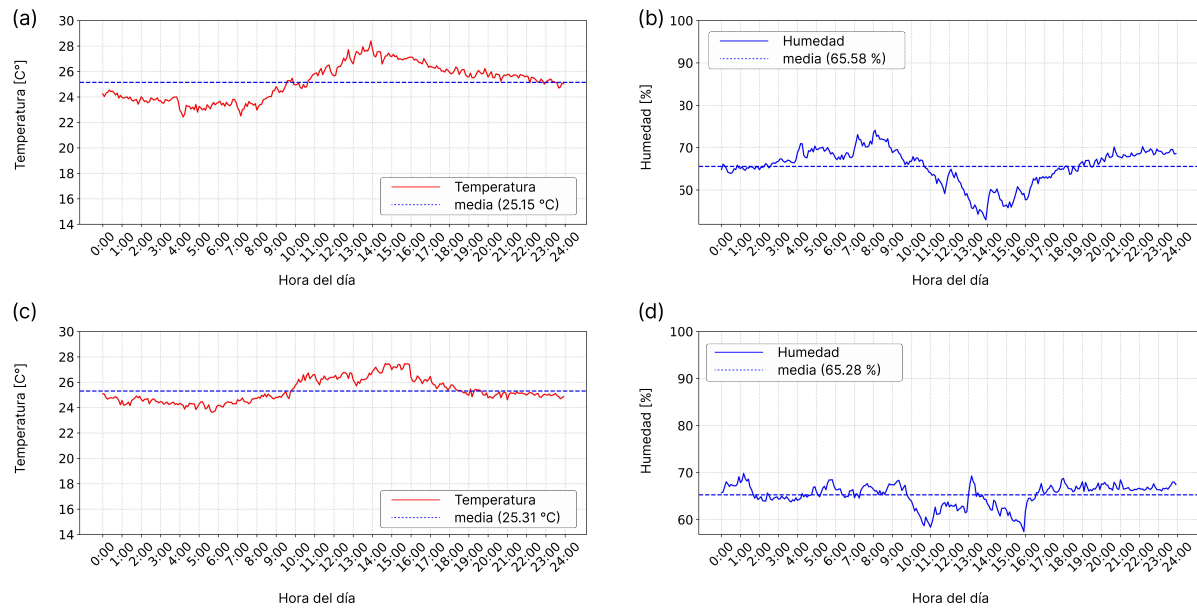


Figura 3.14: Evolución temporal de la temperatura (línea roja) y la humedad relativa (línea azul) en el interior de la cámara de cultivo, registrada cada minuto durante un día frío (paneles a y b) y un día caluroso (paneles c y d). Las líneas punteadas indican los valores medios registrados. En este caso, el sistema implementó un control ON/OFF escalonado con prioridad—calefacción, extracción y deshumidificación—para mantener la temperatura entre 22–27 °C y la humedad relativa entre 60–70 %.

3.2.1.1. Actuadores

En la Tabla 3.5 se detallaron los dispositivos principales encargados de la renovación de aire y el control de humedad en la cámara de cultivo. Para la extracción se empleó un ventilador VIVOSUN R4 de conducto de 4" con un caudal de 720 CFM, mientras que el intractor correspondió a un VIVOSUN D4 de 195 CFM. La recirculación interna se garantizó mediante un ventilador AeroWave E6 de 6" y 350 CFM, optimizando la homogeneidad térmica al interior de la cámara de cultivo. Por otro lado, la deshumidificación quedó a cargo de un modelo compacto capaz de extraer 0.25 L/día, y el aporte de calor se realizó con un calefactor eléctrico de 1500 W provisto de un pequeño ventilador de 25 W para distribuir el aire caliente. En la Tabla 3.5 además se relaciona el costo aproximado de cada uno de estos componentes en dólares estadounidenses.

Tabla 3.5: Especificaciones técnicas y costo aproximado de los equipos de ventilación, deshumidificación y calefacción empleados.

Función	Nombre / Modelo	Caudal / Capacidad	Voltaje	Costo (USD)
Extractor	VIVOSUN R4 4" In-line Duct Fan	720 CFM	110-120 V AC	\$75
Intractor	VIVOSUN D4 4" In-line Duct Fan	195 CFM	110 V AC	\$60
Recirculación	VIVOSUN AeroWave E6 Grow Tent Fan, 6"	350 CFM	110 V AC	\$50
Deshumidificador	VIVOSUN Mini Dehumidifier 500 mL	0.25 L día ⁻¹	110 V AC	\$40
Calefactor	AgiiMan Electric Greenhouse Heater	1 500 W (25 W fan)	110-120 V AC	\$49.99

En la Figura 3.15 puede observarse el montaje integrado de estos equipos en la cámara de crecimiento, con el extractor situado en la parte superior para evacuar el aire viciado, el intractor e intercambiadores posicionados estratégicamente para asegurar un flujo uniforme, y el deshumidificador y calefactor ubicados en la base para optimizar la distribución de humedad y temperatura.




Figura 3.15: Fotografías de los actuadores instalados al interior de la cámara de crecimiento controlada.

3.2.2. Control de calidad del agua

El núcleo de automatización del sistema hidropónico reside en un microcontrolador ESP32 DEV 1 que vincula, en tiempo real, las lecturas de los sensores con los actuadores encargados de dosificar nutrientes y correctores de pH. Dado que el objetivo primario es mantener los parámetros dentro de los rangos permitidos y que la dinámica hidráulica del depósito es relativamente lenta (la mezcla del tanque tarda entre 10 y 20 minutos en estabilizarse después de añadir nutrientes) ($\tau \approx 10-15$ min), se optó por una estrategia de control ON/OFF con histéresis, suficiente para garantizar estabilidad sin sobreinversión computacional ni riesgo de saturación de los actuadores. Todas las decisiones se ejecutan localmente; la nube sólo recibe *logs* para trazabilidad y análisis retrospectivo.

Los puntos de consigna para el pH y la EC se fijaron en:

- pH = 5.8 ± 0.2 ,
- EC = 900 ± 150 mS/cm.

El esquema simplificado permite una implementación clara y robusta en el ESP32, y puede describirse en pseudocódigo de la siguiente manera (ver Algoritmo 1):

Algoritmo 1: Control ON/OFF con histéresis para pH y EC

Input: pH , EC medidos; Δ_{pH} , Δ_{EC}
Output: Estado de cada bomba (ON/OFF)

- 1 **if** $pH > 6.0 + \Delta_{pH}$ **then**
- 2 └ activar bomba de H_3PO_4 ;
- 3 **if** $pH < 5.6 - \Delta_{pH}$ **then**
- 4 └ desactivar bomba de H_3PO_4 ;
- 5 **if** $EC < 1.8 - \Delta_{EC}$ **then**
- 6 └ activar bombas Nutriente A y Nutriente B;
- 7 **if** $EC > 2.2 + \Delta_{EC}$ **then**
- 8 └ desactivar bombas Nutriente A y Nutriente B;

Este controlador ON/OFF con histéresis demostró ser suficiente para mantener los parámetros dentro de los rangos deseados, evitando tanto la inestabilidad por oscilaciones rápidas como el desgaste prematuro de las bombas por ciclos excesivos.

3.2.2.1. Dispositivos de dosificación y ajuste

Para la dosificación de nutrientes y regulación del pH se emplearon tres bombas peristálticas modelo BOM-PER-12V (5027), cada una dedicada respectivamente a Nutriente A, Nutriente B y una última para el corrector de pH. La Tabla 3.6 lista las especificaciones más relevantes reportadas por el fabricante.

Tabla 3.6: Especificaciones de la bomba peristáltica BOM-PER-12V.

Parámetro	Valor
Tensión nominal	12 VDC
Corriente típica	80 mA
Caudal (agua)	0–100 mL/min
Velocidad del eje	0.1–100 rpm
Diámetro del tubo (int./ext.)	2.5 mm / 4.7 mm
Dimensiones del motor	27.6 mm \varnothing \times 37.9 mm alto
Dimensiones del cabezal	31.7 mm \varnothing \times 20.1 mm alto
Reversibilidad del flujo	Inversión de polaridad

Para garantizar una dosificación de nutrientes exacta, las bombas se calibraron mediante ensayos gravimétricos con una balanza analítica de alta precisión. En cada prueba se

llenó un recipiente sobre la balanza y se hizo funcionar la bomba durante un intervalo controlado de 60 s, registrando la masa de líquido dispensado. Este procedimiento se repitió tres veces por cada tipo de solución, lo que permitió calcular el caudal medio y su variabilidad. La balanza utilizada contaba con un rango de 0–200 g, precisión de 0,01 g y era verificada antes de cada serie con pesas estándar trazables, asegurando la fiabilidad de las mediciones.

Para calcular el caudal volumétrico de cada bomba, se registró la masa acumulada Δm sobre la balanza analítica y se empleó la densidad conocida del líquido ρ (aproximadamente 1 g/mL para soluciones acuosas), aplicando la relación:

$$Q = \frac{\Delta m}{\rho \Delta t},$$

donde Δt es el tiempo de prueba, en este caso 60 s. A continuación se describen las tres pruebas realizadas:

- **Agua destilada:** Operación continua durante 60 s; se realizaron $n = 5$ mediciones gravimétricas, promediando $72 \pm 3 \text{ mL} \cdot \text{min}^{-1}$ (CV = 4.2 %).
- **Nutrientes Bionova A/B:** Prueba idéntica; el flujo medio cayó un 3 % debido a la mayor viscosidad.
- **Ácido fosfórico 30 %:** Operación en pulsos de 5 s; se registró un flujo estable de $68 \pm 2 \text{ mL} \cdot \text{min}^{-1}$, sin degradación del tubo tras 100 ciclos.

A partir de las pruebas gravimétricas se obtuvo para cada líquido un caudal medio \bar{Q} expresado en $72 \pm 3 \text{ mL/min}$. Para incorporar ese resultado al firmware—cuyo algoritmo de control opera la bomba en pulsos ON/OFF—se define el coeficiente volumétrico.

$$k = \frac{\bar{Q}}{60} [\text{mL/s}],$$

el cual indica cuántos mililitros entrega la bomba por segundo cuando funciona a la tensión nominal de 12 V. Durante la operación, el microcontrolador sólo necesita conocer el volumen objetivo V_{target} (mL); el tiempo que la bomba debe permanecer activada se calcula mediante la ecuación:

$$t_{\text{ON}} = \frac{V_{\text{target}}}{k} [\text{s}],$$

tras lo cual el programa genera un delay($t_{\text{ON}} \times 1000$) y desenergiza la salida. De este modo, la tabla de coeficientes k , una entrada por fluido, permite traducir volumen deseado en tiempo de activación.

Los coeficientes obtenidos alimentan una tabla de mL/s que el firmware consulta para convertir cada pulso de la bomba en volumen dosificado, cerrando así el lazo de control diseñado en el Algoritmo 1.

Los valores de caudal medio \bar{Q} , coeficiente de variación (CV) y coeficiente volumétrico k obtenidos para cada solución se resumen en la Tabla 3.7.

Tabla 3.7: Resultados de las pruebas volumétricas de la bomba BOM-PER-12V (n = 5).

Solución	Modo y tiempo	Caudal medio Q (mL/min)	CV (%)	Observación	k (mL/s)
Agua destilada	Continua, 60 s	72 ± 3	4.2	Referencia gravimétrica	1.20
Nutrientes Bionova A/B	Continua, 60 s	70 ± 3	4.3	3 % menos por viscosidad	1.17
Ácido fosfórico 30 %	Pulsos, 5 s	68 ± 2	2.9	Sin degradación tras 100 ciclos	1.13

La Figura 3.16 muestra un histograma comparativo de los caudales medios y sus desviaciones estándar para los tres fluidos evaluados. Se observan barras sólidas que representan el valor medio de cada caudal, con líneas de error que indican la variabilidad medida. El agua destilada presenta el mayor flujo medio (72 mL/min) y una dispersión relativamente baja (CV 4.2 %), mientras que los nutrientes Bionova A/B reducen ligeramente el caudal a 70 mL/min (CV 4.3 %), reflejando el efecto de la mayor viscosidad. El ácido fosfórico al 30 % muestra el flujo medio más bajo (68 mL/min) y la menor variabilidad (CV 2.9 %), lo que indica un comportamiento muy consistente incluso bajo operación en pulsos.




Figura 3.16: Histograma del caudal medio y su desviación estándar para la bomba peristáltica BOM-PER-12V, medido en cinco repeticiones ($n=5$) con tres soluciones distintas: agua destilada, nutrientes Bionova A/B y ácido fosfórico al 30 %. Cada barra muestra el caudal promedio (mL/min) y las líneas de error indican la variabilidad observada en los ensayos.

Este análisis gráfico confirma la fiabilidad de la caracterización gravimétrica y pone de manifiesto la necesidad de ajustar individualmente el coeficiente volumétrico k para cada tipo de fluido en el firmware. De este modo, al consultar la tabla de k en tiempo real, el controlador puede convertir de forma precisa cualquier volumen objetivo en el tiempo de activación de la bomba, asegurando dosificaciones reproducibles y optimizando el uso de reactivos.

3.2.2.2. Resultados del control

En esta sección se detallan los ensayos de validación del módulo de control “Hidro”, todos ellos realizados con agua potable como fluido base. Cada prueba siguió la misma secuencia metodológica:

- (i) Se realizó la adición gradual de los nutrientes Bionova A y B hasta alcanzar el punto de consigna de EC, para este caso se estableció en $\sim 900 \mu\text{S}/\text{cm}$.
- (ii) Se llevó a cabo la corrección del pH mediante dosis pulsadas de H_3PO_4 al 30 %, de esta manera se alcanzó un pH DE 6.0.
- (iii) Se estableció un periodo de 24 horas tiempo antes de iniciar el siguiente ciclo.

Se programaron cuatro ciclos de 20 min cada uno, con mediciones de EC y pH cada 30 s, lo que generó un total de cuarenta registros por magnitud en cada ciclo. Para calcular el

tiempo de actuación de las bombas, se emplearon los coeficientes volumétricos obtenidos en la fase de calibración, $k_{Nutrientes}=1.17 \text{ mL/s}$ y $k_{\text{Ácido}}=1.13 \text{ mL/s}$.

La evolución de la EC durante la dosificación se resume en la Tabla 3.8 y se visualiza en la Figura 3.17. En todos los ensayos, las bombas peristálticas entraron en funcionamiento entre 21.s y 22.s para dispensar el volumen de nutriente necesario ($\approx 25, \text{mL}$) y llevar la EC hasta el set point. Adicionalmente, de la Figura 3.17 se observa que las trayectorias individuales de cada ensayo revelan pequeñas variaciones en la pendiente de subida y en el tiempo de estabilización, reflejando diferencias en la viscosidad inicial del agua y en la respuesta de las bombas. Por ejemplo, el Ensayo 1 presenta un ascenso más pronunciado y un tiempo de estabilización corto (6 min), mientras que el Ensayo 4 exhibe un incremento más gradual y un periodo de reposo prolongado (9.5 min). A pesar de esta variabilidad temporal en los cuatro ensayos, la EC final se mantuvo consistentemente entre 850 y 902 $\mu\text{S/cm}$, lo cual cumple rigurosamente con la tolerancia operativa del sistema ($\pm 6 \%$) para aplicaciones de fertirrigación.

Tabla 3.8: Parámetros de dosificación de Bionova A y B y EC final obtenida.

Ensayo	$T_{\text{stab}}(\text{EC})(\text{min})$	Bionova A		Bionova B		$\text{EC}_{\text{final}}(\mu\text{S}\cdot\text{cm}^{-1})$
		Vol. (mL)	$t_{\text{ON}}(\text{s})$	Vol. (mL)	$t_{\text{ON}}(\text{s})$	
1	6.0	24	20.5	24	20.5	874
2	7.5	26	22.2	26	22.2	902
3	6.3	25	21.4	25	21.4	850
4	9.5	25	21.4	25	21.4	884

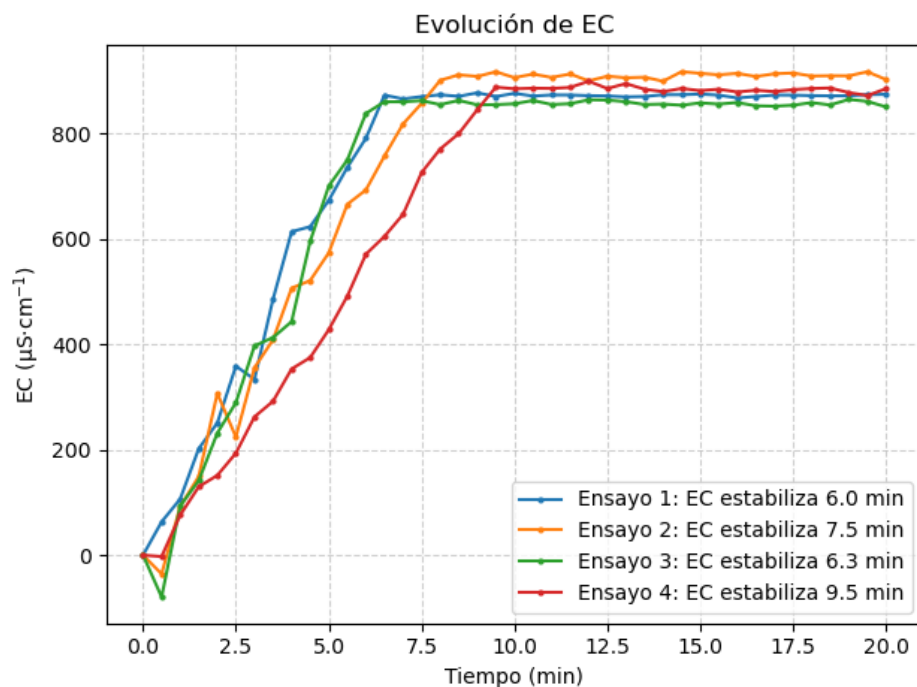


Figura 3.17: Evolución temporal de la conductividad eléctrica en los cuatro ensayos de validación del módulo “Hidro”. Cada curva muestra los cuatro ciclos de dosificación de 20 min con muestreo cada 30 s.

A continuación, la tabla 3.9 y la figura 3.18 sintetizan la dinámica de ajuste de pH durante los cuatro ensayos de validación. Tras la dosificación inicial de nutrientes, el pH descendió hasta aproximadamente 6.5. Para alcanzar el set-point de $\text{pH} = 5.8$, se aplicaron pulsos de ácido fosfórico al 30 %, con duraciones de 8.0 s a 9.7 s, tal como indica la columna de t_{ON} . El tiempo de estabilización, definido como el lapso necesario para mantener el pH dentro de ± 0.02 unidades alrededor de la consigna, osciló entre 12.5 min (Ensayo 1) y 16.0 min (Ensayo 4), evidenciando una cinética más lenta que la de la EC, debido tanto a la inercia ácido-base de la disolución como al retardo de la sonda de pH.

Tabla 3.9: Parámetros de dosificación de ácido fosfórico al 30 % y pH final obtenido.

