

SURAT KETERANGAN PENGECEKAN SIMILARITY

Saya yang bertanda tangan di bawah ini

Nama : Yurni Oktarina
Nim : 03013622227005
Prodi : Doktor Ilmu Teknik

Menyatakan bahwa benar hasil pengecekan similarity Disertasi yang berjudul “Sistem Kendali Iklim Mikro Pada *Greenhouse* Tenaga Surya Melalui Pendekatan *Neural Network* dan *Iot Monitoring* dalam Skema *Agrivoltaic*” adalah 19 %.

Dicek oleh operator *1 Dosen Pembimbing

2. UPT Perpustakaan

Demikianlah surat keterangan ini saya buat dengan sebenarnya dan dapat saya pertanggung jawabkan.

Menyetujui
Dosen pembimbing,

Dr. Ir. Bhakti Yudho Suprpto, M.T.,IPM
NIP: 197502112003121002

Palembang, 4 November 2024
Yang menyatakan,

Yurni Oktarina
NIM: 03013622227005

***Lingkari salah satu jawaban, tempat anda melakukan pengecekan Similarity**

laporan disertasi REVISI 4 turnitin.pdf

by Ida_pubaa@yahoo.com 1

Submission date: 03-Nov-2024 06:11AM (UTC-0500)

Submission ID: 2492144260

File name: laporan_disertasi_REVISI_4_turnitin.pdf (3.71M)

Word count: 28966

Character count: 183207

1.1 Latar Belakang Masalah

Sebagai negara agraris, sebagian besar wilayah Indonesia merupakan lahan pertanian yang menjadi salah satu sumber penghasilan bagi masyarakat Indonesia, maka tidak berlebihan jika sektor pertanian menjadi sektor yang strategis di Indonesia karena peranannya yang penting dalam sistem ketahanan pangan negara.

Indonesia memiliki jumlah penduduk yang besar, menurut Hasil Sensus Penduduk (SP2020) pada September 2020 mencatat jumlah penduduk Indonesia sebesar 270,20 juta jiwa bertambah 32,56 juta jiwa dibandingkan hasil SP2010. Dengan luas daratan Indonesia sebesar 1,9 juta km², maka kepadatan penduduk Indonesia sebanyak 141 jiwa per km². Laju pertumbuhan penduduk per tahun selama 2010-2020 rata-rata sebesar 1,25 persen.[1]

Seiring dengan peningkatan populasi di Indonesia kebutuhan pangan pun terus meningkat, hal ini harus sejalan dengan meningkatnya jumlah produksi pertanian. Kondisi ini menghadapi sejumlah tantangan, yaitu berkurangnya sumber daya lahan sebanyak 0,49% (hampir mencapai 500 Ha pertahun : BPS, 2021) akibat alih fungsi lahan menjadi permukiman, fasilitas umum dan industri yang terus berkembang selain itu berkurangnya tenaga kerja petani usia produktif dan sistem pertanian di Indonesia yang sebagian besar masih mengandalkan pertanian manual.[2]–[4].

Masalah perubahan iklim pun menjadi tantangan tersendiri bagi petani dalam menentukan jadwal tanam mereka. Perubahan iklim yang dinamis mengakibatkan adanya varietas iklim di berbagai daerah di Indonesia dimana terdapat kondisi daerah yang kekeringan namun sebaliknya terjadi banjir di daerah lainnya. Untuk mengatasi tantangan ini, pertanian harus mengadopsi teknologi “pintar” yang mengoptimalkan penggunaan sumber daya dan memenuhi kebutuhan konsumsi yang meningkat.

Pertanian perkotaan dilakukan untuk meningkatkan pendapatan atau aktivitas memproduksi bahan pangan untuk dikonsumsi. *Greenhouse* merupakan salah satu metode bagi pertanian perkotaan untuk dapat memberikan hasil yang lebih optimal, karena dengan adanya *greenhouse* dapat meningkatkan perlindungan tanaman terhadap serangan hama, suhu lingkungan, intensitas hujan, dan sinar matahari yang merupakan variabel iklim mikro. Lebih lanjut dapat pula mengoptimalkan pemeliharaan tanaman,

pemupukan yang sesuai syarat pertumbuhan tanaman dan irigasi mikro, sehingga mampu meningkatkan produksi yang lebih berkualitas tanpa tergantung dengan perubahan musim.[5][6].

Salah satu tanaman komoditas hortikultura yang diharapkan dapat tumbuh sepanjang musim adalah cabai. Cabai dengan nama latin *Capsicum frutescens L* adalah salah satu komoditas pertanian yang menarik perhatian banyak orang. Permintaan dan ketersediaan cabai di Indonesia cenderung meningkat setiap tahunnya seiring dengan pertumbuhan populasi dan industri pengolahan cabai (Kementerian Pertanian, 2017). Secara keseluruhan, dari data Badan Pusat Statistik (BPS) menunjukkan bahwa konsumsi cabai pada tahun 2013 mencapai lebih dari 300 ribu ton per tahun dan meningkat 18,21 ribu ton per tahun pada tahun 2014.[7] Sementara itu konsumsi cabai per orang di Indonesia pada tahun 2003 adalah 1,35 kg pada tahun 2007 adalah 1,47 kg dan menjadi 4 kg/tahun.[8]

Prospek cabai cukup menjanjikan untuk pemenuhan konsumen domestik dan permintaan ekspor. Pada tahun 2017-2021, permintaan cabai diproyeksikan mengalami peningkatan sebesar 2,65% tiap tahunnya meliputi kebutuhan bibit, konsumsi, serta bahan baku industri. Sebaliknya, proyeksi produksi cabai diperkirakan mengalami penurunan 0,4% per tahun selama 2017-2021.

Penurunan produksi cabai dipengaruhi oleh penurunan luas lahan yang ditanami. Faktor iklim juga memainkan peran penting dalam produksi cabai. Pada musim hujan, bunga-bunga cabai akan berguguran dan produksi cabai cenderung menurun, sehingga pasokannya menjadi langka.[9]

Selain itu, serangan hama, suhu lingkungan, angin dan humiditas tanah adalah contoh-contoh lain faktor-faktor penghambat eksternal dalam pertanian di lahan terbuka karena dapat menyebabkan terganggunya pertumbuhan tanaman dan juga menyebabkan terjadinya penurunan produktivitas pertanian. Untuk mengurangi pengaruh negatif dari faktor iklim, budidaya cabai dapat dilakukan dengan teknik khusus seperti penggunaan *greenhouse*.

Budidaya tanaman dalam *greenhouse* merupakan alternatif solusi yang baik untuk mengontrol/mengendalikan kendala-kendala tersebut. Pengamatan dan pengendalian iklim mikro dalam suatu *greenhouse* sangat penting dilakukan menggunakan aplikasi teknologi atau digital farming.[10]–[19].