Ensayo	T_{stab} (pH) (min)	Vol. (mL)	t_{ON} (s)	pH final
1	12.5	10	8.9	5.89
2	14.5	11	9.7	5.79
3	13.5	10	8.9	5.78
4	16.0	9	8.0	5.74

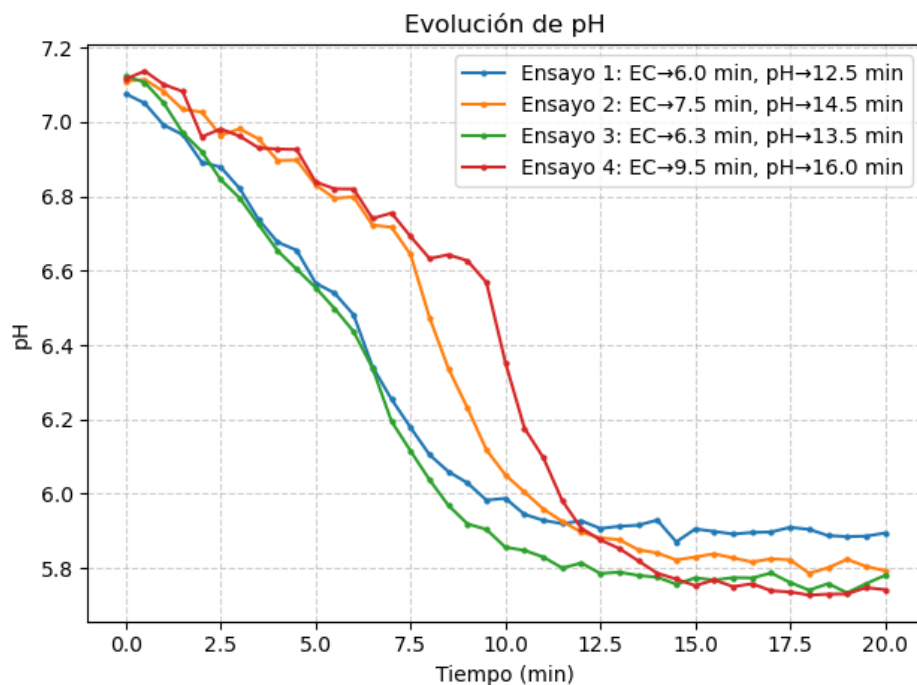


Figura 3.18: Evolución del pH en los cuatro ensayos de validación del módulo “Hidro”. Cada curva muestra los ciclos de 20 min con muestreo cada 30 s.

En conjunto, los cuatro ensayos confirman que el algoritmo ON/OFF con histéresis, combinado con la caracterización volumétrica de las bombas, permite alcanzar de forma repetible los set-points de EC y pH con errores inferiores al 6% y 0.02 unidades, respectivamente. Las pequeñas variaciones observadas en los tiempos de estabilización demuestran la influencia de la dinámica hidráulica y de la perturbación aleatoria introducida; sin embargo, la convergencia final dentro de las bandas específicas valida la robustez del lazo de control para aplicaciones de cultivo hidropónico a escala experimental.

3.3. Infraestructura de Borde (Edge Computing)

La arquitectura de la infraestructura de borde fue diseñada conforme a principios fundamentales de la ingeniería de software, con el objetivo de desarrollar un sistema eficiente, escalable y mantenible en el tiempo. La organización de los componentes siguió los principios de descomposición y modularidad, separación de responsabilidades, satisfacción de requisitos funcionales y no funcionales, asincronía y capacidad de evolución. En este marco conceptual, se implementaron seis módulos funcionales con responsabilidades claramente delimitadas, además de un módulo principal que actúa como núcleo integrador del sistema, donde se consolidan la lógica operativa y las reglas de negocio necesarias para garantizar un funcionamiento óptimo y coherente del sistema en su conjunto.

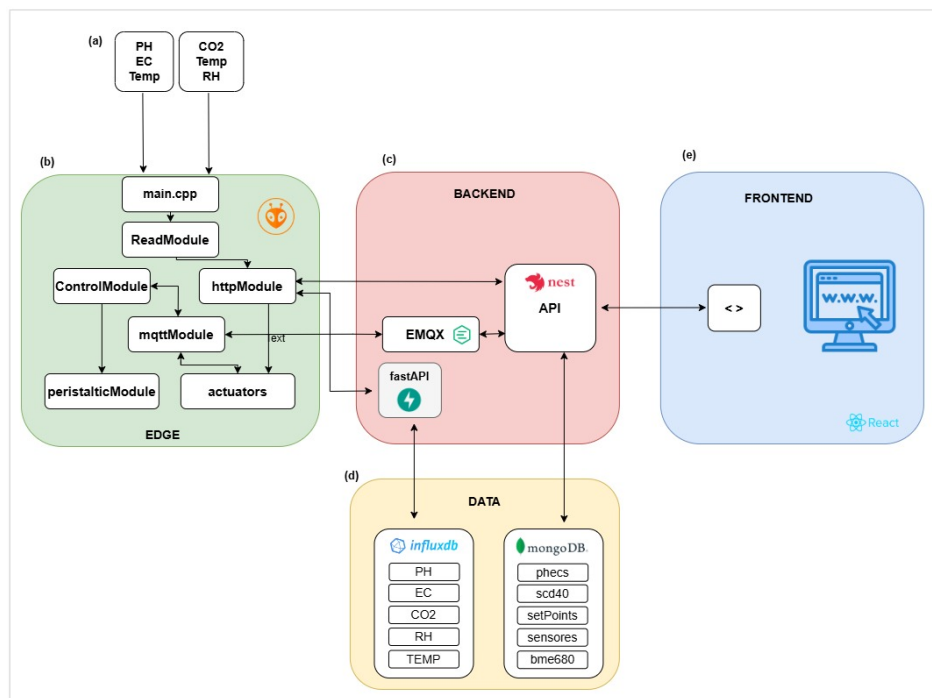


Figura 3.19: Arquitectura IoT; (a) Sensores en sitio; (b) Nodo Borde; (c) Nodo Backend; (d) Nodo Bases de datos; (e) Nodo Frontend.

El éxito de la infraestructura IoT no reside únicamente en la calidad de los sensores descritos anteriormente; también en la eficiencia de la comunicación entre sus componentes. La infraestructura EDGE actúa como puente entre el entorno experimental y los servicios en la nube: en él confluyen todos los sensores y actuadores previamente caracterizados, así como la lógica de automatización y los algoritmos de control embebidos. La arquitectura de borde se sustenta en cuatro pilares—**monitoreo, control, automatización y comunicación**. Los tres primeros ya han sido abordados en secciones anteriores; la sección siguiente se centra en el cuarto pilar, detallando los subsistemas de comunicación y su papel en el flujo integral de datos y comandos.

3.3.1. Módulos de comunicación

Para garantizar un intercambio de información seguro, robusto y gobernable, el subsistema de comunicación se ha descompuesto en módulos especializados, cada uno asociado a un protocolo y a una responsabilidad claramente delimitada.

HttpModule: Esta clase está diseñada para configurarse dinámicamente mediante parámetros que incluyen el DNS del servidor, el puerto de escucha, la carga útil en formato JSON y la ruta que identifica al sensor responsable de la adquisición de datos. Asimismo, expone el método `ActivateActuator`, el cual permite activar los relés de entrada, salida y recirculación de agua mediante el envío de solicitudes HTTP dirigidas al servidor configurado.

MqttModule: Esta clase permite la configuración dinámica de la conexión al broker MQTT (EMQX) mediante TCP/IP, definiendo parámetros como la dirección del broker, el puerto de comunicación y el tópico de suscripción. Proporciona métodos para publicar los datos recopilados por los sensores en el tópico correspondiente y para suscribirse a mensajes de control que, al recibirse, disparan la activación de los relés del sistema. Además, al soportar los distintos niveles de Calidad de Servicio (QoS) de MQTT, garantiza una transmisión fiable y eficiente, facilitando su integración en la arquitectura de red distribuida.

ReadModule: Esta biblioteca agrupa los procedimientos necesarios para inicializar los sensores y configurar la comunicación con el microcontrolador a través de los protocolos I2C y UART. Implementa métodos encargados de adquirir los datos brutos de los sensores y formatearlos en un archivo JSON estructurado con los parámetros medidos. Además, optimiza el flujo de información entre los sensores y el microcontrolador, garantizando una transmisión continua y fiable que acelera el desarrollo y refuerza la robustez del sistema.

WifiModule: Esta clase centraliza la gestión de la conectividad Wi-Fi, permitiendo la configuración dinámica de parámetros como SSID, contraseña y modo de operación (estación o punto de acceso). Implementa métodos para:

- Iniciar y mantener la conexión inalámbrica, comprobando periódicamente la intensidad de la señal (RSSI) y el estado de enlace.
- Detectar y registrar errores de autenticación o de enlace, y reintentar la conexión de forma automática siguiendo reglas configurables (intervalos de reconexión, número máximo de intentos).
- Exponer un mecanismo de notificaciones visuales (LEDs y pantalla integrada) que refleja el estado actual de la red (conectado, desconectado, reconectando).

Gracias a estas funcionalidades, simplifica la configuración inicial, facilita la resolución de incidencias y asegura un uso óptimo y estable de las capacidades Wi-Fi dentro del sistema.

ControlModule: Esta clase gestiona la regulación automática de la EC y el pH de la solución nutritiva. Implementa las siguientes funcionalidades:

- Carga y almacena los parámetros de referencia (**EC_target**, **pH_target**).
- Compara periódicamente las mediciones de EC y pH con los valores de referencia.
- Dispara el protocolo de control (ON/OFF) mencionado en secciones anteriores durante el intervalo de homogeneización configurado cuando detecta desviaciones.
- Marca el estado de control como **true** al completar el ciclo y programa un reinicio automático a **false** tras 24 horas, reactivando así el protocolo y la recirculación de agua.

Este módulo garantiza niveles uniformes de nutrientes, optimizando las condiciones de crecimiento en el sistema.

PeristalticModule: Esta clase gestiona la activación de las bombas peristálticas responsables de dispensar nutrientes en el sistema. Implementa:

- Recepción de comandos del **ControlModule**, definiendo parámetros de dosificación como duración y frecuencia de los pulsos.
- Control preciso del motor peristáltico para asegurar el volumen y tiempo de dispensación configurados.
- Monitoreo continuo del estado operativo, con detección y notificación de anomalías (atascos, fallos de motor).
- Registro de los ciclos de dosificación para trazabilidad y análisis de desempeño.

Este módulo garantiza una dosificación meticulosa y eficiente, optimizando la distribución de nutrientes en el sistema.

main.cpp: Este archivo principal estructura el sketch de Arduino e implementa la lógica de configuración y ejecución del sistema. Incluye:

- Inicialización de bibliotecas y protocolos de comunicación (I2C, UART, Wi-Fi).
- Configuración de pines, parámetros de hardware y creación de instancias de los módulos funcionales.
- Gestión de la conexión inalámbrica, supervisando el estado de la red y delegando reconexiones automáticas.
- Asignación de tareas entre los dos núcleos del ESP32 mediante FreeRTOS:
 - *Core 0*: adquisición de datos y control de actuadores.
 - *Core 1*: comunicación con la nube y supervisión de estado.
- Implementación del bucle principal (**loop**) con llamadas secuenciales a los módulos: **ReadModule**, **ControlModule**, **PeristalticModule**, **MqttModule**, y **HttpModule**.

Esta arquitectura de doble núcleo optimiza el rendimiento al separar las responsabilidades de adquisición y comunicación, garantizando un control eficiente y una transmisión de datos fluida.

3.3.2. Plataforma de backend y frontend

La plataforma de aplicación Backend coordina la interacción entre los distintos componentes del sistema a través de dos canales complementarios: una API RESTful y un broker MQTT. La API RESTful, desplegada en contenedores Docker para garantizar un entorno reproducible, expone operaciones CRUD (Crear, Leer, Actualizar, Eliminar) mediante el protocolo HTTP y se ha implementado con NestJS siguiendo un paradigma modular que facilita la ampliación y el mantenimiento del código. Paralelamente, el broker MQTT administra el intercambio de mensajes entre los actuadores del Edge y la lógica de control del frontend.

Para el almacenamiento y la gestión de datos, la API REST se integra con MongoDB mediante Mongoose en un servicio Node.js, optimizando la definición de esquemas y las

operaciones sobre la base de datos. Adicionalmente, se ha incorporado un canal WebSocket que establece una comunicación bidireccional en tiempo real entre el frontend y el Edge, mejorando la experiencia de usuario y reduciendo la latencia en la actualización de estados y datos de sensores.

La capa de frontend se implementó con React.js bajo el patrón arquitectónico Modelo–Vista–Controlador, lo que permitió modularizar la lógica de negocio, la interfaz y el flujo de eventos. React.js facilita la construcción de componentes reutilizables y declarativos, optimizando el tiempo de desarrollo y el mantenimiento del código.

Para asegurar una experiencia en tiempo real y de baja latencia, se estableció un canal WebSocket persistente con Smartgrow-Backend, habilitando la actualización instantánea de datos. Asimismo, se integró MQTT como protocolo de mensajería ligera para la comunicación fiable con el nodo Borde, permitiendo tanto la recepción de eventos de usuario como el control manual de actuadores.

3.3.3. Base de datos e interfaz gráfica

Para garantizar la seguridad y la alta disponibilidad de la información, se implementó una arquitectura de redundancia de datos que evita la dependencia de un único punto de almacenamiento. En el servidor local se despliega, mediante Docker Compose, un microservicio de InfluxDB encargado de recibir en tiempo real las métricas transmitidas desde el Edge a través de MQTT. Esta configuración asegura que, incluso ante una falla del backend principal, los datos de series temporales permanezcan accesibles y consistentes.

InfluxDB, optimizado para el manejo de grandes volúmenes de datos de series temporales y consultas ad hoc, proporciona una interfaz web con paneles y cuadernos personalizables para su visualización y análisis preliminar. Tras el procesamiento y la agregación de la información, el backend persiste los resultados en MongoDB, estableciendo un segundo nivel de seguridad y consistencia de los datos.

La infraestructura se soporta sobre servidores con Raspbian Bullseye y Ubuntu Bionic Beaver, donde se ejecutan Docker v23.0.2 y Docker Compose v1.25.0 para garantizar la escalabilidad, el aislamiento de servicios y la facilidad de mantenimiento del sistema.

La GUI de Smartgrow-DataControl se diseñó para optimizar la experiencia del usuario, facilitando tanto la visualización de datos en tiempo real como el control de los actuadores del sistema [49]. Como se muestra en la Figura 3.20, la interfaz incluye:

- (1) **Barra de navegación:** Ubicada en la parte superior, permite alternar entre las cuatro secciones principales (Weather, Hydro, Dispositivos de Salida y Puntos de Ajuste).
- (2) **Indicadores de estado:** Muestran el estado de los actuadores (encendido/apagado) y la conectividad MQTT con el servidor. Con estos indicadores se tiene una visión inmediata del estado operativo del sistema.

- (3) **Panel de datos en tiempo real:** La sección actualmente activa, Weather en la Figura 3.20, despliega variables ambientales críticas temperatura, humedad relativa, CO₂, VPD, PPF y PPFD y el grafico de la SPF. Tambien muestra la ultima fecha de actualizacion de cada variable.

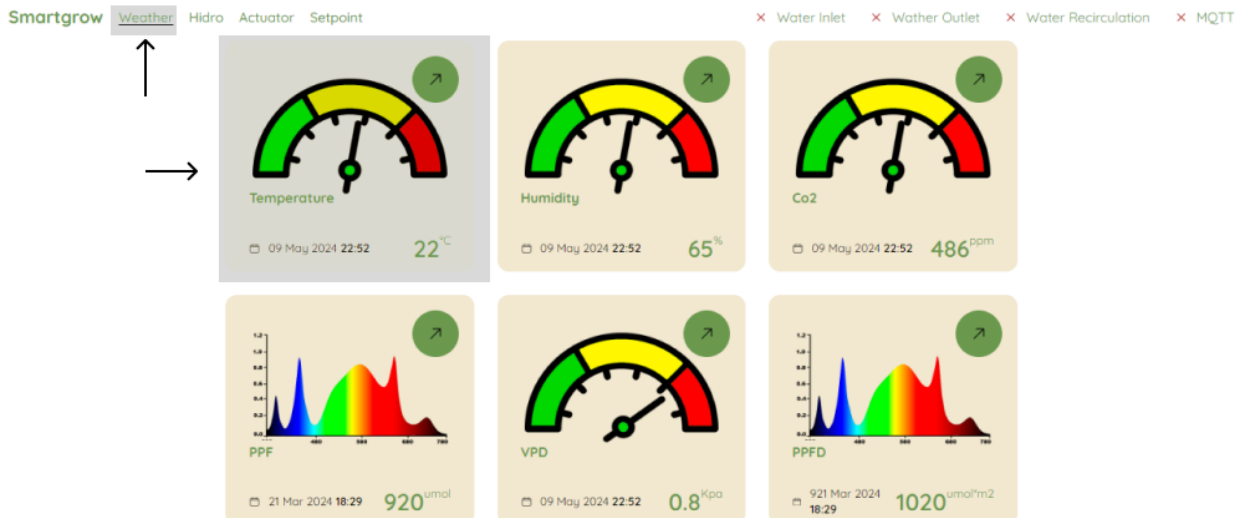


Figura 3.20: Interfaz GUI de la pestaña *CannaWeather* en Smartgrow-DataControl: visualización en tiempo real de las variables ambientales — temperatura, humedad relativa, CO₂, VPD, PPF y PPFD— con fecha de última actualización.



Figura 3.21: Interfaz GUI de control hidroponía en Smartgrow-DataControl: (1) visualización de parámetros de calidad del agua y fecha de última actualización; (2) activación manual de válvulas de entrada y salida; (3) configuración de puntos de consigna de pH y EC.

Capítulo 4

Evaluación espectral y crecimiento en *Cannabis sativa*

4.1. Diseño experimental

Con el objetivo de evaluar cuantitativamente cómo tres composiciones espectrales de luz (tratamientos A, B y C) modulan el crecimiento vegetativo temprano de *Cannabis sativa*, se implementó un diseño de Bloques Completos al Azar (BCA) con bloqueo temporal. El experimento se desarrolló durante 180 días, organizados en tres bloques sucesivos de 60 días cada uno (Bloque I: días 0–60; Bloque II: 60–120; Bloque III: 120–180), y cada bloque se subdividió en tres ciclos de 20 días. En cada ciclo, se asignó aleatoriamente uno de los tres espectros a un lote de cuatro clones genéticamente idénticos, garantizando tres réplicas por tratamiento a lo largo del estudio. Esta estructura experimental (Figura 4.1) permitió comparar los tratamientos bajo condiciones ambientales iniciales homogéneas y minimizar tanto la variabilidad temporal como los efectos intrínsecos de la cámara de cultivo. La ejecución del protocolo siguió cuatro etapas: (1) instalación y calibración, con desinfección de la cámara, colocación de sensores y trasplante de los clones; (2) aplicación de los espectros según el diseño bloqueado; (3) muestreo sistemático de temperatura y humedad cada cinco minutos y de altura y diámetro basal al inicio y final de cada ciclo; y (4) análisis de los datos mediante el cálculo de incrementos relativos, verificación de supuestos y análisis estadístico (ANOVA con bloque y comparaciones múltiples), complementado con un modelado predictivo preliminar. Esta sección describe el enfoque experimental adoptado, los componentes tecnológicos utilizados, y el procedimiento analítico para modelar el crecimiento en condiciones hidropónicas con ambiente controlado.

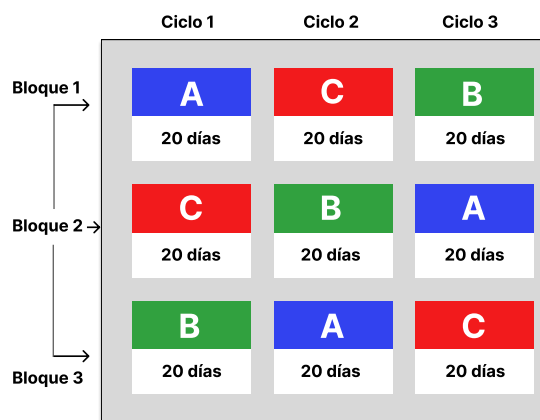


Figura 4.1: Diseño experimental BCA con bloqueo temporal.

4.1.1. Configuración espectral de luz

Para el desarrollo experimental se seleccionó la fuente de luz Sunplus S250 4 Bars LM301H 250W, un sistema de iluminación LED de espectro completo diseñado para cultivos de interior 4.2. Esta fuente está equipada con diodos Samsung LM301H y Osram SSL80, que proporcionan un espectro PAR para todas las etapas de crecimiento, desde la germinación hasta la floración. Su diseño modular de cuatro barras permite regular de forma independiente tres canales espectrales. Las especificaciones técnicas se presentan en la Tabla 4.1.



Figura 4.2: Sunplus S250 4 Bars LM301H 250W

Tabla 4.1: Características técnicas del sistema de iluminación Sunplus S250 4 Bars LM301H 250W.

Especificación	Detalle
Potencia nominal	250 W
Eficiencia fotónica (PPE)	2.9 $\mu\text{mol}/\text{J}$
PPFD a 30 cm	1105 $\mu\text{mol}/\text{m}^2/\text{s}$
Espectro lumínico	380nm - 730 nm
Cantidad de LEDs	480 (192×3000K, 256×5000K, 16×660 nm, 8×730 nm, 8×395 nm)
Control de canales	Independiente para VEG, BLOOM y UV
Ángulo de apertura	120°

El control de la fuente de luz se estableció mediante una salida PWM (frecuencia de muestreo de 10 KHz) de la fuente a través de puerto RJ11; al conectarla a un microcontrolador ESP32 se pudieron establecer niveles de irradiancia específicos por longitud de onda. Para ello, se combinaron diodos UV-A, azul y rojo, ajustando sus intensidades en términos de PPFD a nivel de copa y SPF. La caracterización de la luz se hizo con el colorímetro portátil OHSP-350C HopooColor con un rango espectral entre 380 nm y 780 nm y una resolución espectral de 0.2 nm. Cada composición espectral se sometió a dos ciclos de trabajo (duty cycle) —50 % y 100 %— lo que permitió variar la irradiancia en los rangos deseados y evaluar su efecto sobre el desarrollo morfológico de las plantas (ver Tabla 4.2).

Tabla 4.2: Ajuste de duty cycle para las diferentes composiciones espectrales (UV, VEG y BLOOM), valores de PPFD aproximados y referencia al espectro obtenido.

Escenario	UV (%)	VEG (%)	BLOOM (%)	PPFD ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$)	Figura
1	0	100	0	324.05	Fig 4.3(A)
2	100	100	100	364.15	Fig 4.3(B)
3	100	50	100	345.8	Fig 4.3(C)

Se seleccionaron tres tratamientos espectrales, referidos como A, B y C, mantenido constante un fotoperíodo de 18 h de luz y 6 h de oscuridad [53]:

- Tratamiento A: 0 % UV, 100 % VEG, 0 % BLOOM. Con ello se obtuvo un PPFD $\approx 324 \mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ (Fig. 4.3a)
- Tratamiento B: 100 % UV, 100 % VEG, 100 % BLOOM Con ello se obtuvo un PPFD $\approx 364 \mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ (Fig. 4.3b)
- Tratamiento C: 100 % UV, 50 % VEG, 100 % BLOOM Con ello se obtuvo un PPFD $\approx 346 \mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ (Fig. 4.3c)




Figura 4.3: (A) Distribución de flujo fotónico espectral en banda azul (400–500 nm). (B) Distribución completa de flujo fotónico espectral (400–700 nm). (C) Distribución de flujo fotónico espectral en banda roja (600–700 nm).

El PPFD varía conforme la planta crece, ya que cuando la fuente de luz se encuentra más cerca del dosel, la densidad de flujo fotónico aumenta. Para demostrar este fenómeno se realizaron mediciones de PPFD a tres alturas: 360 mm, 609 mm y 914 mm respecto al dosel de la planta (ver Figura 4.4). Cada altura se muestreó en una cuadrícula de 3×3 , obteniéndose coeficientes de variación inferiores al 1% en los puntos donde están ubicadas las plantas (esquinas de la matriz), lo que garantiza una distribución homogénea de la luz en cada bloque experimental. La Figura 4.4 presenta el diseño y las mediciones realizadas para comprobar dicha homogeneidad lumínica.




Figura 4.4: Matriz de densidad fotonica (PPFD) sobre el dosel de la planta. (a) Matriz de PPFD a 360 mm, (b) Matriz de PPFD a 609 mm, (c) Matriz de PPFD a 914 mm, (d) Ubicación experimental de la matriz de intensidad fotonica

4.1.2. Condiciones de cultivo e infraestructura

Para garantizar un entorno de cultivo altamente controlado y minimizar la variabilidad asociada a sustratos tradicionales, este estudio emplea un sistema hidropónico sin suelo basado en la técnica Deep Water Culture (DWC) (véase la Figura 4.5). Esta elección permite una regulación precisa de los parámetros nutricionales y ambientales (pH, EC y temperatura), eliminando además las interferencias debidas a la heterogeneidad física y química del suelo.

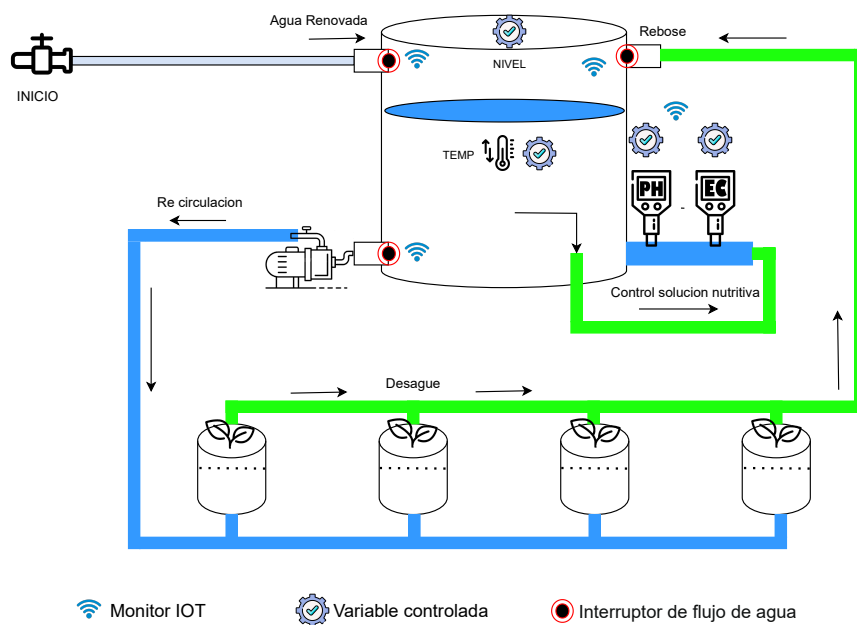


Figura 4.5: Diseño experimental del sistema de fertirriego hidropónico DWC.

El banco experimental del sistema hidropónico propuesto consta de cuatro tanques DWC de 3 L cada uno, interconectados a un circuito de recirculación que opera dos veces al día. Cada ciclo de recirculación tiene una duración de 30 minutos y un caudal de 0.4 L/min, lo que maximiza la oxigenación de la solución y limita la proliferación de algas y patógenos que podrían comprometer el desarrollo del material vegetal. Tras cada ensayo, se activa un protocolo de lavado que abre las válvulas de drenaje y llenado para efectuar cuatro recambios completos con agua limpia.

Antes de cada ciclo experimental, se calibran y verifican los sensores de pH, EC y temperatura para asegurar que el sistema quede en condiciones óptimas antes del siguiente experimento. El sistema hidropónico se divide en cuatro etapas:



Figura 4.6: Sistema hidropónico experimental en configuración DWC

1. **(Caja de control**(figura 4.6 (a)): Aloja el microcontrolador (ESP32 DEV KIT 1) que gestiona la dosificación automatizada de nutrientes y la recirculación; los conversores analógico-digitaes para la adquisición de señales; y una interfaz de usuario con pantalla LCD 20x4 para monitorización en sitio.
2. **Tanque de control** (figura 4.6 (b)): Dedicado a la preparación y mezcla de los nutrientes, así como el monitoreo continuo de la solución nutritiva.
3. **Tanques de cultivo** (figura 4.6 (c)): Tanques empelados para alojar el material vegetal objeto de estudio.
4. **Módulo de actuadores** (figura 4.6 (d)): Incluye cuatro bombas peristálticas (BOMPER-12V 100mL/min) controladas por relés de estado sólido, encargadas de dosificar nutrientes y corregir el pH mediante la inyección de soluciones ácidas o básicas. También gestiona la recirculación activa de la solución entre los tanques.

En la Figura 4.7 se muestra la estabilidad de la solución nutritiva a lo largo de un ciclo de 24 h, muestreada cada 10 min (144 datos diarios). El pH osciló entre 5,82 y 6,10 (media 5,89), la conductividad eléctrica se mantuvo entre 903.5 y 918.4 $\mu\text{S}/\text{cm}$ (media 906.13). Y la temperatura osciló entre 18.7 y 21.2 $^{\circ}\text{C}$. Estas variaciones se encuentran dentro de los rangos óptimos reportados para Cannabis sativa (pH 5.5–6.5; CE 800–1200 $\mu\text{S}/\text{cm}$; temperatura (20–22 $^{\circ}\text{C}$) [81, 82].

Estos resultados indican que el sistema DWC implementado ofrece un control óptimo de los parámetros críticos, reduciendo al mínimo las fluctuaciones que podrían afectar el desarrollo y la absorción de nutrientes por parte de las plantas.

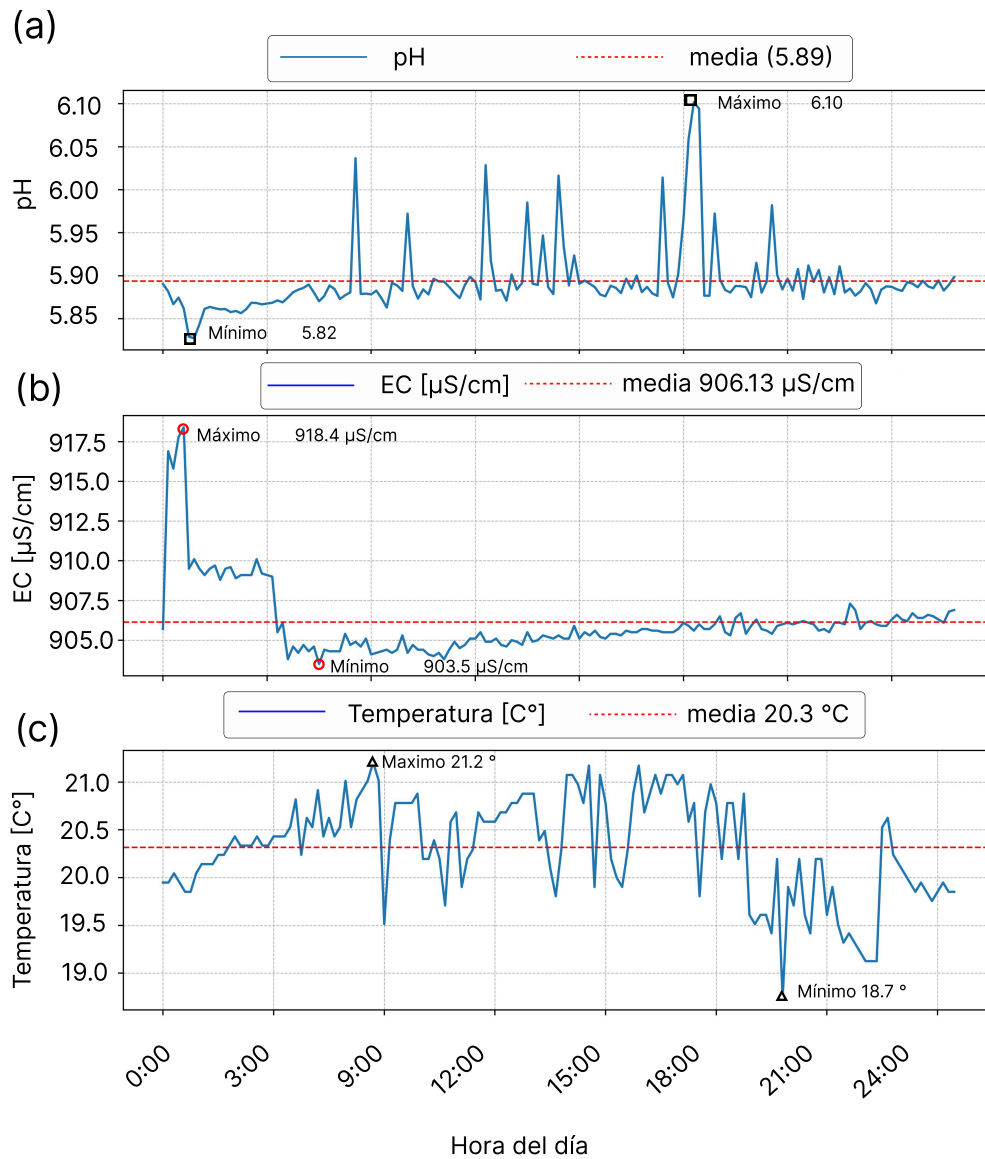


Figura 4.7: Evolución temporal de los parámetros de la solución nutritiva durante un ciclo de 24 h la línea punteada roja muestra la media, además se indican los valores mínimo y máximo. (a) Variación del pH. (b) Variación de EC. (c) Variación de temperatura

4.1.3. Material vegetal y manejo agronómico

Se seleccionó la variedad Rosa Andina del banco de semillas Colombia Breeders (derivada de la línea “Santa Marta Golden”) por su ciclo corto y perfil cannabinoide. Esta variedad de ciclo corto presenta, según su ficha técnica, los siguientes valores de cannabinoides: THC 19.6 %, CBGA 0.6 %, CBCA 0.4 % y CBD 0.3 % [83]. Su perfil cannabinoide le confiere aplicaciones medicinales: tradicionalmente se emplea en el manejo del dolor y como antiinflamatorio.

La propagación del material vegetal se hizo exclusivamente mediante esquejes, como se

ilustra en la Figura 4.8. Con ello, se buscaba homogeneidad genética y minimizar la variabilidad fenotípica entre los individuos de prueba. De este modo se evita que distintas expresiones fenotípicas dentro de la misma especie introduzcan respuestas morfológicas dispares ante un mismo tratamiento experimental, generando varianza e incertidumbre al experimento. Los esquejes se enraizaron en un sistema aeropónico diseñado ad hoc siguiendo las recomendaciones de la literatura especializada [38].




Figura 4.8: Material vegetal clonado (a) clones en proceso de enraizamiento para experimento, (b) Planta madre para clonacion, (c) clones iniciando ciclo experimental.

Ubicación geográfica y condiciones de invernadero

El experimento se desarrolló en Guarne, vereda Montañés (6.295061 N, -75.150905 O), altitud 2.200 m s.n.m., subregión natural andina alta (ICA). El clima es frío moderado, con temperatura anual media de 17 °C y precipitación promedio oscila entre 1.800 y 2.500 mm/año [84]. Los experimentos se llevaron a cabo en una cámara de crecimiento de dimensiones internas 0.80 × 0.80 × 1.40m (largo × ancho × alto), construida con estructura rígida y recubrimiento reflectante. Esta unidad fue instalada al interior de una habitación cerrada, lo que permitió un control adicional de las condiciones ambientales externas y minimizó la influencia de la luz y la ventilación no deseadas.

Para capturar el microclima se instaló la torre de monitoreo ambiental en el centroide de la superficie de cultivo, a la altura del dosel, como se observa en la Figura 4.6 (c). Esta ubicación es para registrar la VFA justo donde las plantas las experimentan, evitando los gradientes que se generan en los bordes del sistema [85–88]. Los sensores se configuraron con un intervalo de muestreo de 5 min.

Se determinaron las condiciones de temperatura en base al estado del arte estudiado donde la tasa fotosintética es mayor al 50 % entre 20° C y 30° C [33]. La humedad se estableció en función de la temperatura con un rango entre 40 % y 70 % [34]. Se definieron los siguientes valores objetivos para la solución nutritiva: EC entre 0.8 y 0.9 $\mu\text{S}/\text{cm}$

[42], temperatura de 18 °C a 22 °C [37] y pH de 5,8 a 6,2 [35].

La Tabla 4.3 resume estos valores objetivo junto con los parámetros ambientales efectivamente registrados durante los experimentos, demostrando la capacidad del sistema para mantener todos los factores críticos dentro de los intervalos óptimos de crecimiento.

Tabla 4.3: Parámetros ambientales y nutricionales establecidos para los experimentos.

Parámetro	Rango o Valor	Unidad
Humedad relativa [34]	40–70	%
Temperatura ambiente [33]	20–30	°C
pH de la solución nutritiva [35]	5,8–6,2	–
Conductividad eléctrica [42]	800 -950	dS/m
Temperatura de la solución nutritiva [37]	18–22	°C

4.2. Variables registradas y mediciones

Durante toda la fase vegetativa del experimento se realizó el monitoreo continuo de variables ambientales y morfológicas esenciales para el experimento. Las variables microclimáticas, temperatura del aire (°C) y humedad relativa (%), fueron registradas con una frecuencia de muestreo de un dato cada 5 minutos (288 registros diarios). Las condiciones espectrales se caracterizaron mediante mediciones una al día de el PPF, empleando un espectrofotómetro portátil de precisión HopooColor OHSP-350C [78], posicionado directamente sobre el dosel superior de cada planta experimental en condiciones estandarizadas de medición. la SPF fue ajustada y establecida desde el inicio de cada ciclo experimental, manteniéndose constante durante todo el período vegetativo.