Pertanian pintar, atau dikenal juga sebagai pertanian digital, menerapkan otomatisasi dengan campur tangan manusia yang minimal melalui penggunaan komponen elektronik seperti pengendali, sensor dan aktuator. Pengendalian berperan sebagai otak utama sistem yang memproses masukan dari sensor. Liao et al. (2017) dan Kumar et al. (2022) telah membuktikan efektivitas pertanian pintar di rumah kaca untuk menciptakan lingkungan ideal bagi tanaman [1]-[6]. Sensor pintar ini mengumpulkan data-data penting untuk memantau tanaman dan beradaptasi dengan perubahan lingkungan, meningkatkan pengelolaan tanaman dan ternak. Sensor pintar yang didukung oleh IoT memungkinkan pemantauan jarak jauh tanpa kehadiran petani[6]-[10].

Berbagai teknologi yang dapat diaplikasikan pada bidang pertanian memungkinkan terwujudnya pertanian pintar (*smart farming*) dimana petani dapat mengendalikan pemeliharaan tanaman secara otomatis dari jarak jauh melalui teknologi *IoT monitoring*. Data-data realtime yang tepat dari pengamatan dan pengendalian iklim mikro ini dibutuhkan untuk menghasilkan keputusan yang tepat bagi tindakan aktuator selanjutnya karena teknologi *IoT monitoring* ini tidak hanya sebagai pemantau, tapi juga sebagai switch otomatis[20-24].

Aktuator berperan penting dalam pertanian pintar dengan mengotomatisasi tugas-tugas seperti penyiraman melalui pompa atau melaksanakan aktivitas kompleks seperti pemanenan dengan robot [12]-[18]. Sistem otonom ini dapat menangani setiap tahap pertanian, mulai dari penanaman hingga proses pasca-panen.

Greenhouse merupakan salah satu metode untuk menggabungkan teknologi dalam pertanian ini yang dapat disesuaikan dengan kebutuhan tanaman dan bebas hama. Teknologi ini dapat digunakan sebagai pengganti pertanian yang dikondisikan untuk meningkatkan hasil pertanian. Pengaturan otomatis yang membutuhkan pemantauan/monitoring terintegrasi diperlukan untuk memastikan bahwa kondisi di dalam *greenhouse* sesuai dan ideal untuk tanaman. Teknologi pertanian digital dapat memastikan hasil panen tetap tinggi bahkan dalam kondisi cuaca yang tidak menguntungkan[11]. Namun, sistem ini bergantung pada pasokan daya yang andal, yang menjadi masalah di daerah seperti Sumatera Selatan, di mana konektivitas energi tidak konsisten. Tantangan ini dapat diatasi dengan menggantikan listrik konvensional dengan sistem fotovoltaik (PV). Ketersediaan energi surya yang melimpah di Sumatera Selatan memastikan keberlanjutan pertanian pintar di Palembang [19]-[25].

Smart farming memerlukan pasokan energi listrik yang terus-menerus dan hal ini menjadi dilema untuk petani yang berada di lokasi yang belum terjangkau listrik PLN atau daerah dengan pasokan listrik yang tidak stabil. Masalah ini dapat diatasi dengan aplikasi listrik energi surya untuk pertanian. Indonesia, Sumatera Selatan pada umumnya memiliki potensi energi surya yang besar dan belum dimanfaatkan maksimal. Pemasangan Pembangkit Listrik Tenaga Surya (PLTS) skala perumahan dapat dilakukan berdampingan dengan pengaturan tanaman sehingga PLTS tidak mengorbankan lahan subur yang justru sangat penting bagi pertanian.

Konsep pemanfaatan energi surya yang berdampingan dengan pertanian disebut dengan *Agri-voltaic*. Agri dari kata *agriculture* dan *voltaic* dari kata *photovoltaic*. Efek PV (*Photovoltaic*) adalah pembangkitan energi listrik secara langsung dengan mengubah energi foton yang dibawa irradiance matahari menjadi energi listrik [25][26]. Indonesia memiliki potensi besar akan pembangkitan energi listrik tenaga surya [27-30].

Berbagai alternatif pemasangan PV panel pada lahan pertanian, diantaranya pemasangan PV panel di atas tanaman sehingga tanaman mendapat naungan dari PV panel dan area dibawah PV panel akan lebih sejuk dan menghindarkan panel dari kemungkinan *overheated* atau panas berlebih.

Studi ini mengeksplorasi pemasangan sistem pertanian pintar berbasis tenaga surya di Palembang, Sumatera Selatan. Mengingat melimpahnya energi surya di wilayah tersebut, sistem PV menawarkan solusi berkelanjutan untuk mendukung pertanian digital. Studi ini meninjau berbagai sensor, aktuator, dan contoh-contoh pertanian otomatis yang diimplementasikan secara lokal dan global, dengan menekankan potensi energi surya untuk mendukung pertanian pintar di Palembang.

Penelitian ini bertujuan untuk menyelaraskan teknologi *smart farming* dan pengembangan energi terbarukan melalui implementasi energi surya menuju *green economy* di sektor pertanian khususnya dalam pengendalian iklim mikro secara kontinyu dalam *greenhouse* dengan metode neural network memungkinkan petani untuk memantau kondisi *greenhouse* secara jarak jauh.

1.2 Novelty dan Kontribusi Penelitian

Penelitian ini menawarkan kebaruan melalui integrasi teknologi modern dalam skema sistem agri-voltaik yang memanfaatkan energi surya untuk mendukung pengelolaan pertanian di daerah tropis. Sistem agri-voltaik yang digunakan dalam

penelitian ini tidak hanya menyediakan energi bagi *greenhouse*, tetapi juga menciptakan lingkungan yang lebih optimal bagi pertumbuhan tanaman dengan memanfaatkan panel surya untuk mengatur intensitas cahaya yang masuk ke dalam *greenhouse*. Pendekatan ini memungkinkan terciptanya lingkungan yang lebih stabil dan efisien bagi pertumbuhan tanaman cabai, yang sering terpengaruh oleh fluktuasi cuaca di wilayah tropis.

Untuk memastikan lingkungan yang ideal dalam *greenhouse*, penelitian ini membahas pemodelan dan desain sistem kendali otomatis untuk mengatur iklim mikro dalam skema agrivoltaik, yang mencakup suhu, kelembapan, dan radiasi matahari. Pendekatan ini menggunakan Neural Network (NN) sebagai inti dari model pengendalian, yang memungkinkan deteksi dan penyesuaian kondisi iklim mikro secara real-time berdasarkan input dari berbagai sensor. IoT monitoring digunakan untuk mengumpulkan data lingkungan secara berkelanjutan, memungkinkan petani mengawasi status *greenhouse* tanpa harus selalu berada di lokasi. Pemantauan ini, yang juga mencakup kinerja pasokan energi surya, memberikan kendali yang lebih presisi dan responsif terhadap perubahan kondisi di dalam *greenhouse*. Penerapan IoT monitoring sebagai bagian dari pengelolaan iklim mikro di rumah kaca adalah aspek baru dalam penelitian ini, menggabungkan teknologi otomatisasi dengan efisiensi penggunaan energi terbarukan.

Lebih jauh lagi, penelitian ini mengkaji prediksi pertumbuhan dan hasil panen tanaman cabai dengan menggunakan pendekatan Convolutional Neural Network (CNN) melalui model transfer learning. Model EfficientNetV2L, EfficientNetV2M, dan ResNet50 yang dilatih menggunakan dataset besar seperti ImageNet, kemudian disesuaikan dengan data spesifik cabai dari lapangan, memungkinkan model untuk menghasilkan prediksi yang lebih akurat mengenai jumlah cabai pada berbagai tahap pertumbuhan. Hasil prediksi ini membantu memperkirakan waktu panen yang tepat dan mengoptimalkan penggunaan sumber daya seperti air dan nutrisi untuk menghasilkan hasil panen yang maksimal.

Dengan integrasi NN untuk pengendalian iklim mikro dan CNN untuk prediksi hasil panen, penelitian ini diharapkan mampu memberikan solusi praktis dalam pengelolaan *greenhouse* tenaga surya, sehingga menciptakan sistem pertanian yang lebih adaptif, presisi, dan berkelanjutan. Prediksi yang akurat mengenai kondisi iklim mikro dan jumlah hasil panen cabai memungkinkan petani untuk melakukan pengambilan

keputusan yang lebih tepat dan efektif. Model ini tidak hanya mendukung keberlangsungan hidup tanaman, tetapi juga memastikan bahwa tanaman mendapatkan perlakuan yang optimal sesuai dengan parameter yang telah terdefiniskan.

Penelitian ini berpotensi untuk menjadi referensi dalam pengembangan e-Smart Farming, di mana integrasi IoT, AI, dan energi terbarukan dapat menciptakan sistem pertanian modern yang efisien. Dengan keberhasilan dalam mengendalikan iklim mikro dan prediksi hasil panen secara otomatis, penelitian ini menawarkan peluang untuk mengembangkan strategi pengelolaan pertanian yang lebih baik di daerah-daerah dengan potensi energi surya tinggi, seperti Indonesia.

1.3 Rumusan Masalah

Dalam pengelolaan *greenhouse* dengan skema agrivoltaik, terdapat beberapa tantangan utama yang perlu diatasi untuk mencapai efisiensi sistem dan optimalisasi produksi tanaman, yaitu:

- a. Bagaimana mengimplementasikan sistem kendali iklim mikro di dalam *greenhouse* berdasarkan data variabel-variabel lingkungan cuaca dan kondisi yang ada?
- b. Bagaimana pendekatan Long Short-Term Memory Artificial Neural Network (LSTM-ANN) dapat digunakan untuk memprediksi output dari Pembangkit Listrik Tenaga Surya (PLTS) secara akurat dalam kondisi variabel cuaca yang dinamis?
- c. Bagaimana memanfaatkan model Convolutional Neural Network (CNN) dengan transfer learning untuk memprediksi hasil panen dan pertumbuhan tanaman berdasarkan data visual?
- d. Bagaimana mengintegrasikan sistem IoT untuk pemantauan jarak jauh dalam rangka meningkatkan efisiensi pengelolaan *greenhouse* tenaga surya dalam skema agrivoltaic?

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah :

- a. Mengimplementasikan sistem kendali iklim mikro yang dapat mengatur suhu, kelembapan udara dalam *greenhouse*
- b. Mengembangkan model prediksi *output* pv dengan pendekatan LSTM-ANN untuk memprediksi pasokan energi secara akurat
- c. Memprediksi pertumbuhan dan hasil panen tanaman cabai berdasarkan data visual yang dikumpulkan secara periodik

- d. Memantau iklim mikro *pada greenhouse* secara jarak jauh teknologi *IoT* menggunakan *IoT software platform*

1.5 ⁷⁴ Pembatasan Masalah

Dalam penelitian ini, terdapat beberapa pembatasan yang ditetapkan untuk memperjelas cakupan dan fokus dari penelitian yang dilakukan, yaitu:

- a. Skema Agrivoltaic

Penelitian ini hanya mencakup pengaturan konfigurasi solar panel dan tata letak greenhouse untuk memaksimalkan penyerapan cahaya pada panel surya dan mengurangi pengaruh bayangan pada tanaman. Pembahasan tentang optimalisasi struktur mekanis atau desain panel surya tidak termasuk dalam penelitian ini.

- b. Cakupan Kendali Iklim Mikro

Sistem kendali iklim mikro dalam greenhouse yang dikembangkan hanya difokuskan pada pengaturan suhu, kelembaban udara, dan kelembaban tanah dalam greenhouse.

Variabel lain seperti konsentrasi karbon dioksida dan pencahayaan buatan tidak termasuk dalam pengendalian yang diimplementasikan pada penelitian ini.

- c. Prediksi Output PLTS Menggunakan Model Hybrid LSTM-ANN

Model prediksi output PLTS yang dibangun menggunakan pendekatan LSTM-ANN hanya memanfaatkan data historis seperti intensitas radiasi matahari, suhu lingkungan, dan kondisi cuaca harian.

Variabel lain yang dapat mempengaruhi output seperti efisiensi panel surya dan degradasi modul tidak dibahas secara mendalam.

- d. Model CNN untuk ⁵⁶ Prediksi Hasil Panen

Pendekatan CNN yang digunakan dalam penelitian ini untuk prediksi hasil panen dan pertumbuhan tanaman hanya difokuskan pada analisis citra visual tanaman yang diambil secara berkala menggunakan kamera IoT.

Data tambahan seperti pengukuran manual atau citra hiperspektral tidak termasuk dalam cakupan penelitian.

- e. IoT Monitoring

Sistem IoT yang digunakan untuk pemantauan mencakup sensor-sensor untuk pengukuran suhu, kelembaban udara, kelembaban tanah, serta perangkat kamera untuk pengambilan citra tanaman.

f. Lokasi dan Kondisi Uji Coba

Pengujian dan pengumpulan data dilakukan di Talang Kemang Kelurahan Gandus Kecamatan Gandus Palembang dengan kondisi cuaca dan iklim yang cukup spesifik. Variasi iklim di luar lokasi penelitian tidak menjadi bagian dari penelitian ini.

1.6 Metodologi Penelitian

Penelitian ini menggunakan metode penelitian deskriptif dengan teknik pengumpulan data memanfaatkan data-data primer melalui data awal di lapangan dan sekunder berupa kajian pustaka. Analisis data menggunakan *content analysis*, yakni menelaah secara kritis terhadap data-data yang diperoleh dan menyimpulkan serta memberi rekomendasi atau saran-saran yang diperlukan, dengan tahapan pengolahan data yaitu :

- (1) Pemodelan teori atau matematis
- (2) Simulasi, untuk mengukur kinerja besaran variabel-variabel yang digunakan
- (3) Eksperimen lapangan dan online

1.7 Sistematika Penulisan Disertasi

Laporan disertasi yang dibuat ini terdiri dari 7 bab, yaitu Bab 1 menjelaskan pendahuluan dari penelitian. Bab 2 membahas *state of the art*, teori mendasar tentang *smart farming* yaitu tentang *agrivoltaic*, *PV system*, *monitoring* dan kendali kecerdasan buatan iklim mikro *greenhouse* dan analisa *PV system*. Bab 3 menjelaskan metodologi penelitian. Bab 4 membahas kontrol iklim mikro *greenhouse* dalam skema *agrivoltaic*. Bab 5 membahas prediksi energi surya dengan pendekatan LSTM-ANN. Bab 6 prediksi pertumbuhan dan hasil panen cabai dengan *transfer learning cnn*. Bab 7 berisi kesimpulan dan saran.