Por otro lado, las variables morfológicas objetivo seleccionadas para evaluar el crecimiento fueron la elongación diaria del tallo y el diámetro basal, ambos registrados en milímetros (mm). La elongación del tallo se determinó mediante una cinta métrica digital Mitutoyo con resolución de 0.01 mm [89], asegurando alta precisión en las lecturas diarias. Simultáneamente, el diámetro basal se midió empleando un calibrador digital tipo pie de rey Mitutoyo (modelo 12-500-173-30) [90], con una precisión instrumental de 0.01 mm. Ambas variables fueron medidas diariamente, aproximadamente a la misma hora (5:00 pm - 6:00pm) cada día, durante los 20 días que comprendieron cada ciclo experimental, con esto se garantiza la consistencia temporal y la comparabilidad entre tratamientos. Al finalizar cada ciclo experimental, los registros obtenidos fueron organizados sistemáticamente en archivos con formato CSV (Comma Separated Values, por sus siglas en ingles). Estos archivos se estructuraron bajo una disposición tabular tipo *long*, en la que cada fila corresponde a una observación diaria por planta. Específicamente, cada planta generó 20 filas (una por cada día del experimento) y se registraron un total de 10 variables distribuidas en columnas: identificación de la planta (Planta), día del muestreo (Día), tratamiento espectral asignado (Tratamiento), humedad relativa (%), temperatura del aire (°C), déficit de presión de vapor (VPD, kPa), densidad de

flujo de fotones fotosintéticos incidentes (PPFD, $\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$), integral diaria de luz (DLI, $\text{mol}\cdot\text{m}^{-2}\cdot\text{día}^{-1}$), diámetro basal (mm) y altura del tallo (mm). Así, para cada ciclo experimental se obtuvieron matrices de datos con un total de 80 filas, correspondientes al seguimiento completo de cuatro plantas por ciclo durante el período de 20 días.

4.3. Análisis de crecimiento y respuesta fisiológica

En esta sección se presentan y analizan los resultados obtenidos a partir de las mediciones morfológicas realizadas durante los ciclos experimentales. Se examinan inicialmente las dinámicas generales de crecimiento, destacando las diferencias entre tratamientos espectrales, y posteriormente se describen en detalle las tasas absolutas y relativas del crecimiento en función de las variables monitoreadas.

Pre-procesamiento de las variables

Para cuantificar la velocidad de crecimiento se calculó la tasa relativa de crecimiento (TRC) en altura entre días sucesivos según la siguiente ecuación:

$$\text{TRC} = \frac{\ln W_2 - \ln W_1}{t_2 - t_1}$$

donde H_{t_1} y H_{t_2} son las alturas en días consecutivos. Con los valores de TRC diarios se obtuvo un conjunto de 36 observaciones por tratamiento, sobre las cuales se estimaron la mediana, el intervalo intercuartílico (IQR) y los valores extremos. La Figura 4.9 resume la distribución de la tasa relativa de crecimiento (TRC, altura relativa) para los 36 clones bajo las tres iluminaciones espectrales:

- **Tratamiento A** – Mediana = 2.40; intervalo intercuartílico (IQR) = 2.24 – 2.64; rango total = 1.39 – 3.12. Se detectó un valor atípico inferior (1.39), asociado a una planta que creció más lentamente que sus congéneres.

- **Tratamiento B** – Mediana = 3.54; IQR = 3.35 – 3.83; rango total = 2.97 – 4.41. No se identificaron atípicos, y la dispersión moderada indica una respuesta relativamente uniforme a este espectro.

- **Tratamiento C** – Mediana = 4.33; IQR = 3.96 – 4.53; rango total = 3.47 – 5.19, el mayor de los tres tratamientos. Aunque no aparecen valores extremos formales, la amplitud del rango revela una variabilidad intra-tratamiento notablemente más alta.




Figura 4.9: Diagramas de caja y bigotes de la TRC (altura relativa) por tratamiento espectral. La línea negra dentro de cada caja marca la mediana; los límites inferior y superior corresponden a los cuartiles Q_1 y Q_3 ; los bigotes se extienden hasta $1.5 \times IQR$ y los puntos aislados representan valores atípicos.

Resultados morfométricos

Durante la fase vegetativa, la elongación del tallo de *Cannabis sativa* sigue inicialmente una dinámica cercana al crecimiento exponencial, impulsada por la rápida división celular y expansión de los entrenudos. A medida que las plantas ganan tamaño se limita la velocidad de alargamiento, aproximando la curva a una forma sigmoideal [91].

En la Figura 4.10, que resume la elongación del tallo en los nueve ciclos experimentales, se evidencian diferencias claras entre tratamientos espectrales (A, B y C), tanto en la magnitud del crecimiento como en la dispersión interindividual. El tratamiento C, caracterizado por una alta proporción de rojo-lejano, promovió una elongación más acelerada, especialmente entre los días 8 y 16, lo cual es coherente con la activación de la vía de señalización del fitocromo-B [92, 93]. Este estímulo lumínico promueve la síntesis y polarización de auxinas, potenciando la expansión celular a lo largo del tallo. Sin embargo, también es notable que este tratamiento genera una variabilidad más alta entre individuos, incluso cuando se trabaja con plantas clonales. Este patrón heterogéneo se explica por la interacción entre el espectro y microvariaciones dentro del dosel, como ángulos de incidencia, zonas de sombreado parcial y distribución espacial del PPFD.

A medida que las plantas crecen, la parte apical se aproxima progresivamente a la fuente de luz, lo que se traduce en un incremento del PPFD efectivo sobre el ápice y,

por tanto, del DLI (Daily Light Integral). Esta retroalimentación positiva potencia aún más la elongación, particularmente en el tratamiento C, donde la señal espectral y la intensidad luminosa convergen para inducir un crecimiento acelerado. Sin embargo, esta misma dinámica amplifica pequeñas diferencias microambientales, produciendo curvas más dispersas y menos paralelas entre plantas (como se observa en las series de los ciclos con tratamiento C, señalados en rojo).

En contraste, los tratamientos A y B, con espectros más equilibrados y ricos en azul, generaron curvas de crecimiento más homogéneas entre plantas. El tratamiento B mostró el crecimiento más alto y sostenido, especialmente en los ciclos intermedios, lo que sugiere que su distribución espectral, combinada con un aumento gradual del DLI, favoreció tanto la elongación como una distribución más uniforme del PPFD entre individuos. El tratamiento A, aunque con crecimiento más moderado, presentó la menor dispersión, indicando que su señal espectral genera respuestas más estables y menos sensibles a variaciones microambientales.

Por otro lado, la Figura 4.11 recoge la variación del diámetro basal de los tallos para los mismos tratamientos durante el mismo período. Aquí también el espectro C promueve el mayor engrosamiento en el tallo de la planta, alcanzando un promedio de 4.59 mm al día 20, frente a los 3.61 mm de A y alrededor de 4.0 mm de B. Nótese que, mientras la curva de elongación en C acelera primero y luego se estabiliza, el diámetro basal crece de forma más constante, lo que sugiere un desfase temporal entre los picos de elongación.




Figura 4.10: Resultados de crecimiento elongación del tallo para cada distribución espectral.

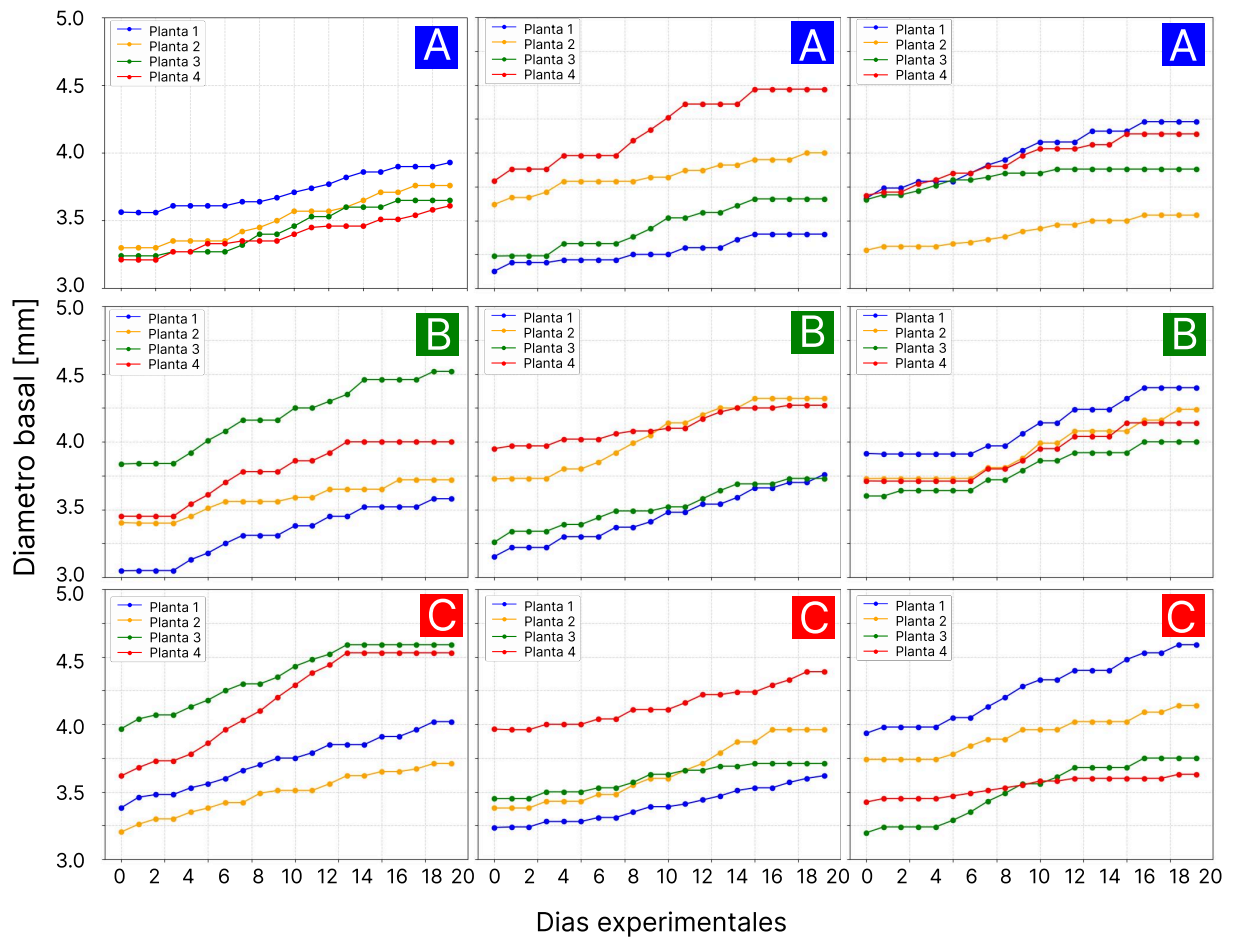


Figura 4.11: Resultados de crecimiento diametro basal para cada distribución espectral

4.3.1. Análisis estadístico (ANOVA)

Para cuantificar la influencia relativa del tratamiento espectral frente al bloque temporal sobre la tasa relativa de crecimiento, se ajustó un modelo lineal de dos factores (tratamiento espectral y bloque temporal) y se evaluó mediante un ANOVA de Bloques Completos al Azar. Los resultados (Tabla 4.4) muestran que la suma de cuadrados atribuible al espectro de iluminación ($SC = 0.003407$; $GL = 2$) es sustancialmente mayor que la correspondiente al bloque temporal ($SC = 0.000098$; $GL = 2$), lo que indica un impacto cuantitativo predominante de la composición espectral sobre la TRC.

El estadístico F para el tratamiento espectral ($F_{2,31}=32.12$, $p < 0.001$) demuestra un efecto altamente significativo, mientras que el bloque temporal no resultó significativo ($F_{2,31}=0.92$, $p < 0.41$). Calculando la proporción de la variabilidad total explicada por cada fuente, se obtiene que el espectro lumínico explica aproximadamente el 66 % de la variación en la TRC, el bloque temporal únicamente el 2 % y el 32 % restante corresponde a variación residual. Este hallazgo confirma que la composición espectral es la principal fuente de variación en el crecimiento relativo de los clones, independientemente de las diferencias entre los ciclos de 20 días.

Los supuestos del modelo ANOVA fueron evaluados para asegurar la validez de las inferencias. La prueba de Shapiro–Wilk para normalidad de los residuos arrojó un valor $p = 0.911$, indicando que no existe evidencia para rechazar la hipótesis de normalidad. La homocedasticidad se verificó mediante el test de Breusch–Pagan ($p = 0.128$), que resultó no significativo, apoyando la homogeneidad de varianzas entre los tratamientos. La independencia de los residuos fue confirmada por el estadístico de Durbin–Watson, cuyo valor ($DW = 2.27$) se encuentra dentro del rango aceptado ($1.5 < DW < 2.5$).

Tabla 4.4: ANOVA de dos factores (tratamiento espectral y bloque temporal) sobre la tasa relativa de crecimiento (TRC): suma de cuadrados (SC), grados de libertad (GL), estadístico F y valor p.

Fuente	SC	GL	F	p -valor
Tratamiento	0.003407	2	32.12	2.8×10^{-8}
Bloque	0.000098	2	0.92	0.41
Residual	0.001644	31		

Para determinar qué pares de tratamientos espectrales diferían de manera significativa, tras el ANOVA se aplicó la prueba de Tukey HSD. Los resultados obtenidos tras aplicar esta prueba revelaron diferencias significativas entre todos los pares de tratamientos (Tabla 4.5). El espectro C presentó una tasa relativa de crecimiento significativamente mayor que B ($p = 0.015$) y A ($p < 0.001$), mientras que B también mostró un incremento significativo respecto a A ($p = 0.0001$). Esta secuencia $A < B < C$ confirma que cada vez que aumentamos la proporción de rojo lejano y rojo en el espectro, la TRC se incrementa de forma estadísticamente robusta.

Tabla 4.5: Prueba de comparaciones múltiples de Tukey HSD para la tasa relativa de crecimiento. Se muestran las diferencias de medias entre tratamientos, sus intervalos de confianza al 95 % y el p -valor ajustado.

Grupo 1	Grupo 2	Dif. medias	IC 95 %	p -ajustada	Significativo
A	B	0.0148	(0.0075, 0.0221)	0.0001	Sí
A	C	0.0236	(0.0163, 0.0309)	< 0.0001	Sí
B	C	0.0088	(0.0015, 0.0161)	0.015	Sí

Para cuantificar hasta qué punto las fluctuaciones microclimáticas podían influir en el crecimiento, examinamos la temperatura y la humedad relativa registradas con un muestreo de 5 minutos (288 lecturas diarias) en cada bloque y ciclo. La Figura 4.12 (a) presenta el comportamiento promedio de un día típico. De hecho, los resultados obtenidos revelan que la temperatura se mantuvo dentro del rango óptimo de 20–30 °C, con una temperatura media igual a 26.38 °C, una temperatura mínima de 25.48 °C y una máxima de 27.78 °C. La desviación estándar fue de 0.603 °C, lo que equivale a un coeficiente de variación (CV) de solo 2.38 %, reflejando una excelente estabilidad térmica.

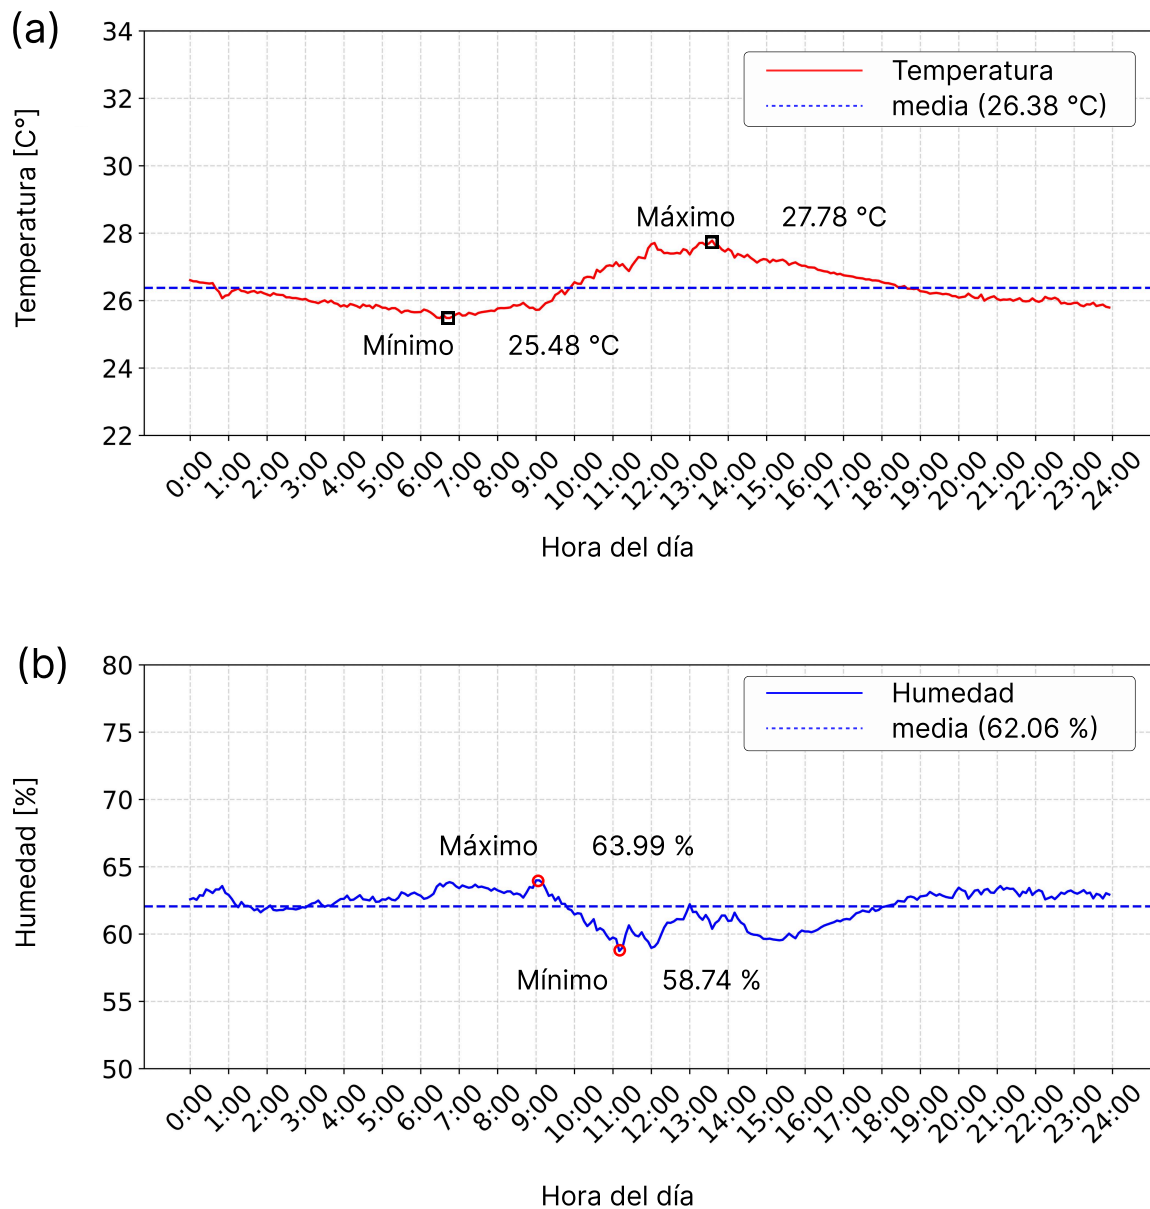


Figura 4.12: Temperatura C° y humedad diaria RH

Por otro lado, la humedad relativa (Figura 4.12(b)), muestra variaciones ligeramente mayores. Durante los momentos más cálidos del día se registraron valores inferiores al 60 %, lo cual es consecuencia del aumento en la capacidad del aire para contener vapor de agua al calentarse. Sin embargo, la recirculación de aire y la posterior disminución de la temperatura generaron aumentos subsecuentes en la humedad. En general, estas variaciones no fueron significativas en la mayoría de los días analizados, ya que la humedad relativa promedio se situó entre 60 % y 70 %, con una media global de 62.06 % y una desviación estándar de 1.23 %. El coeficiente de variación obtenido fue del 1.98 %, lo cual evidencia homogeneidad en los datos, resultado que también se apoya en que los percentiles del 25–75 % (61.11–63.02 %) estuvieron estrechamente agrupados alrededor de la media.