2.1 *State of The Art* Penelitian

Dalam *state of the art*, peneliti menyajikan beberapa penelitian yang relevan untuk menganalisis dan memperkaya pembahasan penelitian yang sedang dilakukan, serta mengidentifikasi perbedaan dengan penelitian sebelumnya.

Penelitian ini merujuk kepada banyak jurnal-jurnal terdahulu yang berkaitan dengan penggunaan metode *neural network*, *IoT monitoring*, pertanian yang terintegrasi dengan panel surya sebagai sumber energi, dan pengendalian iklim mikro dalam *greenhouse*.

Pertanian Indonesia sangat bergantung pada cuaca; perubahan musim yang tidak dapat diprediksi akan sulit untuk menentukan jenis tanaman yang akan diproduksi. Jika musim hujan terlalu lama akan menyebabkan banyak penyakit, seperti pembusukan akar, dan jika musim kering akan menyebabkan kekurangan air untuk tanaman, hama juga akan menyerang, yang dapat menyebabkan kerugian. Dengan cara yang sama, ketika suatu komoditas sulit ditemukan, harganya menjadi sangat tinggi, tetapi ketika ada banyak produk, harganya turun, sehingga ada kerugian. Untuk mencapai tujuan ini, pengendalian iklim mikro harus dilakukan agar tidak bergantung pada lingkungan luar. Akibatnya, produksi dapat dijadwalkan secara mandiri dan berkelanjutan. Untuk menghindari *loss* komoditas yang dibutuhkan konsumen, petani tidak perlu membanjiri pasar dengan produk yang sama yang menyebabkan harga anjlok.

Implementasi *digital farming* diharapkan mampu meningkatkan produksi pertanian dan mengurangi beban petani. Kontribusi teknologi dalam bentuk otomasi pertanian saat ini mungkin diwujudkan mengingat harga komponen elektronika terjangkau dan mudah didapat melalui layanan online market. Otomatisasi pertanian diharapkan mampu mengurangi masalah penurunan kinerja sektor pertanian yang dibahas oleh Winoto dkk(2008). Shang dkk(2021) membahas adopsi dan difusi teknologi pertanian untuk meningkatkan kinerja pertanian[2]. *Digital farming* dapat berupa terapan teknologi tepat guna seperti yang disajikan oleh Putra dkk(2021) atau dalam bentuk robotika yang dikemukakan pada[8-15]

Tabel 1 State of The Art Penelitian

A. Iklim Mikro Dalam Greenhouse

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Ding et al., 2018	Automatic carbon dioxide enrichment strategies in the greenhouse: A review	Tentang peningkatan CO2 di rumah kaca, menggambarkan perkembangan terbaru dalam teknologi peningkatan CO2 otomatis di rumah kaca.	<ol style="list-style-type: none"> 1. Membahas berbagai sumber peningkatan CO2 di rumah kaca. 2. Menangani pemantauan konsentrasi CO2 dan pemrosesan data sensor asli. 3. Membahas berbagai metode pengendalian CO2 di rumah kaca, yang terutama melibatkan pengendalian klasik, pengendalian modern, pengendalian cerdas, dan pengendalian <i>hybrid</i>. 4. Membahas tantangan dan perspektif baru serta mencakup perkembangan terbaru dalam pemerdayaan CO2 otomatis dan bentuk baru budidaya di rumah kaca. 	<p>Review pada pengelolaan rumah kaca otomatis menunjukkan bahwa penggunaan gas buang dari pembakaran bahan bakar fosil atau energi terbarukan dapat dimanfaatkan sebagai sumber CO2, yang sebaiknya dikombinasikan dengan penyimpanan panas untuk manfaat ekonomi dan lingkungan yang optimal. Pengembangan Jaringan Sensor Nirkabel (WSN) telah meningkatkan kontrol otomatis dan optimal CO2, dengan sensor yang lebih akurat dan murah berpotensi meningkatkan otomatisasi. Di bawah kondisi iklim yang tidak menguntungkan, algoritme cerdas dapat menyeimbangkan biaya generator CO2 dan produksi rumah kaca. Teknologi visi mesin dan Dinamika Fluida Komputasi (CFD) juga berperan dalam menganalisis pertumbuhan tanaman dan distribusi konsentrasi CO2, yang esensial untuk mencapai kultivasi rumah kaca presisi dan rumah kaca simbiotik dengan kontrol CO2 yang tepat, menawarkan signifikansi ekonomi dan lingkungan yang besar.</p>

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Kumar et al, 2022	IoT enabled system to monitor and control greenhouse	Sebuah sistem dikembangkan untuk memantau tanaman di rumah kaca menggunakan energi solar.	Arduino dirancang untuk memantau suhu tanah, kelembapan, dan cahaya untuk mengontrol pompa air, kipas, sprinkler, dan lampu.	Sensor Kelembapan Tanah mendeteksi tingkat kelembapan tanah secara real-time dan mengirimkan sinyal ke Arduino yang kemudian mengontrol motor berdasarkan kebutuhan—menyalakan jika diperlukan dan mematikannya jika tidak. Sistem ini juga menggunakan sensor suhu dan kelembapan untuk mengatur operasi kipas, dengan semua pembacaan dari sensor suhu, kelembapan, dan intensitas cahaya ditampilkan di layar LCD. Secara keseluruhan, sistem berfungsi dengan sukses dalam mengelola kondisi berdasarkan data yang diperoleh dari berbagai sensor.
Alkhalaf et al, 2017	An IoT-based greenhouse monitoring system with MicaZ motes	1. Kebutuhan untuk melacak parameter iklim lokal di berbagai bagian rumah kaca berskala besar guna memastikan operasi yang tepat dari sistem otomatisasi rumah kaca. 2. Pemasangan kabel akan	1. Prototipe WSN yang terdiri dari node MicaZ yang digunakan untuk mengukur suhu, cahaya, tekanan, dan kelembapan di rumah kaca. 2. Data diambil hanya dalam satu hari dan pada hari kedua pintu rumah kaca dibuka, yang mengakibatkan beberapa perubahan cepat dalam nilai yang tercatat.	WSN memungkinkan pemantauan iklim rumah kaca, mengumpulkan data rinci dan menyimpannya untuk analisis yang mendalam, membantu petani memahami dan memperbaiki proses pertanian. Sistem ini juga memungkinkan petani untuk mengontrol rumah kaca dari ponsel atau komputer yang terhubung ke internet.

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Liao et al. 2017	On precisely relating the growth of Phalaenopsis leaves to greenhouse environment factors by using an IoT-based monitoring system	membuat sistem pengukuran menjadi mahal, rentan, dan juga sulit untuk dipindahkan setelah terpasang. Metode tradisional untuk memantau faktor lingkungan di rumah kaca dan pertumbuhan angrek Phalaenopsis sering kali mengalami resolusi spasi dan waktu yang rendah, intensitas kerja yang tinggi, memerlukan banyak waktu, serta kurangnya otomatisasi dan sinkronisasi.	<ol style="list-style-type: none"> Seluruh sistem terdiri dari sistem pemantauan lingkungan berbasis IoT dan platform pencitraan nirkabel berbasis IoT. Sebuah algoritma pemrosesan citra yang berdasarkan metode deteksi tepi Canny, metode pertumbuhan wilayah berbiji (SRG), dan morfologi matematis juga dikembangkan untuk memperkirakan luas daun Phalaenopsis. Sebuah algoritma pemrosesan citra yang deteksi tepi Canny, metode pertumbuhan wilayah berbiji (SRG), dan morfologi matematis juga 	<ol style="list-style-type: none"> The experimental results indicate that the daily average growth rate of the leaf area of Phalaenopsis is approximately 79.41 mm²/day when the temperature and relative humidity in the greenhouse are controlled at 28.83 ± 2.58 (°C) and 71.81 ± 8.88 (%RH), respectively. The proposed system shows a great potential to provide quantitative information with high spatiotemporal resolution to floral farmers. It is promisingly expected that the proposed system will effectively contribute to updating farming strategies for Phalaenopsis in the future.

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Hernández-Morales et al., 2022	Design and deployment of a practical IoT-based monitoring system for protected cultivations,	<ol style="list-style-type: none"> 1. Pertumbuhan populasi yang pesat menimbulkan tuntutan yang berat dalam produksi pangan untuk memenuhi permintaan. 2. Selain itu, peningkatan 	<p>dikembangkan untuk memperkirakan luas daun Phalaenopsis.</p> <ol style="list-style-type: none"> 4. Eksperimen jangka panjang terkait dengan empat kondisi lingkungan yang berbeda untuk budidaya Phalaenopsis sedang dilakukan. 5. Metode analisis statistik, termasuk ANOVA satu arah, ANOVA dua arah, dan uji Games-Howell, dilakukan untuk mengkaji hubungan antara pertumbuhan daun Phalaenopsis dan faktor-faktor lingkungan di rumah kaca. 	<ol style="list-style-type: none"> 1. Selama lebih dari 6 bulan, sistem IoT telah divalidasi secara eksperimental dengan memantau suhu dan kelembapan di rumah kaca tanaman tomat di Meksiko. 2. Persentase ketersediaan sistem selama periode ini adalah 92%, di mana 8% yang hilang disebabkan oleh kesalahan manusia. 3. Strategi penerapan sensor yang praktis yang memberikan kompromi efisien

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Chang et al. 2021	Artificial intelligence	1. Model pertumbuhan	1. Mengintegrasikan FL, NN, dan NF untuk mengekstrak	(1) Hasilnya menunjukkan bahwa FLs, NN, dan NFs semuanya memiliki
		suhu dan perubahan iklim juga berdampak negatif pada pasokan makanan.	dengan biaya penerapan dan pengelolaan yang rendah. 2. Pelatihan dan pengujian ANN dengan 3 lapisan dan 8 neuron untuk setiap lapisan.	antara biaya dan akurasi. (maximum actions of <i>greenhouse</i> workers). 4. Cakupan spasial sebesar 94% dapat dicapai hanya dengan 5 perangkat IoT untuk sebuah rumah kaca seluas dua hektar. 5. Makalah ini menerapkan pemodelan prediksi berbasis data untuk mikroklimat di dalam rumah kaca menggunakan jaringan saraf buatan. Hasil ini menunjukkan bahwa model ANN dapat digunakan dengan sukses untuk membuat perkiraan suhu selama periode 24 jam dengan ANN tiga layer sederhana yang memiliki 8 neuron di lapisan tersembunyi. 6. Metode yang diusulkan memodelkan nilai masa depan dari suhu internal rumah kaca (dengan nilai MAE kurang dari 1 °C) hanya berdasarkan 8 input sebelumnya dari deret waktu suhu yang sama. Dibandingkan dengan solusi serupa lainnya dalam literatur, kerangka kerja IoT yang diusulkan lebih fleksibel, dan mencakup fitur utama untuk mengoptimalkan produktivitas dan keberlanjutan.

Penulis	Judul	Permasalahan	Metode	Results and Advantages
	18 approaches to predict growth, harvest day, and quality of lettuce (Lactuca sativa L.) in a IoT-enabled greenhouse system	tanaman yang lengkap tidak hanya memprediksi hasil panen tetapi juga mengandung informasi kuantitatif tentang pertumbuhan dan perkembangan tanaman. 2. Faktor fisiologis tanaman, termasuk transpirasi, fotosintesis, dan respirasi, sebagian besar dipengaruhi oleh faktor lingkungan. 3. Karena interaksi kompleks dari mekanisme pertumbuhan tanaman, sulit untuk	parameter pertumbuhan yang terkait dengan selada, dan model prediksi dibangun melalui percobaan eksperimental dan operasi budidaya standar. 2. Memprediksi beberapa parameter fisiologis yang terkait dengan daun 3. Pertumbuhan tanaman selada (<i>Lactuca sativa L.</i>) (jumlah daun, luas kontur daun, dan massa kering), fotosintesis (laju bersih) dan transpirasi untuk memahami waktu panen dan kualitas pertumbuhan selada yang ditanam dalam sistem hidroponik.	kemampuan prediktif yang baik ($R^2=0,82-0,96$). (2) Dalam penelitian ini, hanya FL yang digunakan untuk memprediksi laju transpirasi dan laju fotosintesis bersih daun selada, dan hasilnya menunjukkan bahwa nilai R^2 tertinggi adalah 0,91. (3) 3. Rata-rata RMSE dari Ht dan Qt mencapai sekitar 0,5176 dan 0,034, masing-masing. (4) Nilai R^2 antara Ht dan Qt yang diperkirakan serta hasil eksperimen mencapai 0,9951 (NF #1) dan 0,9844 (NF #2), masing-masing, yang secara kuat menunjukkan adanya hubungan linier antara nilai eksperimen dan nilai yang diperkirakan terkait Ht dan Qt. (5) Namun, terdapat risiko di mana estimasi menjadi semakin buruk akibat akumulasi kesalahan model. Meskipun kesalahan meningkat ketika FL #3 dan NN digunakan selama tahap vegetatif pertumbuhan tanaman, kesalahan ini hanya sedikit mempengaruhi nilai RMSE yang dihasilkan dengan menggunakan NF #1. (6) Hasil prediksi tetap berada dalam rentang ketidaktentuan pengukuran,

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Abioye et al. 2021	IoT-based monitoring and data-driven modelling of drip irrigation system for mustard leaf cultivation experiment	Dinamika yang berubah, non-linearitas kandungan kelembaban tanah, serta variabel cuaca dan tanaman lainnya	Peningkatan pemantauan dan pemodelan berbasis data terhadap dinamika parameter yang mempengaruhi irigasi tanaman daun mustard.	<p>sehingga menunjukkan bahwa dari dataset uji, NFs cocok dengan dinamika pertumbuhan selada dan mencapai estimasi Ht dan Qt yang wajar.</p> <p>(7) Informasi ini dapat membantu para petani membuat keputusan tentang perubahan iklim dan pengelolaan tanaman sebelumnya</p> <ol style="list-style-type: none"> 1. Sebanyak 20.703 sampel data eksperimen dikumpulkan dari platform berbasis IoT yang selanjutnya digunakan untuk pemodelan berbasis data melalui identifikasi sistem di MATLAB. 2. Hasilnya menunjukkan pengembangan berbagai model prediktif untuk prediksi kandungan kelembapan tanah. 3. Model prediksi ARX terbukti memiliki kinerja yang lebih baik dibandingkan dengan model ARMX, BJ, dan ruang negara dalam hal kecocokan estimasi sebesar 91,31%, 91,09%, 91,08%, dan 90,75% secara berturut-turut. 4. Oleh karena itu, sebuah kerangka pemantauan yang kuat untuk sistem irigasi telah dikembangkan, sementara kinerja model ARX yang diidentifikasi menunjukkan hasil yang menjanjikan

Penulis	Judul	Permasalahan	Metode	Results and Advantages
				dalam memprediksi kandungan air tanah secara volumetrik.