La Figura 4.13 muestra, mediante diagramas de caja, la variabilidad del coeficiente de variación de la temperatura y la humedad relativa a lo largo de los nueve ciclos experimentales de 20 días. Estos estadísticos descriptivos permiten evaluar cuantitativamente la estabilidad microclimática entre lotes y a lo largo del tiempo. En el caso de la temperatura, se observa una alta homogeneidad, con medias diarias comprendidas entre 24.49°C y 25.66°C , y CV inferiores al 7.5 % en todos los ciclos, lo cual refleja un control térmico consistente. De forma similar, la humedad relativa se mantuvo entre 63.96 % y 65.70 %, con CV menores al 5.1 %, indicando un régimen hídrico uniformemente regulado. La baja dispersión observada —con CV de temperatura por debajo del 8 % y de humedad relativa por debajo del 6 %— confirma que las medias diarias son representaciones estadísticamente robustas de las condiciones ambientales. Esto no solo valida la homogeneidad de los tratamientos ambientales, sino que también justifica el uso de dichas medias en los análisis estadísticos posteriores, reduciendo el costo computacional de los modelos predictivos, conforme a lo planteado en el diseño experimental y en el sistema de control climático descritos en el capítulo 3.

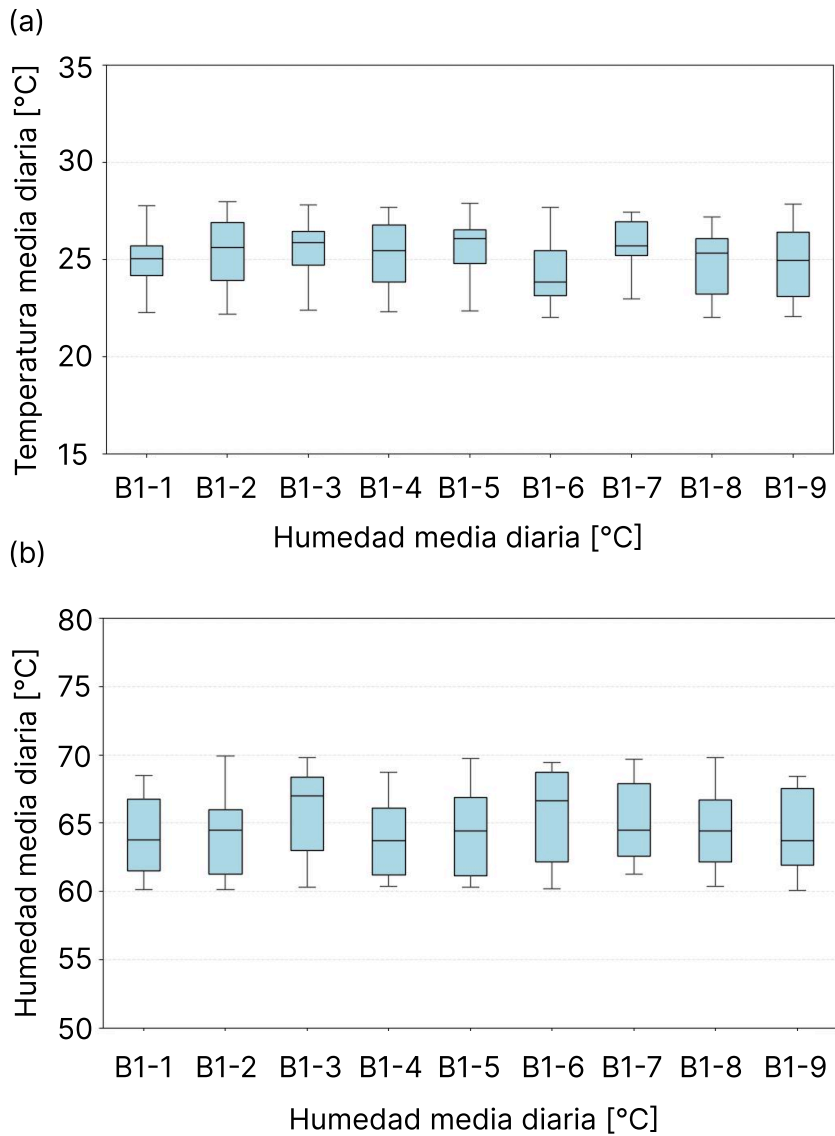


Figura 4.13: Variabilidad temperatura

4.3.2. Evaluación de correlaciones y colinealidad

Finalmente, para descartar posibles colinealidades entre variables ambientales y fisiológicas que pudieran sesgar los modelos predictivos, se calculó la matriz de correlaciones de Pearson entre siete variables numéricas del experimento: temperatura media (Temp_°C), humedad relativa (HR_%), déficit de presión de vapor (VPD_kPa), densidad de flujo de fotones fotosintéticos (PPFD_μmol/m²/s), integral diaria de luz (_mol/m²/día), altura del tallo (Alt_mm) y diámetro basal (Diam_mm). La Figura 4.14 muestra la matriz de correlación de Pearson donde los colores más cálidos indican correlaciones positivas más fuertes, y los más fríos, correlaciones negativas. Cabe recordar que el coeficiente de Pearson r varía entre -1 (correlación lineal negativa perfecta) y $+1$ (positiva perfecta).




Figura 4.14: Matriz de correlaciones de Pearson. Los tonos rojos indican correlaciones positivas y los azules negativas; la intensidad se corresponde con la magnitud del coeficiente.

Como puede observarse, las variables de iluminación PPFD y DLI están fuertemente correlacionadas entre sí ($r = 1.00$) y también presentan alta correlación con la altura ($r = 0.98$) y el diámetro ($r = 0.76$), lo que respalda su inclusión como predictores clave en los modelos de crecimiento. Por otro lado, las variables térmicas (Temp_°C y HR_%) no presentan correlaciones lineales relevantes con las variables de respuesta ($r \approx 0.06$), lo cual reduce el riesgo de multicolinealidad al combinar factores climáticos y fotónicos en un mismo modelo. Estos resultados confirman que las variables seleccionadas aportan información complementaria y no redundante para explicar la variabilidad observada en el crecimiento de los clones.

A partir de los resultados de la matriz de correlación (Tabla 4.6), se concluye que las variables más estrechamente relacionadas con el crecimiento fueron el PPFD y el DLI, ambas con una correlación muy alta respecto a la altura del tallo ($r = 0.98$) y al diámetro basal ($r = 0.76$). Esto confirma el papel determinante de la luz, tanto en cantidad instantánea como acumulada, en la promoción del crecimiento morfológico. Además, la pareja altura–diámetro también mostró una relación lineal clara ($r = 0.78$), lo cual resulta coherente desde un punto de vista fisiológico: las plantas que se elongan más tienden también a engrosar sus tallos.

En contraste, las variables ambientales como la temperatura y la humedad relativa exhibieron correlaciones muy bajas con las variables de crecimiento, lo que se explica por su escasa variabilidad experimental ($\approx 1^\circ\text{C}$ y 2% HR). Esta estabilidad climática minimiza su influencia sobre los resultados y reduce el riesgo de confusión en la comparación entre tratamientos espectrales. En conjunto con el ANOVA, estos resultados refuerzan que las diferencias significativas observadas en el crecimiento son atribuibles principalmente a la composición espectral de la luz y no a condiciones ambientales ni al bloque temporal.

Tabla 4.6: Coeficientes de correlación de Pearson (r) entre las variables ambientales y morfométricas.

Par de variables	r	Interpretación
Altura – PPF	0.98	Correlación <i>muy alta</i> y positiva; mayor densidad de fotones incidentes se asocia fuertemente con una mayor elongación del tallo.
Altura – DLI	0.98	Relación <i>muy fuerte</i> ; a mayor integral diaria de luz, mayor crecimiento vertical.
Diámetro – PPF	0.76	Correlación <i>alta</i> ; el engrosamiento del tallo responde positivamente al incremento del PPF.
Diámetro – DLI	0.76	Asociación <i>alta y positiva</i> ; la acumulación de luz diaria favorece también el desarrollo radial.
Altura – Diámetro	0.78	Relación <i>moderada-fuerte</i> ; las plantas más altas tienden también a tener un mayor diámetro basal.
Temperatura – VPD	0.77	Correlación <i>alta</i> y positiva; temperaturas más elevadas incrementan el déficit de presión de vapor.
Humedad – VPD	-0.63	Relación <i>moderadamente fuerte y negativa</i> ; a mayor humedad relativa, el VPD disminuye significativamente.
Temperatura – Humedad	-0.01	Correlación prácticamente nula; las variables térmica e hídrica se comportaron de forma independiente.
Altura – Temperatura	0.06	Asociación <i>muy débil</i> y positiva; no hay dependencia lineal clara.
Altura – Humedad	-0.02	Relación <i>nula</i> ; la elongación del tallo no depende linealmente de la humedad en este rango.

Capítulo 5

Modelado predictivo

El crecimiento vegetal es un fenómeno dinámico y multicausal que emerge de la interacción entre la dotación genética del cultivo y un entorno físico-químico cambiante. Predecir esa dinámica es decisivo para programar labores agrícolas, optimizar riegos, ajustar la luz y maximizar rendimiento y calidad con recursos limitados. Sin embargo, la naturaleza no lineal de las respuestas fisiológicas, los retardos en el desarrollo y la heterogeneidad microclimática dificultan el modelado.

En este capítulo abordamos dichas dificultades mediante la construcción y evaluación de cuatro modelos de aprendizaje automático: ElasticNet, Huber, Random Forest y XGBoost. Para cada uno, aplicamos una optimización bayesiana de hiperparámetros y comparamos su desempeño sobre particiones cronológicas de los datos empleando métricas estandarizadas tales como MAE, RMSE y R^2 MAE, RMSE y R^2 . Los objetivos específicos son los siguientes: primero, definir una línea base interpretable que cuantifique la contribución individual de variables fisiológicas y ambientales; segundo, cuantificar la mejora en precisión que aportan los algoritmos avanzados frente al modelo de referencia; tercero, caracterizar la importancia de los predictores y verificar su coherencia con la fisiología del cultivo; y cuarto, evaluar la factibilidad de implementar el modelo óptimo en plataformas embebidas para monitoreo en tiempo real. Con este enfoque se busca no solo rendimiento predictivo, sino también transparencia y viabilidad operativa.

5.1. Estructura y preprocesamiento del conjunto de datos

El conjunto de datos se organizó en formato long, de modo que cada fila correspondiera a la medición diaria realizada sobre una planta individual. Como variables de entrada se incluyeron los datos ambientales (temperatura del aire y humedad relativa), el tratamiento lumínico codificado ordinalmente ($A = 0$, $B = 1$, $C = 2$), las variables fotométricas PPFD y DLI, así como el diámetro basal debido a su alta correlación con el crecimiento vegetal. La variable dependiente (variable objetivo) fue la altura de la planta. Para los modelos de regresión basados en redes neuronales se aseguró una escala homogénea entre variables mediante la estandarización utilizando la clase `StandardScaler` del paquete `sklearn.preprocessing`. En cambio, para los modelos basados en árboles

de decisión no se realizó ningún procedimiento de normalización o estandarización, dado que el rendimiento de estos algoritmos no se ve afectado por la escala de las variables de entrada.

Posteriormente, para capturar las dependencias temporales inherentes al crecimiento vegetal, se generaron secuencias supervisadas mediante ventanas deslizantes de longitud fija de 20 días. En este esquema, cada secuencia se conforma por variables ambientales, tratamientos lumínicos codificados, variables espectrales y diámetros basales correspondientes a los 20 días previos, utilizados como entradas para predecir la altura de la planta durante los siguientes 20 días.

El conjunto final resultante consiste en un dataset estructurado con una fila por cada una de las 36 plantas estudiadas, y un total de 121 columnas, distribuidas en variables de entrada etiquetadas desde x_0 hasta x_{99} y variables de salida desde y_0 hasta y_{19} , correspondientes a los 20 días consecutivos de predicción del crecimiento esperado.

El conjunto de datos se dividió en tres particiones mutuamente exclusivas: entrenamiento (56%), validación (14%) y prueba (30%), utilizando el método `train_test_split` de `scikit-learn` con semilla `random_state=42` para asegurar reproducibilidad. La división se realizó en dos etapas: primero, se reservó el 30% de los datos como conjunto de prueba final; luego, el 20% del conjunto restante se asignó a validación. Esta estrategia se usó con el fin de optimizar hiperparámetros sobre el conjunto de validación sin exponer el modelo a los datos de prueba, buscando una estimación válida de su capacidad de generalización.

5.2. Modelos

A fin de evaluar diferentes enfoques predictivos con respecto a su complejidad, interpretabilidad y robustez frente a datos atípicos, se seleccionaron cuatro algoritmos supervisados con características contrastantes. Se incluyeron modelos lineales penalizados, modelos lineales robustos a valores extremos y modelos no lineales basados en ensambles de árboles de decisión. A continuación, se describen brevemente sus fundamentos teóricos y los hiperparámetros críticos optimizados mediante búsqueda bayesiana con `Optuna`.

5.2.1. Modelos lineales

5.2.1.1. Elastic Net

El modelo `ElasticNet` combina las penalizaciones L_1 y L_2 dentro de la función de pérdida de la regresión lineal, lo que permite simultáneamente fomentar la parcimonia (selección de variables) y mantener la estabilidad numérica. En este estudio, la variable objetivo corresponde a la altura proyectada de la planta durante 20 días consecutivos, lo que convierte el problema en una regresión multisalida: una predicción vectorial $\hat{\mathbf{y}} \in \mathbb{R}^{20}$ por

cada observación.

Para optimizar los hiperparámetros del modelo se usó Optuna (v3.6.1), utilizando búsqueda bayesiana (TPE) y fijando la semilla (`random_state=42`) para garantizar la reproducibilidad. El espacio de búsqueda incluyó el parámetro `alpha` con una distribución log-uniforme en el rango $[10^{-5}, 10^2]$ y un `l1_ratio` con una distribución uniforme en $[0, 1]$. El primero de estos permitió controlar la fuerza de la regularización total y el segundo ayudó a definir la proporción entre las penalizaciones L_1 y L_2 , permitiendo un equilibrio entre selección de variables y estabilidad en la regresión.

Los valores óptimos obtenidos para `alpha` y `l1_ratio` fueron 0.0245 y 0.9822, respectivamente. Es importante mencionar que en cada iteración, los predictores se estandarizaban mediante `StandardScaler` ajustado sobre el conjunto de entrenamiento y aplicado luego a los subconjuntos de validación y prueba. A continuación, se entrenaban veinte instancias independientes de `ElasticNet` (una por cada horizonte de predicción de 1 a 20 días), encapsuladas dentro de un `MultiOutputRegressor`, y se generaban las predicciones sobre el bloque de validación cronológica. Finalmente, se calculaba el error absoluto medio (MAE) en milímetros sobre los vectores de salida desnormalizados.

La Figura 5.1 muestra el comportamiento individual de cada hiperparámetro sobre la métrica de desempeño. En el gráfico superior (a) se observa que valores de `alpha` menores a 10^{-3} o mayores a 1 producen errores elevados, mientras que la región óptima se encuentra alrededor de 0.01 a 0.1. En el gráfico inferior (b), se evidencia que el mejor desempeño se alcanzó con valores altos de `l1_ratio`, especialmente por encima de 0.8, lo que indica que el modelo se benefició de una regularización fuertemente dominada por el término L_1 . Los puntos marcados en ambas curvas representan las combinaciones con menor MAE alcanzado durante la búsqueda.




Figura 5.1: Gráfico tipo slice que muestra la relación entre los hiperparámetros alpha (a) y l1_ratio (b) frente al valor objetivo (MAE).

El modelo final, entrenado con los valores óptimos de alpha y l1_ratio sobre la totalidad del conjunto de entrenamiento, obtuvo un MAE de 5.7440 mm, equivalente a un error relativo del 1.78 %. La RMSE alcanzó 8.4867 mm, mientras que el coeficiente de determinación (R^2) fue igual a 0.9259, lo que implica que el modelo explica el 92.59 % de la variabilidad en las alturas observadas del conjunto de prueba. Estos resultados confirman una alta precisión predictiva y una excelente capacidad de ajuste. Por otro lado, la dispersión entre los valores reales y las predicciones para los 20 horizontes de predicción se muestra en la Figura 5.2, evidenciando la estrecha alineación de las estimaciones con la diagonal de referencia.




Figura 5.2: Dispersión de las alturas reales frente a las predichas por el modelo Elastic Net en el conjunto de prueba, donde cada punto corresponde a una predicción para uno de los 20 días de horizonte y la línea diagonal indica el ajuste perfecto.

5.2.1.2. Huber Regressor

Se implementó el modelo Huber Regressor, el cual combina la simplicidad de la regresión lineal con la robustez frente a valores atípicos mediante una función de pérdida que es cuadrática para residuales pequeños y lineal más allá de un umbral ϵ . Este comportamiento defiende al modelo de la influencia excesiva de observaciones extremas, sin renunciar por completo a la sensibilidad típica del error cuadrático medio. Para adaptarlo al problema multisalida de horizonte 20 días, cada estimador base se encapsuló en un MultiOutputRegressor, generando de forma independiente una predicción diaria.

Este modelo tiene dos hiperparámetros que controlan tanto su comportamiento frente a valores atípicos como su capacidad de generalización:

- Epsilon (ϵ): umbral que determina la transición entre el régimen cuadrático y el lineal de la función de pérdida. Para errores residuales $|y - \hat{y}| \leq \epsilon$, la pérdida es cuadrática (como en MSE); mientras que para errores mayores, la pérdida pasa a ser lineal, disminuyendo la sensibilidad a valores atípicos. Un valor bajo de ϵ hace al modelo más robusto, pero puede perder precisión si hay pocos valores extremos. Se exploró el rango [1.1, 2.5].
- Alpha (α): coeficiente de regularización L_2 que penaliza la magnitud de los coeficientes β . Este término controla la complejidad del modelo y ayuda a evitar el sobreajuste. Cuanto mayor es α , más se restringen los coeficientes hacia cero. Se utilizó una escala logarítmica en el rango $[10^{-5}, 10^{-1}]$ para cubrir varios órdenes de magnitud con precisión.