B. Prediksi Hasil Panen Berbasis CNN

Penulis	Judul	Permasalahan	Metode	Results and Advantages
Ding et al., 2018	Automatic carbon dioxide enrichment strategies in the greenhouse: A review	Tentang peningkatan CO2 di rumah kaca, mengembangkan teknologi peningkatan CO2 otomatis di rumah kaca.	5. Membahas berbagai sumber peningkatan CO2 di rumah kaca. 6. Menangani pemantauan konsentrasi CO2 dan pemrosesan data sensor asli. 7. Membahas berbagai metode pengendalian CO2 di rumah kaca, yang terutama melibatkan pengendalian klasik, pengendalian modern, pengendalian cerdas, dan pengendalian <i>hybrid</i> . 8. Membahas tantangan dan perspektif baru serta mencakup perkembangan terbaru dalam pemerkayaan CO2 otomatis dan bentuk baru budidaya di rumah kaca.	Review pada pengelolaan rumah kaca otomatis menunjukkan bahwa penggunaan gas buang dari pembakaran bahan bakar fosil atau energi terbarukan dapat dimanfaatkan sebagai sumber CO2, yang sebaiknya dikombinasikan dengan penyimpanan panas untuk manfaat ekonomi dan lingkungan yang optimal. Pengembangan Jaringan Sensor Nirkabel (WSN) telah meningkatkan kontrol otomatis dan optimal CO2, dengan sensor yang lebih akurat dan murah berpotensi meningkatkan otomatisasi. Di bawah kondisi iklim yang tidak menguntungkan, algoritme cerdas dapat menyeimbangkan biaya generator CO2 dan produksi rumah kaca. Teknologi visi mesin dan Dinamika Fluida Komputasi (CFD) juga berperan dalam menganalisis pertumbuhan tanaman dan distribusi konsentrasi CO2, yang esensial untuk mencapai kultivasi rumah kaca presisi dan rumah kaca simbiotik dengan kontrol CO2 yang tepat, menawarkan signifikansi ekonomi dan lingkungan yang besar.
Kumar et al., 2022	IoT enabled system to monitor and	Sebuah sistem dikembangkan untuk memantau	Arduino dirancang untuk memantau suhu tanah, kelembapan, dan cahaya untuk	Sensor Kelembapan Tanah mendeteksi tingkat kelembapan tanah secara real-time dan mengirimkan sinyal ke Arduino yang

Penulis	Judul	Permasalahan	Metode	Results and Advantages
	control <i>greenhouse</i>	tanaman di rumah kaca menggunakan energi solar.	mengontrol pompa air, kipas, sprinkler, dan lampu.	kemudian mengontrol motor berdasarkan kebutuhan—menyalakan jika diperlukan dan mematikannya jika tidak. Sistem ini juga menggunakan sensor suhu dan kelembapan untuk mengatur operasi kipas, dengan semua pembacaan dari sensor suhu, kelembapan, dan intensitas cahaya ditampilkan di layar LCD. Secara keseluruhan, sistem berfungsi dengan sukses dalam mengelola kondisi berdasarkan data yang diperoleh dari berbagai sensor.

Pertanian pintar adalah sistem pertanian otomatis yang mengandalkan teknologi sebagai pekerja utamanya, contohnya sistem penyiraman otomatis akan aktif jika mendapatkan input dari sensor kelembapan yang terpasang ditanah. Aplikasi teknologi yang memungkinkan pertanian pintar otomatis merupakan tujuan utama dari penelitian ini.

Penggabungan pertanian pintar dan pengembangan energi surya disebut dengan *Agrivoltaic*[7-9] *Agrivoltaic* memiliki banyak pilihan aplikasi baik PV panel dipasang diantara tanaman maupun dipasang diatas *greenhouse*. *Smart greenhouse* merupakan bentuk aplikasi teknologi *agrivoltaic* yang menguntungkan petani karena dengan sistem *greenhouse* pertanian tidak tergantung cuaca dan lingkungan, sebagaimana dibahas oleh Achour dkk(2021) tentang implementasi teknologi terbaru pada *greenhouse* modern[19].

Pertanian dengan *agrivoltaic* memungkinkan petani menanam tanaman yang kurang mampu beradaptasi dengan penyinaran berlebihan. Tanaman mendapat naungan dari PV panel yang terpasang diatas tanaman. Kelembapan udara dibawah PV panel juga dapat terjaga sehingga tidak terjadi *overheated* atau panas berlebih yang dapat menurunkan *output* dan efisiensi dari PV panel yang bernilai jual tinggi tanpa terkendala kondisi lingkungan baik dataran rendah maupun dataran tinggi, karena iklim mikro *greenhouse* dapat diatur sehingga produktivitas maksimal.

Pada penelitian ini pertanian pintar *agrivoltaic* akan diatur oleh *IoT monitoring*, dimana jika terjadi perubahan suhu, kelembapan dan lain lain, maka sistem *IoT monitoring* akan otomatis menyesuaikan dan membuat iklim kembali ke kondisi ideal. Oammi dkk(2020) dan Jamil dkk(2022) mengajukan integrasi *IoT monitoring* untuk meningkatkan produksi pertanian[21-22].

Pertanian pintar *Agrivoltaic* dengan *IoT monitoring* memerlukan pasokan listrik yang terjaga, sehingga akan sulit diaplikasikan di daerah yang belum mendapat listrik PLN. Keterbatasan aplikasi ini dapat diatasi dengan pemanfaatan energi surya sebagai suplai daya listrik untuk *Agrivoltaic greenhouse*, sebagaimana disampaikan oleh La Notte dkk(2020) dan Zhang dkk(2022)[20-21].

2.2 *Greenhouse*

Greenhouse merupakan sebuah bangunan yang berkerangka atau dibentuk menggelembung, diselubungi bahan bening atau tembus cahaya yang dapat meneruskan

cahaya secara optimum untuk produksi dan melindungi tanaman dari kondisi iklim yang merugikan bagi pertumbuhan tanaman.

Dalam hal ini, teknologi rumah kaca dapat menjadi satu-satunya pilihan untuk mengendalikan iklim mikro guna memaksimalkan produktivitas tanaman per satuan luas dan meningkatkan produksi tanaman dalam hal kuantitas dan kualitas yang tidak mungkin dilakukan pada kondisi lahan terbuka.