La búsqueda bayesiana con Optuna fue llevada a cabo también para este modelo, con el fin de optimizar los hiperparámetros del mismo. La combinación óptima resultó $\epsilon = 1.1924639$ y $\alpha = 4.2975 \times 10^{-4}$. Con esto las métricas obtenidas después del entrenamiento fueron: un error absoluto medio (MAE) de 4.2076 mm , RMSE de 5.6552 mm y un coeficiente de determinación $R^2 = 0.8996$. Estos valores indican que el modelo fue capaz de capturar la tendencia general del crecimiento en los 20 días, manteniendo al mismo tiempo cierta tolerancia frente a observaciones atípicas. En la Figura 5.3 se presenta la dispersión entre los valores reales y predichos, donde se observa un agrupamiento alrededor de la diagonal $y = \hat{y}$, lo cual refleja una buena capacidad predictiva del modelo.




Figura 5.3: Dispersión de las alturas reales frente a las predichas por el modelo Huber Regressor en el conjunto de prueba para un horizonte de 20 días. La línea diagonal indica el ajuste perfecto.

5.2.2. Modelos basados en árboles

5.2.2.1. Random Forest

Random Forest es un algoritmo de ensamblado basado en el método bagging, que entrena múltiples árboles de decisión sobre subconjuntos aleatorios de datos y predictores, y promedia sus salidas para mejorar la generalización y reducir la varianza.

Los rangos de búsqueda definidos para los hiperparámetros fueron seleccionados con base en recomendaciones empíricas y consideraciones específicas del problema. Se estableció un número de árboles (`n_estimators`) entre 100 y 500 para permitir un equilibrio entre capacidad de generalización y tiempo de entrenamiento. La profundidad máxima de los árboles (`max_depth`) se restringió a un rango entre 5 y 50 para controlar el riesgo de sobreajuste. Los hiperparámetros `min_samples_split` y `min_samples_leaf` se optimizaron en intervalos cortos, con el objetivo de evitar divisiones o nodos hoja con muy

pocos ejemplos, lo cual es frecuente en series de crecimiento con pocos datos.

Finalmente, el hiperparámetro `max_features` se exploró sobre las opciones clásicas de `"sqrt"` y `"log2"`, así como la posibilidad de utilizar todas las variables disponibles. En este contexto, `"sqrt"` indica que en cada división se consideran únicamente \sqrt{p} variables (siendo p el número total de predictores), mientras que `"log2"` limita la selección a $\log_2(p)$ variables, lo que introduce mayor aleatoriedad y reduce la correlación entre árboles.

Los siguientes hiperparámetros se optimizaron con búsqueda bayesiana mediante Optuna v3.6.1:

- `n_estimators`: número de árboles en el bosque $\in [100, 500]$
- `max_depth`: profundidad máxima de cada árbol $\in [5, 50]$
- `min_samples_split`: mínimo de muestras para dividir un nodo interno $\in [2, 10]$
- `min_samples_leaf`: mínimo de muestras en una hoja $\in [1, 5]$
- `max_features`: número de predictores a considerar en cada división $\in \{ "sqrt", "log2", None \}$

Así mismo, se fijó el parámetro `random_state` en 42 para asegurar reproducibilidad de los resultados obtenidos. El modelo entrenado con los hiperparámetros óptimos encontrados mediante Optuna mostró un desempeño aceptable en el conjunto de prueba. En este caso, se obtuvo un MAE de 14.27 mm, con un error relativo del 5.26 %. El MSE fue de 468.65 mm², mientras que el RMSE alcanzó 21.65 mm. Finalmente, el R^2 fue igual a 0.8263, lo que indica que el modelo explicó aproximadamente el 83 % de la variabilidad observada. Estos resultados se ilustran en la Figura 5.4, donde se observa la dispersión de los valores reales frente a los predichos y la línea diagonal que representa el ajuste perfecto.




Figura 5.4: Dispersión de las alturas reales frente a las predichas por el modelo Random Forest en el conjunto de prueba para un horizonte de 20 días.

5.2.2.2. XGBoost

El modelo XGBRegressor corresponde a una implementación de gradient boosting, donde se construyen árboles de decisión de forma secuencial para corregir los errores del modelo anterior. Cada nuevo árbol se agrega al conjunto minimizando una función de pérdida regularizada. Este algoritmo ha demostrado gran capacidad predictiva en problemas de datos tabulares, combinando flexibilidad no lineal y control del sobreajuste mediante varios mecanismos internos de regularización.

Durante el proceso de optimización, se identificaron tres hiperparámetros con mayor relevancia en el desempeño del modelo: `gamma`, `reg_alpha` y `n_estimators`. Estos fueron priorizados por el algoritmo de búsqueda bayesiana debido a su impacto directo en la reducción del MAE.

- `gamma` (0–5): Representa el umbral mínimo de ganancia en la función de pérdida requerido para realizar una partición en los árboles. Valores altos favorecen árboles más conservadores, reduciendo el sobreajuste estructural.
- `reg_alpha` (10^{-8} –1.0): Coeficiente de regularización L_1 que promueve esparsidad en los pesos del modelo, eliminando ramas menos relevantes y ayudando a la generalización.
- `n_estimators` (50–500): Define la cantidad total de árboles a construir. Un mayor número de árboles permite una mejor aproximación de la función objetivo, aunque con mayor costo computacional.

Adicionalmente, se incluyeron en el espacio de búsqueda los hiperparámetros `max_depth`, `learning_rate`, `subsample`, `colsample_bytree`, `reg_lambda`, que si bien formaron parte del proceso de exploración, mostraron una influencia marginal sobre la métrica objetivo en este caso de estudio.

El modelo XGBoost logró un desempeño adecuado entre los modelos evaluados, alcanzando un MAE de 10.41 mm, lo que representa un error relativo del 3.83%. El RMSE obtenido fue de 16.25 mm, mientras que el coeficiente de determinación fue de $R^2 = 0.8583$, indicando que este modelo explicó aproximadamente el 86% de la variabilidad observada. Estos resultados reflejan una capacidad aceptable del modelo para capturar la dinámica general del crecimiento durante el periodo evaluado de 20 días. La Figura 5.5 muestra la relación entre las predicciones y los valores reales, donde se observa un agrupamiento satisfactorio alrededor de la diagonal ideal.




Figura 5.5: Dispersión de las alturas reales frente a las predichas por el modelo XGBoost en el conjunto de prueba para un horizonte de 20 días. La línea diagonal indica el ajuste perfecto.

5.3. Análisis de resultados

5.3.1. Comparación de desempeño global

La Tabla 5.1 resume las métricas obtenidas por los cuatro modelos evaluados sobre el conjunto de prueba. A partir de estas métricas, se observa que los modelos basados en regresión lineal regularizada (ElasticNet y Huber Regressor) presentan los mejores resultados generales en términos de precisión. En particular, ElasticNet obtuvo el menor error absoluto medio (MAE de 3.27 mm) y el menor error relativo (1.20 %), acompañado de un $R^2 = 0.9412$, lo que indica una alta capacidad de predicción de la altura proyectada de las plantas de *Cannabis sativa*. El modelo Huber, aunque ligeramente inferior a ElasticNet, también mostró un buen desempeño con un MAE de 4.21 mm y un $R^2 = 0.8997$, validando su robustez ante posibles valores atípicos.

Tabla 5.1: Comparación de las métricas de desempeño claves de los modelos en el conjunto de prueba.

Modelo	MAE (mm)	RMSE (mm)	R^2	Error relativo (%)
ElasticNet	3.2670	4.1696	0.9412	1.20
Huber Regressor	4.2076	5.6552	0.8997	1.55*
Random Forest	14.2712	21.6483	0.8263	5.26
XGBoost	10.4100	16.2500	0.8583	3.83

*El error relativo del modelo Huber se calculó con la fórmula: $\text{MAE}/\bar{y}_{\text{test}} \times 100\%$.

En contraste, XGBoost reportó un MAE de 10.41 mm ($R^2 = 0.8583$) y Random Forest presentó el peor desempeño con (MAE = 14.27 mm, RMSE = 21.65 mm). Estas cifras indican que ElasticNet reduce el error absoluto medio en un 68.6 % y 77.1 % frente a XGBoost y Random Forest, respectivamente, y en un 22.3 % respecto al Huber Regressor. Cuando evaluamos el RMSE, los árboles de decisión muestran desviaciones cuadráticas promedio que son entre 2.9 y 5.2 veces mayores que las de los penalizadores lineales (ElasticNet = 4.17 mm; Huber = 5.66 mm), lo que evidencia que los errores puntuales extremos se controlan con mucha más eficacia mediante las regularizaciones L_1 y L_2 .

Este comportamiento se explica, por un lado, por el tamaño reducido del conjunto de entrenamiento (36 plantas), escenario en el cual los modelos parsimoniosos con penalización de complejidad son menos propensos al sobreajuste. Por otro, las relaciones entre las variables ambientales, el diámetro basal y la altura parecen adecuadamente capturadas por combinaciones lineales, sin requerir la flexibilidad extrema de los ensambles de árboles.

En el contexto de este estudio, donde el objetivo es realizar un seguimiento detallado del crecimiento diario, los modelos de regresión regularizada demostraron mayor eficacia que los métodos basados en árboles. ElasticNet destaca por su balance entre precisión y estabilidad, mientras que el modelo Huber ofrece una alternativa robusta ante ruidos o posibles valores atípicos. Por su parte, XGBoost y Random Forest, si bien son modelos más complejos y potentes en grandes volúmenes de datos, no lograron superar a los enfoques lineales en este conjunto reducido. Estos resultados enfatizan la importancia de adaptar la complejidad del modelo al tamaño y naturaleza del conjunto de datos disponible.

5.3.2. Evaluación de la robustez

La robustez de un modelo de aprendizaje automático se refiere a su capacidad para mantener un rendimiento estable frente a pequeñas perturbaciones en los datos de entrada, como aquellas provocadas por ruido instrumental, variaciones ambientales o errores de medición. En el contexto agrícola, esta propiedad es fundamental debido a que las condiciones en el campo son inherentemente ruidosas, y la confiabilidad del modelo debe sostenerse incluso cuando los sensores no operan en condiciones ideales.

Para analizar la robustez de los modelos ante perturbaciones en los datos de entrada, se introdujo ruido gaussiano aditivo con una desviación estándar equivalente al 5 % del valor de cada variable predictora en el conjunto de prueba. Esta simulación representa posibles imprecisiones en la medición de variables ambientales o fisiológicas durante la implementación en campo. Posteriormente, se evaluó el rendimiento de los modelos frente a estos datos alterados mediante las cuatro métricas utilizadas en este trabajo: MAE, RMSE, R^2 y error relativo porcentual. La Tabla 5.2 resume los resultados obtenidos, y permite comparar la sensibilidad de cada enfoque ante pequeñas perturbaciones en las condiciones de entrada.

Tabla 5.2: Comparación de métricas bajo nivel de ruido del 5 % para todos los modelos.

Modelo	MAE (mm)	RMSE (mm)	R ²	Error relativo (%)
ElasticNet	4.19	5.47	0.9393	1.53
Huber Regressor	5.99	7.65	0.9011	2.19
Random Forest	14.44	21.95	0.8259	5.33
XGBoost	10.49	16.35	0.8580	3.84

Los resultados indican que el modelo ElasticNet presenta la mayor robustez entre todos los enfoques evaluados. Este modelo exhibe los valores más bajos tanto de MAE como de RMSE frente al nivel de ruido del 5 %. Además, su pérdida de desempeño es moderada y progresiva, lo que refleja una alta estabilidad frente a errores en las mediciones o a variaciones naturales en las variables de entrada. En particular, el incremento del MAE fue de apenas 2.18 mm al pasar del 1 % al 10 % de ruido, mientras que el RMSE aumentó solamente 3.06 mm en el mismo intervalo.

El modelo Huber Regressor, diseñado específicamente para tolerar valores atípicos, también muestra una respuesta relativamente estable ante perturbaciones. Sin embargo, sus errores son sistemáticamente superiores a los obtenidos por ElasticNet, y esta diferencia se amplifica a medida que aumenta el nivel de ruido. Esto sugiere que, aunque el modelo es eficaz frente a valores extremos aislados, su capacidad para enfrentar una incertidumbre generalizada en todas las variables es más limitada en comparación con el modelo ElasticNet.

En el caso de Random Forest, el rendimiento permanece prácticamente constante ante el aumento de ruido, pero en un nivel de error considerablemente más alto. Esto sugiere que el modelo podría estar sobreajustado a las particularidades del conjunto de entrenamiento, lo que limita su capacidad para adaptarse a condiciones modificadas. Por su parte, XGBoost muestra una ligera variación en las métricas con el aumento del ruido, pero en términos generales mantiene un comportamiento robusto de nivel intermedio. Aun así, su desempeño global continúa siendo inferior al de los modelos lineales en este conjunto reducido de datos.

En conjunto, la evaluación de la robustez confirma los hallazgos previamente obtenidos mediante las métricas de desempeño en condiciones normales. ElasticNet no solo proporciona una alta precisión, sino que también mantiene su estabilidad ante perturbaciones, lo cual resulta esencial para aplicaciones en entornos agrícolas reales, caracterizados por variaciones continuas en las condiciones ambientales y posibles imprecisiones en la recolección de datos.

5.3.3. Selección del modelo final

En aplicaciones agrícolas, los modelos de inteligencia artificial destinados a predecir variables de crecimiento vegetal o condiciones ambientales deben equilibrar precisión y claridad interpretativa [94]. La capacidad de explicar el comportamiento del sistema a técnicos y productores es tan importante como la precisión de los pronósticos. Por ello, evaluar los modelos únicamente por métricas numéricas es insuficiente si no se considera también su interpretabilidad y viabilidad de implementación.

Para la selección del modelo final se consideraron cuatro criterios: (1) desempeño predictivo, (2) robustez frente a datos anómalos, (3) requerimientos computacionales y (4) facilidad de implementación en sistemas embebidos, especialmente relevante en entornos con recursos limitados.

El primer criterio se evaluó mediante métricas como el coeficiente de determinación, que indica qué proporción de la variabilidad observada es explicada por el modelo. Valores altos de R^2 reflejan una mejor capacidad predictiva.

En segundo lugar, se consideró la robustez ante datos con ruido o valores atípicos, comunes en registros agrícolas debido a fluctuaciones ambientales.

El tercer criterio se centró en la complejidad computacional. Modelos simples son preferibles en contextos con infraestructura limitada, donde el consumo de memoria y procesamiento debe mantenerse bajo.

Finalmente, la posibilidad de implementación embebida fue clave. Para operar en tiempo real sobre plataformas como microcontroladores, los modelos deben ser ligeros y eficientes.

Evaluando los modelos bajo estos criterios, ElasticNet y Huber Regressor presentaron los mejores resultados. ElasticNet alcanzó un $R^2 = 0.9412$, explicando más del 94 % de la variabilidad en el crecimiento vegetal. Huber Regressor obtuvo un $R^2 = 0.8997$, también con errores absolutos menores a 5 mm.

Random Forest y XGBoost mostraron menor desempeño en este conjunto de datos, con R^2 de 0.8263 y 0.8583 respectivamente. Estos modelos tienden a sobreajustar cuando se dispone de pocos datos, lo que puede afectar su capacidad de generalización.

En términos de robustez, Huber Regressor fue el más resistente frente a valores atípicos. ElasticNet también mostró buen comportamiento gracias a su combinación de penalizaciones L1 y L2.

Respecto a los recursos computacionales, ElasticNet y Huber destacaron por su bajo consumo de memoria y procesamiento, a diferencia de Random Forest y XGBoost, que requieren estructuras más complejas y mayor capacidad de cómputo.

En cuanto a implementación, los modelos lineales son adecuados para microcontroladores como ESP32 o Arduino. En cambio, Random Forest y XGBoost presentan mayores dificultades por la necesidad de gestionar múltiples árboles de decisión.

En conclusión, ElasticNet fue el modelo más adecuado al satisfacer todos los criterios: alto rendimiento predictivo, robustez, eficiencia computacional y fácil integración en sistemas embebidos. Huber Regressor representa una opción sólida en presencia de datos atípicos, aunque con menor desempeño global. Random Forest y XGBoost pueden ser útiles en escenarios con más datos y mayor capacidad computacional, pero no resultan óptimos para aplicaciones agrícolas en pequeña escala.

5.3.4. Interpretabilidad del modelo

Para evaluar la interpretabilidad del modelo ElasticNet se utilizaron dos enfoques complementarios: los valores SHAP (SHapley Additive exPlanations) y la importancia por permutación. Ambos métodos permiten identificar cuáles variables contribuyen de manera más significativa a las predicciones del modelo, pero lo hacen desde perspectivas

diferentes.

SHAP

El análisis mediante valores SHAP cuantifica la contribución individual de cada característica a la predicción para cada observación. En la Figura 5.6, se muestra la importancia media absoluta de cada variable. Para ello se utilizó la implementación de la librería SHAP, con un muestreador de 29 muestras para estimar de forma eficiente las contribuciones. La Figura 5.6 presenta la importancia media absoluta de cada variable, donde destacan con claridad el PPFD y el DLI . Estos indicadores luminosos registran los valores SHAP más elevados, lo que confirma su papel predominante en la dinámica de crecimiento de *Cannabis sativa*. A continuación aparecen el día de cultivo (día cronológico) y el tratamiento lumínico, mientras que la temperatura, la humedad relativa y el déficit de presión de vapor (VPD) aparecen con valores muy cercanos a cero, indicando escasa influencia en el modelo.




Figura 5.6: Importancia media absoluta de variables según SHAP para el modelo ElasticNet.