Untuk ini berbagai jenis struktur rumah kaca tersedia untuk produksi tanaman. Karena ada kelebihan dan kekurangan dalam semua jenis struktur rumah kaca untuk aplikasi tertentu, secara umum tidak ada jenis rumah kaca tunggal dianggap sebagai yang terbaik. Oleh karena itu, berbagai jenis desain rumah kaca berdasarkan utilitas, bentuk, material dan konstruksi tersedia untuk memenuhi kebutuhan spesifik. (gambar 1).



Gambar 1 Tipe-Tipe Bangunan Greenhouse

⁴ Budidaya tanaman di dalam *greenhouse* memiliki keunggulan berupa lingkungan mikro yang lebih terkontrol dan keseragaman hasil produksi pada tiap tanaman. Berbeda dengan fungsi *greenhouse* di daerah iklim subtropis yang digunakan untuk mengendalikan lingkungan mikro, keberadaan *greenhouse* di daerah tropis lebih cenderung untuk perlindungan tanaman. *Greenhouse* di daerah tropis digunakan untuk melindungi tanaman dari serangan hama dan menahan air hujan yang jatuh secara langsung ke tanaman sehingga dapat merusak tanaman. Oleh karena itu, rancangan *greenhouse* di daerah tropis lebih sederhana dibanding di daerah subtropis. Suhu di dalam *greenhouse* menjadi lebih tinggi dibanding dengan suhu di luar *greenhouse* disebabkan oleh perubahan radiasi surya yang masuk (bergelombang pendek) yang memanaskan permukaan dalam *greenhouse* dan selanjutnya permukaan dalam *greenhouse* memancarkan kembali dalam bentuk gelombang panjang.

Oleh atap *greenhouse* gelombang panjang ini tidak diteruskan melainkan dipantulkan kembali ke dalam *greenhouse*. Dengan demikian, radiasi gelombang panjang ini makin lama semakin bertambah dan semakin meningkatkan energi dalam *greenhouse* yang diekspresikan dengan meningkatnya suhu di *greenhouse*. Rancangan *greenhouse* berpengaruh besar terhadap lingkungan mikro didalamnya. Salah satu parameter lingkungan mikro tanaman adalah suhu. Suhu yang tinggi dapat mempercepat evapotranspirasi tanaman yang akan mempercepat *loss* air dan energi. Salah satu cara untuk mengendalikan lingkungan mikro tanaman di dalam *greenhouse* khususnya suhu adalah dengan ventilasi alamiah. Keuntungan pemakaian ventilasi alamiah adalah biaya yang relatif murah dan tidak diperlukan perawatan. Kerugian yang perlu diperhatikan pada penggunaan cara ini adalah ketergantungan lingkungan mikro pada alam yang sulit dikendalikan.

Desain dan posisi bukaan ventilasi berperan penting dalam mengatur sirkulasi udara dalam *greenhouse*, yang esensial untuk mengurangi suhu. Konfigurasi dan letak ventilasi berpengaruh terhadap aliran udara, yang digunakan untuk mengeluarkan udara panas dari dalam *greenhouse*. Peningkatan volume udara panas yang dilepaskan dari *greenhouse* akan efektif dalam menurunkan suhu udara. Beberapa kondisi lingkungan berikut dapat dihindari, antara lain:

- a. Variasi suhu dan kelembaban
- b. Efek negatif dari radiasi matahari seperti UV dan IR
- c. Kekurangan air pada musim kemarau dan kelebihan air pada musim penghujan
- d. Hama dan binatang pengganggu serta penyakit tanaman seperti jamur dan bakteri
- e. Tiupan angin kencang yang dapat merusak tanaman dan daun
- f. Tiupan serangga dan angin yang dapat menghentikan penyerbukan bunga
- g. Akibat polusi udara yang buruk

Kondisi lingkungan yang dapat di ciptakan dengan adanya *greenhouse*, antara lain:

- a. Cuaca yang mendukung pertumbuhan tanaman
- b. Suhu, kelembaban, dan intensitas cahaya matahari dapat disesuaikan sesuai kebutuhan
- c. Penyiraman tanaman dapat diatur secara berkala
- d. Kebersihan lingkungan dapat dijaga dengan baik untuk mencegah penyakit tanaman

- e. Kenyamanan terhadap aktivitas produksi dan pengendalian mutu.
- f. Udara bebas polutan

2.3 Tanaman Cabai

Cabai (*Capsicum frutescens* L.) adalah salah satu tanaman hortikultura yang tergolong family Solanaceae yang memiliki nilai ekonomi tinggi. Tanaman ini banyak digemari masyarakat Indonesia, karena dapat dimanfaatkan sebagai bumbu masakan. Kebutuhan cabai di Indonesia saat ini cukup tinggi seiring dengan bertambahnya jumlah penduduk dan berkembangnya kebutuhan cabai untuk memenuhi kebutuhan rumah makan dan industri olahan cabe lainnya.

Dalam budidaya tanaman cabai, unsur hara (nutrisi) di dalam tanah dan kondisi iklim mikro merupakan hal yang sangat berpengaruh. Unsur hara yang tersedia cukup di tanah akan diserap oleh tanaman untuk pertumbuhannya, sedangkan iklim berkaitan dengan faktor di luar tanaman dalam mendukung pertumbuhannya



Gambar 2 Tanaman Cabai

Iklim merupakan salah satu komponen ekosistem yang menjadi salah satu faktor penentu keberhasilan produksi pertanian karena sifatnya yang dinamis dan sulit dikendalikan. Perubahan iklim menjadi permasalahan nyata yang tidak bisa dihindarkan. Menurut Adib (2014) perubahan iklim yang disebabkan meningkatnya suhu dipermukaan bumi terjadi akibat dari kegiatan antropogenik.

¹⁰ Di sejumlah wilayah Indonesia, gejala perubahan iklim semakin dirasakan, terutama musim kemarau dan penghujan. Perubahan iklim yang terjadi dapat berpengaruh terhadap hasil tanaman cabai rawit yang diakibatkan perubahan curah hujan, suhu dan kelembapan. Perubahan tersebut berpengaruh terhadap kualitas dan kuantitas hasil cabai yang ditanam oleh petani.

Tanaman cabe merupakan salah satu tanaman yang cukup ⁹ peka terhadap perubahan lingkungan yang tidak sesuai dengan pertumbuhannya. Jika kondisi lingkungan tidak sesuai akan ditunjukkan dengan ⁹ perubahan fisik dari tanaman cabe seperti daun yang berubah menjadi keriting dan berwarna kekuningan bahkan akan mengalami kebusukan pada akarnya jika terlalu banyak terkena hujan.

⁴¹ Tanaman cabai lebih sesuai jika ditanam dengan intensitas sinar matahari yang cukup, karena selama pertumbuhannya tanaman cabai memerlukan suhu yang rendah hingga hangat (24 - 28 °C), kelembapan lingkungan ± 80 % dan pH pada kisaran 6-7. ⁹ Kualitas penyinaran dengan sinar matahari merupakan faktor utama di dalam pertumbuhan optimal tanaman cabai.