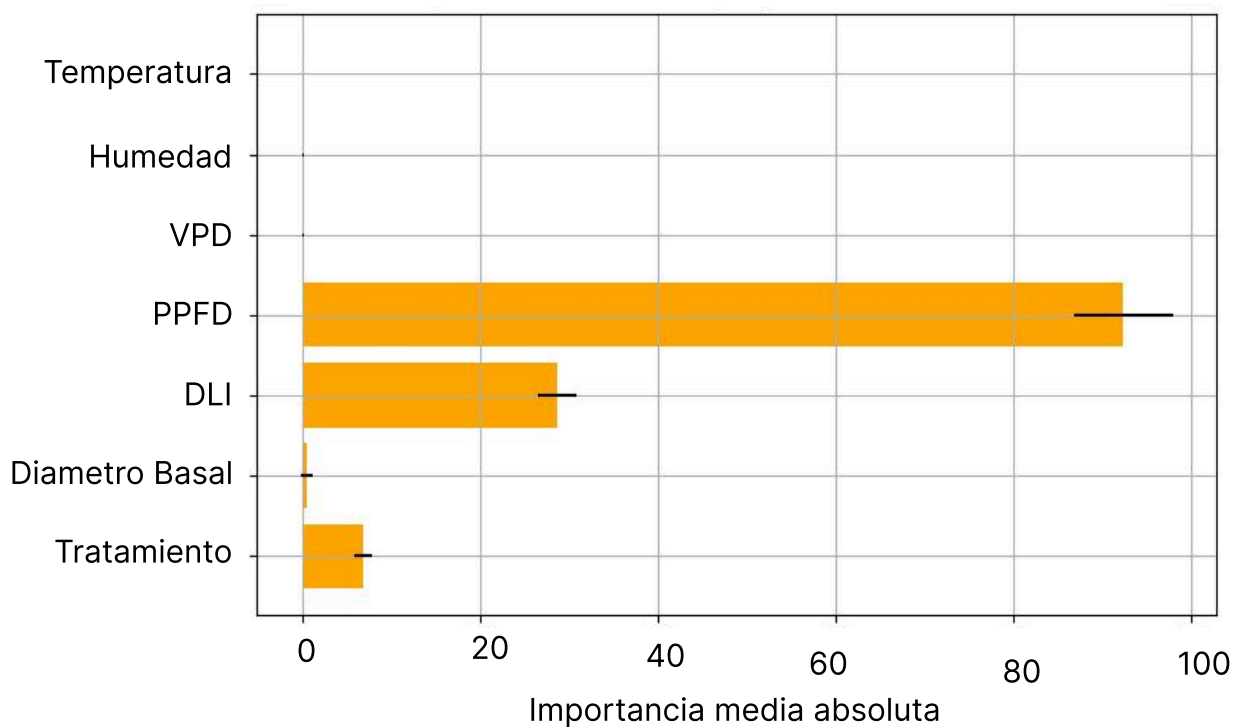


Figura 5.7: Importancia de variables por permutación para el modelo ElasticNet (disminución en MAE).

Permutación.

La importancia por permutación se basó en la alteración del orden de cada variable de entrada para medir la disminución del desempeño del modelo, en este caso evaluado por el aumento del error MAE. Como se observa en la Figura 5.7, los resultados son consistentes con los obtenidos con SHAP, ya que el PPFd y el DLI vuelven a destacar como las variables más importantes. La disminución en el rendimiento al permutar estas variables es considerable, lo cual refuerza su rol central en la predicción del crecimiento vegetal. Otras variables, como el tratamiento y el diámetro, tienen una menor, pero no despreciable, influencia. El resto de las variables ambientales tienen impacto casi nulo en el modelo.

La estrecha coincidencia entre los perfiles de importancia obtenidos con SHAP y permutación confirma de manera sólida que los factores luminosos son los principales motores del crecimiento en altura durante la fase vegetativa del cultivo. Desde un punto de vista fisiológico, esto tiene sentido, ya que el PPFd determina la tasa instantánea de captura de fotones por la maquinaria fotosintética, mientras que el DLI integra esa captura a lo largo del día, correlacionándose directamente con la acumulación de carbohidratos y la elongación del tallo.

La aparente irrelevancia de la temperatura y la humedad relativa debe interpretarse en el contexto de un invernadero con condiciones térmicas y hídricas muy controladas. En un rango tan estrecho, esas variables apenas aportan señal adicional al modelo. No

obstante, esto no desacredita su papel agronómico, pues en escenarios de estrés térmico o déficit hídrico, su influencia crecería y debería ser reintroducida en ámbitos de cultivo más variables.

Del mismo modo, el diámetro basal mostró un peso intermedio en la explicación de la altura futura, lo cual refleja su alta colinealidad con la altura inicial; para futuros estudios sería útil evaluar interacciones no lineales o incluir métricas de biomasa adicionales (por ejemplo, área foliar o contenido de clorofila).

Capítulo 6

Conclusiones y perspectivas

Modelar el crecimiento de *Cannabis sativa* durante su fase vegetativa requirió articular tres componentes fundamentales: un sistema de monitoreo IoT, el análisis experimental de respuestas fisiológicas y el desarrollo de modelos predictivos basados en técnicas de aprendizaje automático. En primer lugar, se implementó un sistema de adquisición de datos con sensores de bajo costo conectados a un microcontrolador ESP32-S2, que permitió medir temperatura, humedad relativa y espectro lumínico. La calibración de los sensores ambientales y la validación espectral frente a un espectrofotómetro de referencia garantizaron la calidad de las mediciones, mientras que la arquitectura modular de borde y nube demostró ser escalable y funcional ante posibles interrupciones de conectividad.

En segundo lugar, se evaluaron tres composiciones espectrales a través de un diseño experimental de bloques completos al azar, midiendo la tasa relativa de crecimiento y la variabilidad entre plantas. El análisis de varianza indicó diferencias significativas entre tratamientos ($p < 0.001$), con un tratamiento rico en rojo (650 nm) que promovió una mayor elongación de tallo, mientras que la fracción azul tendió a moderar ese efecto. La correlación de Pearson ($r = 0.78$) confirmó la asociación positiva entre el balance espectral y la tasa de crecimiento.

En el modelado predictivo, se compararon cuatro técnicas de regresión y ensamble sobre un horizonte de predicción de 20 días. El modelo ElasticNet, optimizado mediante búsqueda bayesiana, alcanzó un MAE de 3.27 mm (error relativo del 1.20 %) y un coeficiente de determinación R^2 de 0.9412, explicando más del 94 % de la variabilidad en la altura proyectada. Al introducir ruido gaussiano del 5 % a las entradas, el error creció solo un 28 %, lo que refleja una alta estabilidad ante imprecisiones instrumentales. El modelo Huber Regressor, diseñado para resistir valores atípicos, obtuvo un MAE de 4.21 mm y un R^2 de 0.8997, confirmando su robustez aunque con un desempeño ligeramente inferior. Por otro lado, XGBoost (MAE = 10.41 mm, $R^2 = 0.8583$) y Random Forest (MAE = 14.27 mm, $R^2 = 0.8263$), aunque efectivos en contextos no lineales, no superaron a los modelos lineales en este conjunto de datos.

El análisis de interpretabilidad, utilizando valores SHAP y permutación de variables, reveló que la PPFD y la DLI fueron las variables más determinantes para el crecimiento en altura. Ambos métodos coincidieron en situar estos indicadores a la cabeza de la jerarquía de predictores, lo que refleja la influencia directa de la captación instantánea y acumulada de fotones sobre la síntesis de biomasa. Esta correspondencia entre los resultados de los modelos y los fundamentos fisiológicos de la fotosíntesis respalda la

utilidad práctica del enfoque propuesto, permitiendo vincular condiciones de iluminación con pronósticos confiables de crecimiento en cultivos de cannabis durante la etapa vegetativa.

Limitaciones y trabajos futuros

Este trabajo presenta ciertas limitaciones que abren oportunidades para futuras investigaciones. En primer lugar, no se incluyó un sistema de medición continua de CO₂, debido a la ausencia de un medidor de referencia que garantizara la confiabilidad de las mediciones, lo cual impidió analizar con precisión su posible influencia sobre el crecimiento de las plantas. Además, el estudio se centró exclusivamente en una variedad específica de *Cannabis sativa* y en la etapa inicial de desarrollo, lo que limita la extrapolación de los resultados a otras genéticas y fases fenológicas. Asimismo, algunos de los sensores utilizados, especialmente los de radiación, podrían ser reemplazados por dispositivos de mayor precisión, capaces de proporcionar una caracterización espectral más detallada. Como proyección futura, sería pertinente incorporar un sistema de control con dosificación de CO₂, repetir el estudio con diferentes variedades de cannabis en condiciones más cercanas a las reales y con densidades de plantación elevadas, así como extender el análisis a otras etapas del ciclo de vida, incluyendo herramientas para la estimación del crecimiento en biomasa seca, como técnicas de visión artificial.

Bibliografía

- [1] UNIR Revista, “La agricultura 4.0: tecnología y digitalización”., <https://www.unir.net/revista/ingenieria/agricultura-4-0/> (visitado el 2025-08-29).
- [2] AgroTech Campus, “Big data e inteligencia artificial en la agricultura”., <https://agrotechcampus.com/blog/big-data-e-inteligencia-artificial-en-la-agricultura/> (visitado el 2025-08-29).
- [3] Hurtado, J. S., “Qué es blockchain y cómo funciona la tecnología blockchain”., <https://www.iebschool.com/hub/blockchain-cadena-bloques-revoluciona-sector-financiero-finanzas/> (visitado el 2025-08-29).
- [4] Galiana, J. M., “Logística 4.0: ¿qué es? beneficios y tecnologías clave”., <https://blog.toyota-forklifts.es/logistica-4-0-que-es-futuro-almacenes> (visitado el 2025-08-29).
- [5] Sánchez-Palacios, L. E., Cárdenas-Rodríguez, M., Murillo-Molina, J. L., y Chacón-Franco, V. M., “El internet de las cosas en la agricultura”, Polo del Conocimiento, vol. 10, no. 2, pp. 766–778, doi:10.23857/pc.v10i2.8914.
- [6] Boyd, A. P., Zankowski, P., Wheeler, R., Stokes-Draut, J. R., Chudnovsky, Y., Ingram, D., Tijerina, M., Mickens, M., Steward, D., Armstrong, K., Boggs, A. S. P., Neely, B. A., Lunney, J. K., y Luo, Y., “Controlled environment agriculture: An opportunity to strengthen interagency research collaboration in the us government”, PNAS Nexus, vol. 4, no. 6, p. pgaf155, 2025, doi:10.1093/pnasnexus/pgaf155. eCollection 2025 Jun.
- [7] Burritt, M., Valle de Souza, S., y Peterson, H. C., “When will controlled environment agriculture in its vertical form fulfill its potential?”, Sustainability, vol. 17, no. 7, 2025, doi:10.3390/su17072957.
- [8] Gómez, C., Currey, C. J., Dickson, R. W., Kim, H.-J., Hernández, R., Sabeh, N. C., Raudales, R. E., Brumfield, R. G., Laury-Shaw, A., Wilke, A. K., Lopez, R. G., y Burnett, S. E., “Controlled environment food production for urban agriculture”, HortScience, vol. 54, no. 9, pp. 1448–1458, 2019, doi:10.21273/HORTSCI14073-19.
- [9] GMP Journal, “Quality standards for medical cannabis - update on pharmacopoeial monographs”, GMP Journal, 2023, <https://www.gmp-journal.com>. Este artículo detalla los requisitos de calidad para el cannabis medicinal, incluyendo los perfiles de cannabinoides y los límites de impurezas.
- [10] ECA Academy, “Usp publishes draft on quality requirements for cannabis”, GMP Compliance News, 2023, <https://www.gmp-compliance.org>. La USP publicó un borrador con los requerimientos de calidad del cannabis medicinal, incluyendo los límites de contaminantes y el perfil de cannabinoides.

- [11] Thieme, “Cannabis flower quality: Standards and production guidelines”, Thieme Connect, 2023, <https://www.thieme-connect.com/products/ejournals/pdf/10.1055/a-1808-9708.pdf>. Estándares de calidad para la producción de flores de cannabis, incluyendo características microscópicas y macroscópicas, además de límites de impurezas.
- [12] ResearchAndMarkets.com, “Cannabis cultivation market size, share, trends, analysis, and forecast 2025–2034 | global industry growth, competitive landscape, opportunities, and challenges”, Business Wire, 2025, <https://www.businesswire.com/news/home/20250619398160/en/Cannabis-Cultivation-Market-Research-Report-2025-2034-Advanced-Techniques-and-Technologies-Drive-Cultivation-Efficiency-Sustainable-Practices-Gaining-Traction---ResearchAndMarkets.com>. Press release based on the ResearchAndMarkets.com report.
- [13] Liang, J., Ji, F., Zhou, Q., y He, D., “Optimizing led light intensity and photoperiod to promote growth and rooting of cannabis sativa plantlets via photoautotrophic micropropagation”, *Plants (MDPI)*, vol. XX, 2025.
- [14] Arora, A. S. y Yun, C. M., “Dynamic spectrum lighting impact on plant morphology and cannabinoid profile of medical and recreational cannabis – a novel leapfrog strategy towards shaping the future of horticulture lighting”, *Industrial Crops and Products*, vol. 199, p. 116799, 2023, [doi:10.1016/j.indcrop.2023.116799](https://doi.org/10.1016/j.indcrop.2023.116799).
- [15] Holweg, M. M. S. F., Kaiser, E., Kappers, I. F., Heuvelink, E., y Marcelis, L. F. M., “The role of red and white light in optimizing growth and accumulation of plant specialized metabolites at two light intensities in medical cannabis (*cannabis sativa* L.)”, *Frontiers in Plant Science*, vol. 15, p. 1393803, 2024, [doi:10.3389/fpls.2024.1393803](https://doi.org/10.3389/fpls.2024.1393803).
- [16] Vergara, D., *Cannabis sativa* L. Production Manual. Cornell Cooperative Extension, Harvest New York, 1 ed., 2023. <https://harvestny.cce.cornell.edu/submission.php?id=159>.
- [17] Sánchez, E., McDonald, J. A., y Baldwin, I. T., “Genomic and chemical diversity in cannabis: Implications for breeding and cultivar registration”, *Journal of Agricultural and Food Chemistry*, vol. 64, no. 28, pp. 5469–5479, 2016, [doi:10.1021/acs.jafc.6b01821](https://doi.org/10.1021/acs.jafc.6b01821).
- [18] Soja, M., Walters, K., Baldwin, R., De la Cruz, M., y Wright, M., “Cannabis domestication, breeding history, present-day genetic diversity and future prospects”, *Plant Genetics and Genomics*, vol. 12, no. 4, pp. 223–244, 2021, [doi:10.1093/pg2/12.4.223](https://doi.org/10.1093/pg2/12.4.223).
- [19] Correa, J. F. y otros, “Comportamiento agronómico de seis genotipos de cannabis sp. no psicoactivo en el trópico alto colombiano”, *Ciencia y Tecnología Agropecuaria*, vol. 24, no. 1, p. e2698, 2023, [doi:10.21930/rcta.vol24_num1_art:2698](https://doi.org/10.21930/rcta.vol24_num1_art:2698).
- [20] Azcón-Bieto, J. y Talón, M. T., *Fundamentos de Fisiología Vegetal*. Madrid, España: McGraw-Hill, 2ª edición ed., 2013.
- [21] Palma, C. F. F., Castro-Alves, V., Morales, L. O., Rosenqvist, E., Ottosen, C.-O., y Strid, , “Spectral composition of light affects sensitivity to uv-b and photoinhibition in cucumber”, *Frontiers in Plant Science*, vol. 11, p. 610011, 2021, [doi:10.3389/fpls.2020.610011](https://doi.org/10.3389/fpls.2020.610011).

- [22] Wei, X., Zhao, X., Long, S., Xiao, Q., Guo, Y., Qiu, C., Qiu, H., y Wang, Y., “Wavelengths of led light affect the growth and cannabidiol content in *cannabis sativa* l”, *Industrial Crops and Products*, vol. 165, p. 113433, 2021, doi:<https://doi.org/10.1016/j.indcrop.2021.113433>.
- [23] Zhen, S., van Iersel, M. W., y Bugbee, B., “Photosynthesis in sun and shade: the surprising importance of far-red photons”, *New Phytologist*, vol. 236, no. 2, pp. 538–546, 2022, doi:<https://doi.org/10.1111/nph.18375>.
- [24] Taiz, L. y Zeiger, E., *Plant Physiology*. Sinauer Associates, 4th edition ed., 2006. Referencia sugerida.
- [25] Kong, Y. y Zheng, Y., “Diverse flowering response to blue light manipulation: Application of electric lighting in controlled-environment plant production”, *Horticulturae*, vol. 10, p. 578, 2024, doi:[10.3390/horticulturae10060578](https://doi.org/10.3390/horticulturae10060578).
- [26] Rodriguez-Morrison, V., Llewellyn, D., y Zheng, Y., “Cannabis yield, potency, and leaf photosynthesis respond differently to increasing light levels in an indoor environment”, *Frontiers in Plant Science*, vol. 12, p. 646020, 2021, doi:[10.3389/fpls.2021.646020](https://doi.org/10.3389/fpls.2021.646020).
- [27] Konvalina, P., Neumann, J., Hoang, T. N., Bernas, J., Trojan, V., Kuchář, M., Lošák, T., y Varga, L., “Effect of light intensity and two different nutrient solutions on the yield of flowers and cannabinoids in *Cannabis sativa* l. grown in controlled environment”, *Agronomy*, vol. 14, no. 12, p. 2960, 2024, doi:[10.3390/agronomy14122960](https://doi.org/10.3390/agronomy14122960).
- [28] Ahrens, A., Llewellyn, D., y Zheng, Y., “Longer photoperiod substantially increases indoor-grown cannabis’ yield and quality: A study of two high-thc cultivars grown under 12 h vs. 13 h days”, *Plants*, vol. 13, no. 3, p. 433, 2024, doi:[10.3390/plants13030433](https://doi.org/10.3390/plants13030433).
- [29] Ashleigh Ahrens, D. L. y Zheng, Y., “Is twelve hours really the optimum photoperiod for promoting flowering in indoor-grown cultivars of *cannabis sativa*?””, *Plants*, vol. 12, no. 2605, 2023, doi:[10.3390/plants12142605](https://doi.org/10.3390/plants12142605).
- [30] Lo Presti, D., Di Tocco, J., Massaroni, C., Cimini, S., De Gara, L., Singh, S., Raucci, A., Manganiello, G., Woo, S. L., Schena, E., y Cinti, S., “Current understanding, challenges and perspective on portable systems applied to plant monitoring and precision agriculture”, *Biosensors and Bioelectronics*, vol. 222, p. 115005, 2023, doi:<https://doi.org/10.1016/j.bios.2022.115005>.
- [31] Suman Chandra, Hemant Lata, I. A. K. y Elsohly, M. A., “Photosynthetic response of *cannabis sativa* l. to variations in photosynthetic photon flux densities, temperature and co2 conditions”, *Physiology and Molecular Biology of Plants*, vol. 14, no. 4, p. 299–306, 2008, doi:[10.1007/s12298-008-0027-x](https://doi.org/10.1007/s12298-008-0027-x).
- [32] Chandra, S., Lata, H., Khan, I., y Elsohly, M., “Photosynthetic response of *cannabis sativa* l., an important medicinal plant, to elevated levels of co2”, *Physiology and molecular biology of plants : an international journal of functional plant biology*, vol. 17, pp. 291–5, 2011, doi:[10.1007/s12298-011-0066-6](https://doi.org/10.1007/s12298-011-0066-6).
- [33] Holweg, M. M., Curren, T., Cravino, A., Kaiser, E., Kappers, I. F., Heuvelink, E., y Marcelis, L. F., “High air temperature reduces plant specialized metabolite yield

- in medical cannabis, and has genotype-specific effects on inflorescence dry matter production”, *Environmental and Experimental Botany*, vol. 230, p. 106085, 2025, [doi:https://doi.org/10.1016/j.envexpbot.2025.106085](https://doi.org/10.1016/j.envexpbot.2025.106085).
- [34] Chaparro Suárez, J. E., “Evaluación del comportamiento fisiológico y producción de metabolitos secundarios en cannabis sativa l. bajo diferentes condiciones ambientales en invernadero”, Master’s thesis, Universidad Nacional de Colombia, 2022.
- [35] Bugbee, B., “Cannabis physiology and cultivation: science, technology, and challenges”, *Horticultural Reviews*, vol. 49, pp. 1–69, 2021, [doi:10.1002/9781119857447.ch1](https://doi.org/10.1002/9781119857447.ch1).
- [36] Caplan, D., Dixon, M., y Zheng, Y., “Optimal rate of organic fertilizer during the flowering stage for cannabis grown in two coir-based substrates”, *HortScience*, vol. 52, no. 12, pp. 1796–1803, 2017, [doi:10.21273/HORTSCI12453-17](https://doi.org/10.21273/HORTSCI12453-17).
- [37] Nugroho, E. D., Putrada, A. G., y Rakhmatsyah, A., “Predictive control on lettuce nft-based hydroponic iot using deep neural network”, en *2021 International Symposium on Electronics and Smart Devices (ISESD)*, pp. 1–6, 2021, [doi:10.1109/ISESD53023.2021.9501402](https://doi.org/10.1109/ISESD53023.2021.9501402).
- [38] Weingarten, M., Mattson, N., y Grab, H., “Evaluating propagation techniques for cannabis sativa l. cultivation: A comparative analysis of soilless methods and aeroponic parameters”, *Plants*, vol. 13, no. 9, 2024, [doi:10.3390/plants13091256](https://doi.org/10.3390/plants13091256).
- [39] Adhikary, D., Kulkarni, M., El-Mezawy, A., Mobini, S., Elhiti, M., Gjuric, R., Ray, A., Polowick, P., Slaski, J. J., Jones, M. P., y Bhowmik, P., “Medical cannabis and industrial hemp tissue culture: Present status and future potential”, *Frontiers in Plant Science*, vol. 12, p. 627240, 2021, [doi:10.3389/fpls.2021.627240](https://doi.org/10.3389/fpls.2021.627240).
- [40] Yep, B., Gale, N. V., y Zheng, Y., “Aquaponic and hydroponic solutions modulate nacl-induced stress in drug-type cannabis sativa l.”, *Frontiers in Plant Science*, vol. 11, p. 1169, 2020, [doi:10.3389/fpls.2020.01169](https://doi.org/10.3389/fpls.2020.01169).
- [41] Saloner, A. y Bernstein, N., “Effect of potassium (k) supply on cannabinoids, terpenoids and plant function in medical cannabis”, *Agronomy*, vol. 12, no. 5, p. 1242, 2022, [doi:10.3390/agronomy12051242](https://doi.org/10.3390/agronomy12051242).
- [42] Caplan, D., Dixon, M., y Zheng, Y., “Optimal rate of organic fertilization for greenhouse cannabis: A field study evaluating the effect of nitrogen availability on yield and quality”, *HortScience*, vol. 52, no. 12, pp. 1796–1803, 2017, [doi:10.21273/HORTSCI12368-17](https://doi.org/10.21273/HORTSCI12368-17).
- [43] Hati, A. y Singh, R., “Ai-driven pheno-parenting: A deep learning-based plant phenotyping trait analysis model on a novel soilless farming dataset”, *IEEE Access*, vol. 11, pp. 35297–35310, 2023, [doi:10.1109/ACCESS.2023.3245598](https://doi.org/10.1109/ACCESS.2023.3245598).
- [44] Saloner, A. y Bernstein, N., “Effect of potassium (k) supply on cannabinoids, terpenoids and plant function in medical cannabis”, *Agronomy*, vol. 12, no. 5, p. 1242, 2022, [doi:10.3390/agronomy12051242](https://doi.org/10.3390/agronomy12051242).
- [45] Eze, V. H. U., Okafor, W. O., Odo, J. I., Ugwu, C. N., Chukwudi, O. F., y Edozie, E., “A critical assessment of data loggers for farm monitoring: Addressing limitations and advancing towards enhanced weather monitoring systems”, *International Journal of Education, Science, Technology, and Engineering*, vol. 6, no. 2, pp. 55–67,

- 2023, doi:[10.36079/lamintang.ijeste-0602.593](https://doi.org/10.36079/lamintang.ijeste-0602.593).
- [46] Barbosa, J., Freitas, V., Vidotto, L., *et al.*, “Biocompatible wearable electrodes on leaves toward the on-site monitoring of water loss from plants”, *ACS Applied Materials & Interfaces*, vol. 14, no. 17, pp. 20561–20573, 2022, doi:[10.1021/acsami.2c02943](https://doi.org/10.1021/acsami.2c02943).
- [47] Vernon, M. *et al.*, “A survey of modern greenhouse technologies and practices for commercial cannabis cultivation”, *IEEE Access*, vol. 11, pp. 62079–62094, 2023, doi:[10.1109/ACCESS.2023.3281009](https://doi.org/10.1109/ACCESS.2023.3281009).
- [48] Soussi, A., Zero, E., Sacile, R., Trincherro, D., y Fossa, M., “Smart sensors and smart data for precision agriculture: A review”, *Sensors*, vol. 24, no. 8, p. 2647, 2024.
- [49] Morales-Guerra, J., Suarez-Cortez, S., Morales-Duran, J., Reyes-Vera, E., y Botero-Valencia, J., “Smartgrow datacontrol: An iot architecture for the acquisition of environmental physiological parameters in cannabis sativa cultivations”, *SoftwareX*, vol. 27, p. 101880, 2024, doi:<https://doi.org/10.1016/j.softx.2024.101880>.
- [50] Guerra-Londono, M., Urrea, G., Botero-Valencia, J., y Reyes-Vera, E., “Design, implementation, and modeling of a lora network installed in a freshwater body”, en *Smart Technologies, Systems and Applications* (Narváez, F. R., Proaño, J., Morillo, P., Vallejo, D., González Montoya, D., y Díaz, G. M., eds.), (Cham), pp. 17–29, Springer International Publishing, 2022.
- [51] Botero-Valencia, J., Reyes-Vera, E., Ospina-Rojas, E., y Prieto-Ortiz, F., “A portable tool for spectral analysis of plant leaves that incorporates a multichannel detector to enable faster data capture”, *Instruments*, vol. 8, no. 1, p. 24, 2024, doi:[10.3390/instruments8010024](https://doi.org/10.3390/instruments8010024).
- [52] Botero-Valencia, J., García-Pineda, V., Valencia-Arias, A., Valencia, J., Reyes-Vera, E., Mejia-Herrera, M., y Hernández-García, R., “Machine learning in sustainable agriculture: Systematic review and research perspectives”, *Agriculture*, vol. 15, no. 4, 2025, doi:[10.3390/agriculture15040377](https://doi.org/10.3390/agriculture15040377).
- [53] Magagnini, G., Grassi, G., y Kotiranta, S., “The effect of light spectrum on the morphology and cannabinoid content of cannabis sativa l.”, *European Journal of Agronomy*, vol. 84, pp. 1–9, 2018, doi:[10.1016/j.eja.2016.11.005](https://doi.org/10.1016/j.eja.2016.11.005).
- [54] Rossi, R., Costafreda-Aumedes, S., Leolini, L., Leolini, C., Bindi, M., y Moriondo, M., “Implementation of an algorithm for automated phenotyping through plant 3d-modeling: A practical application on the early detection of water stress”, *Computers and Electronics in Agriculture*, vol. 197, p. 106937, 2022, doi:[10.1016/j.compag.2022.106937](https://doi.org/10.1016/j.compag.2022.106937).
- [55] Kaburuan, E. R., Jayadi, R., y Harisno, “A design of iot-based monitoring system for intelligence indoor micro-climate horticulture farming in indonesia”, *Procedia Computer Science*, vol. 157, pp. 459–464, 2019, doi:<https://doi.org/10.1016/j.procs.2019.09.001>. The 4th International Conference on Computer Science and Computational Intelligence (ICCSCI 2019) : Enabling Collaboration to Escalate Impact of Research Results for Society.
- [56] Kusuma, P., Pattison, P. M., y Bugbee, B., “From physics to fixtures to food: current and potential led efficacy”, *Horticulture Research*, vol. 7, no. 1, p. 56,

- 2020, doi:10.1038/s41438-020-0283-7.
- [57] Danziger, N. y Bernstein, N., “Light matters: Effect of light spectra on cannabinoid profile and plant development of medical cannabis (*cannabis sativa* l.)”, *Industrial Crops and Products*, vol. 164, p. 113351, 2021, doi:<https://doi.org/10.1016/j.indcrop.2021.113351>.
- [58] Li, L., Zhang, Q., y Huang, D., “A review of imaging techniques for plant phenotyping”, *Sensors*, vol. 14, no. 11, pp. 20078–20111, 2014, doi:10.3390/s141120078.
- [59] Morello, V., Brousseau, V. D., Wu, N., Wu, B.-S., MacPherson, S., y Lefsrud, M., “Light quality impacts vertical growth rate, phytochemical yield and cannabinoid production efficiency in *cannabis sativa*”, *Plants*, vol. 11, no. 21, 2022, doi:10.3390/plants11212982.
- [60] Moher, M., Llewellyn, D., Golem, S., Foley, E., Dinka, S., Jones, A., y Zheng, Y., “Light spectra have minimal effects on rooting and vegetative growth responses of clonal cannabis cuttings”, *HortScience: a publication of the American Society for Horticultural Science*, vol. 58, pp. 215–221, 2023, doi:10.21273/HORTSCI16752-22.
- [61] Honsberg, C. y Bowden, S., “Photon flux”, 2014, <https://www.pveducation.org/pvcdrom/properties-of-sunlight/photon-flux>. Consulted 15 June 2025.
- [62] Berthold Technologies, “How to convert irradiance into photon flux”, 2023, <https://www.berthold.com/en-us/bioanalytics/knowledge/faq/how-to-convert-irradiance-into-photon-flux/>. Consulted 15 June 2025.
- [63] Kotiranta, S., Pihlava, J.-M., Kotilainen, T., y Palonen, P., “The morphology, inflorescence yield, and secondary metabolite accumulation in hemp type *Cannabis sativa* can be influenced by the r:fr ratio or the amount of short wavelength radiation in a spectrum”, *Industrial Crops and Products*, vol. 208, p. 117772, 2024, doi:10.1016/j.indcrop.2023.117772.
- [64] Islam, M. J., Ryu, B. R., Azad, O., Rahman, M. H., Rana, M., Kang, C.-W., Lim, J., y Lim, Y.-S., “Comparative growth, photosynthetic pigments, and osmolytes analysis of hemp (*cannabis sativa* l.) seedlings under an aeroponics system with different led light sources”, *Horticulturae*, vol. 7, p. 239, 2021, doi:10.3390/horticulturae7080239.
- [65] Ahsan, S., Injamum-Ul-Hoque, M., Shaffique, S., Ayoobi, A., Rahman, M. A., Rahman, M. M., y Choi, H. W., “Illuminating *cannabis sativa* l.: The power of light in enhancing *c. sativa* growth and secondary metabolite production”, *Plants*, vol. 13, no. 19, 2024, doi:10.3390/plants13192774.
- [66] Li, C., Adhikari, R., Yao, Y., Miller, A. G., Kalbaugh, K., Li, D., y Nemali, K., “Measuring plant growth characteristics using smartphone based image analysis technique in controlled environment agriculture”, *Computers and Electronics in Agriculture*, vol. 168, p. 105123, 2020, doi:10.1016/j.compag.2019.105123.
- [67] Chen, T. y Yin, H., “Camera-based plant growth monitoring for automated plant cultivation with controlled environment agriculture”, *Smart Agricultural Technology*, vol. 8, p. 100449, 2024, doi:10.1016/j.atech.2024.100449.
- [68] Wen, T., Li, J.-H., Wang, Q., Gao, Y.-Y., Hao, G.-F., y Song, B.-A., “Thermal imaging: The digital eye facilitates high-throughput phenotyping traits of plant

- growth and stress responses”, *Science of the Total Environment*, vol. 899, p. 165626, 2023, doi:10.1016/j.scitotenv.2023.165626.
- [69] Chen, D., High-throughput phenotyping for biomass prediction in barley under controlled conditions. PhD thesis, University of XYZ, 2021.
- [70] Kumar, P., “A cyber-physical system approach for precision agriculture focused on crop growth”, master’s thesis, Arizona State University, 2024.
- [71] Sun, C., “Application of smart sensors to monitor the interactive effects of temperature and lighting on plant growth in a simulated controlled environment facility”, master’s thesis, University of Manitoba, 2024.
- [72] Reyes-Vera, E., Valencia-Arias, A., García-Pineda, V., Aurora-Vigo, E. F., Vásquez, H. A., y Sánchez, G., “Machine learning applications in optical fiber sensing: A research agenda”, 2024, doi:10.3390/s24072200.
- [73] Rojas-Rincón, C., Vélez-Galvis, Y., Botero-Londoño, M., Reyes-Vera, E., y Sepúlveda, A., “Machine learning for the prediction of perovskite solar cell performance: A brief review”, 2025, doi:10.1007/978-3-031-88995-0_2.
- [74] Gibson, A. R., “Growth studies with hemp (*cannabis sativa* l.): a thesis presented in partial fulfilment of the requirements for the degree of master of science in horticultural science at massey university”, Master’s thesis, Massey University, Palmerston North, New Zealand, 2007.
- [75] Sieracka, D., Zaborowicz, M., y Frankowski, J., “Identification of characteristic parameters in seed yielding of selected varieties of industrial hemp (*cannabis sativa* l.) using artificial intelligence methods”, *Agriculture*, vol. 13, no. 5, 2023, doi:10.3390/agriculture13051097.
- [76] Hesami, M. y Jones, A. M. P., “Modeling and optimizing callus growth and development in *cannabis sativa* using random forest and support vector machine in combination with a genetic algorithm”, *Applied Microbiology and Biotechnology*, vol. 105, no. 12, pp. 5201–5212, 2021, doi:10.1007/s00253-021-11375-y.
- [77] Pepe, M., Hesami, M., Small, F., y Jones, A. M. P., “Comparative analysis of machine learning and evolutionary optimization algorithms for precision micropropagation of *Cannabis sativa*: Prediction and validation of *in vitro* shoot growth and development based on the optimization of light and carbohydrate sources”, *Frontiers in Plant Science*, vol. 12, p. 757869, 2021, doi:10.3389/fpls.2021.757869.
- [78] Hopoo Color, “Espectrofotómetro portátil ohsp-350c”. <https://www.hopoo-color.com/es/product/detail/OHSP-350C.html>, 2024. Consultado el 22 de julio de 2025.
- [79] SunPlus LED, “S250 4 bars lm301h 250w horticulture led grow light”, 2025, <https://sunplusled.com/products/s250-4-bars-lm301h-250w-horticulture-led-grow-light>. Ficha técnica de lámpara LED para horticultura con espectro completo. Consultado en julio de 2025.
- [80] Atlas Scientific, “Sma pt-1000 temperature kit”. <https://atlas-scientific.com/kit/s/sma-temperature-kit/>, 2025. Kit includes EZO™ RTD Temperature Circuit, non-isolated carrier board and Class-B platinum PT-1000 probe.
- [81] Dunn, B. y Singh, H., “Electrical conductivity and ph guide for hydroponics”, extension fact sheet hla-6722, Oklahoma State University, Division of Agricultural

Sciences and Natural Resources, 2017.

- [82] Thakulla, D., Dunn, B., Hu, B., Goad, C., y Maness, N., “Nutrient solution temperature affects growth and °brix parameters of seventeen lettuce cultivars grown in an nft hydroponic system”, *Horticulturae*, vol. 7, no. 9, 2021, doi: [10.3390/horticulturae7090321](https://doi.org/10.3390/horticulturae7090321).
- [83] Colombia Breeders, “Ficha técnica de la variedad rosa andina”. <https://www.colombiabreeders.com/fichas/rosa-andina.pdf>, 2023. Consultado: 13 de abril de 2025.
- [84] Cornare, “Evaluación y zonificación de riesgos y dimensionamiento de procesos erosivos en los 26 municipios de la jurisdicción de cornare: Municipio de guarne”, rep. tec., Corporación Autónoma Regional de las Cuencas de los Ríos Negro y Nare (Cornare), Antioquia, Colombia, 2012. Convenio Cornare–Gobernación de Antioquia N° 2011-CF-12-0051 y 217-2011.
- [85] Schimelpfenig, G., Guiterman, T., y Harkiewicz, V., “Make data work for you: Environmental monitoring for optimal outcomes”, *Cannabis Science and Technology*, vol. 4, no. 8, pp. 34–41, 2021.
- [86] Burgner, S., “How poor environmental control creates pest pressure”, *Cannabis Science and Technology*, vol. 5, no. 3, pp. 28–30, 2022.
- [87] Collado, C. E., Hwang, S. J., y Hernández, R., “Supplemental greenhouse lighting increased the water use efficiency, crop growth, and cutting production in *Cannabis sativa*”, *Frontiers in Plant Science*, vol. 15, p. 1371702, 2024, doi:[10.3389/fpls.2024.1371702](https://doi.org/10.3389/fpls.2024.1371702).
- [88] Apogee Instruments, Logan, UT, USA, SQ-500 Series Quantum Sensors: User Manual, 2022. <https://www.apogeeinstruments.com/content/SQ-500.pdf>.
- [89] Mitutoyo Corporation, “Measuring instruments catalog no. e2021”. <https://www2.mitutoyo.co.jp/eng/useful/catalog-2021/html5.html#page=225>, 2021. Catálogo de instrumentos de medición — sección específica en la página 225.
- [90] Fisa Equipos de Medición y Precisión, “Calibrador pie de rey digital 12-500-173-30 - mitutoyo”. <https://www.fisa.com.co/equipos-de-medicion-y-precision/1635-calibrador-pie-de-rey-digital-12-500-173-30-mitutoyo.html>, 2024. Consultado el 22 de julio de 2025.
- [91] Garcia-Neto, M. y Kebreab, E., “Growth curve: An intelligent life history described by a mathematical model using the practical program for forces modeling spreadsheet”. Data Repository, Universidade Estadual Paulista (UNESP), 2021, <http://hdl.handle.net/11449/204625>. Accessed 22 July 2025.
- [92] Demotes-Mainard, S., Peron, T., Corot, A., Bertheloot, J., Le Gourrierc, J., Pelleschi-Travier, S., Crespel, L., Morel, P., Huché-Thélier, L., Boumaza, R., Vian, J.-F., Guérin, V., y Leduc, N., “Plant responses to red and far-red light: a review”, *Plant, Cell Environment*, vol. 39, no. 8, pp. 1799–1818, 2016, doi:[10.1111/pce.12746](https://doi.org/10.1111/pce.12746).
- [93] Smith, H., “Phytochromes and light signal perception by plants—an emerging synthesis”, *Nature Reviews Molecular Cell Biology*, vol. 19, pp. 713–730, 2018, doi:[10.1038/s41580-018-0049-7](https://doi.org/10.1038/s41580-018-0049-7).
- [94] Azeem, M. A. y Dev, S., “A performance and interpretability assessment of machine learning models for rainfall prediction in the republic of ireland”, *Decision Analytics*