¹⁶ Menurut (Dermawan, 2010), salah satu sifat tanaman cabai yang disukai oleh petani adalah tidak mengenal musim. Artinya, tanaman cabai dapat ditanam kapan pun tanpa tergantung musim, namun penanaman cabai pada musim hujan mengandung resiko. Penyebabnya adalah tanaman cabai tidak tahan terhadap hujan lebat yang terus menerus. Selain itu, genangan air pada daerah penanaman bisa mengakibatkan kerontokan daun dan terserang penyakit akar. Pukulan air hujan juga bisa menyebabkan bunga dan bakal buah berguguran. Maka metode penanaman cabai dalam *greenhouse* merupakan langkah terbaik dalam mengoptimalkan pertumbuhan cabai.

⁹ Pengamatan iklim mikro yang ada di dalam *greenhouse* yaitu kelembapan tanah, kelembapan lingkungan, suhu lingkungan, intensitas matahari, dan suhu tanah harus selalu diperhatikan agar pertumbuhan tanaman dapat dioptimalkan. Informasi iklim mikro ini sangat penting karena terkait langsung dengan tindakan lanjutan, untuk menjamin agar tanaman dapat tetap tumbuh optimal. Kesalahan pengukuran harus dicegah agar tindakan antisipasi untuk melindungi tanaman akibat pengaruh buruk dari luar yang merusak tanaman dapat langsung dilakukan.

Informasi iklim ini kemudian akan dimanfaatkan untuk membuat rancangan aktuator otomatis yang dapat mengerjakan kegiatan perawatan tanaman cabai

menggantikan tenaga manusia untuk menjamin pemeliharaan yang berkelanjutan sesuai dengan sifat pertumbuhan tanaman agar diperoleh hasil yang baik.

2.4 *Agrivoltaic*

⁴⁸ *Agrivoltaics* merupakan konsep menggabungkan penggunaan lahan pertanian dengan produksi energi listrik dari PLTS/solar PV (*agriculture + photovoltaics*). Peningkatan kebutuhan energi dan penurunan stok energi fosil membuat dunia semakin berlomba menggunakan energi terbarukan yang salah satunya adalah energi surya. Pembangunan PLTS mini untuk perorangan maupun bisnis kian hari semakin murah. Namun permasalahan baru muncul, PLTS memerlukan lahan yang luas untuk memasang PV Panel, sedangkan lahan terbatas dan lahan subur akan mubazir jika digunakan hanya sebagai lahan PLTS.

¹¹⁴ Pendekatan untuk menyelesaikan masalah ini adalah dengan menggunakan metode pertanian *Agrivoltaic*, dimana *AGRIculture* berdampingan dengan sistem *photovoltaic*. Pemasangan PV panel pada sistem *agrivoltaic* dapat dilakukan dengan memasang PV panel dengan ketinggian yang pas sehingga bagian bawahnya tetap bisa dimanfaatkan sebagai lahan pertanian, atau dengan memasang PV panel diatas *greenhouse*; untuk pertanian yang menggunakan *greenhouse*. Konsep yang lain adalah dengan memasang solar panel diantara tanaman.

Pada penelitian ini, diambil konsep memasang PV panel pada ketinggian tertentu dan memilih tanaman yang tidak tahan terhadap panas matahari berlebih. Tanaman yang dipilih pada penelitian ini adalah paprika yang bernilai jual tinggi tapi tidak tahan terhadap panas berlebih. Gambar 3 memperlihatkan konsep pertanian *Agrivoltaic* dengan 2 alternatif pemasangan panel, panel berjejer dan slit mounted panel atau pemasangan panel dengan jarak tertentu agar sinar matahari tetap bisa masuk dan menyinari tanaman. Selain sebagai pelindung tanaman, PV panel juga bisa berfungsi sebagai tempat berteduh bagi para ternak yang digembalakan disekitar lahan pertanian sebagaimana diilustrasikan pada gambar 3.



Gambar 3 Konsep Pertanian Agrivoltaik

Penerapan energi surya dalam pertanian dikenal sebagai agrivoltaic [5] [27]-[33], dan salah satu contoh agrivoltaic yang dipantau dan dikendalikan adalah rumah kaca bertenaga surya [1]-[3][6]-[10]. Namun, konsep agrivoltaic perlu diperkenalkan kepada petani seperti yang dilakukan oleh ³¹ Dos Santos et al. pada tahun 2020 [27] bersama EDF (Electricity of France) Renewable Frances dalam mengembangkan dan mempromosikan agrivoltaic untuk petani di Prancis.

Potensi penerapan pertanian bertenaga surya di India telah diselidiki oleh Malu et al. pada tahun 2017 [28] melalui simulasi metode yang diusulkan dalam Model Advisor Sistem (SAM). Simulasi tersebut mencakup pemasangan panel PV yang dipasang tetap di antara tanaman anggur dengan 17 baris dan 32 kolom, menghasilkan daya sebesar 168,64 kW per acre.

Kemajuan dan tantangan dalam produksi tanaman dan pembangkitan listrik pada sistem agrivoltaik menggunakan teknologi fotovoltaik semi-transparan dipresentasikan oleh Gorjian et al. pada tahun 2022 [33]. Penelitian ini membandingkan penerapan teknologi PV dalam agrivoltaik untuk menyelidiki solusi terbaik terhadap dampak bayangan yang disebabkan oleh modul PV pada sistem agrivoltaik terhadap parameter pertumbuhan tanaman (seperti hasil panen, ukuran, berat kering dan segar, warna, tinggi batang, dll.). Penelitian ini memasang panel PV berbasis silikon semi-transparan, film tipis, dan organik. Hasilnya menunjukkan bahwa panel PV berbasis silikon masih lebih hemat biaya dibandingkan teknologi panel PV lainnya. Studi dalam agrivoltaik dan rumah


kaca bertenaga surya menunjukkan bahwa ketika dikombinasikan dengan teknologi IoT dan pengendali berbasis AI, agrivoltaik akan memberikan hasil terbaik [34].

2.5 Pembangkit Listrik Tenaga Surya (PLTS)

PLTS dapat dimanfaatkan oleh masyarakat perorangan seperti petani untuk mengatasi kekurangan pasokan listrik. Pembangkitan listrik secara langsung menggunakan efek fotovoltaik dimana energi foton dari matahari mengeksitasi elektron-elektron pada bahan semikonduktor dan pergerakan elektron tersebut membawa muatan listrik. Arus listrik yang dihasilkan oleh teknologi fotovoltaik/pv adalah arus listrik searah (DC) sehingga digunakan inverter untuk mengkonversi arus listrik searah (DC) ini menjadi arus listrik bolak-balik (AC). PLTS memiliki 2 jenis aplikasi, off-grid atau standalone dan on-grid. PV System off-grid adalah PLTS yang berdiri sendiri tanpa terhubung ke PLN atau sumber listrik jala-jala.

2.6 Analisa Matematis PV System

Analisa matematis dari PV system dengan memodelkan solar cell sebagai dioda ideal seperti yang diperlihatkan pada gambar 4. PV panel jumlahnya sesuai dengan kapasitas maksimum panel, contohnya PV panel dengan kapasitas 300 Wp terdiri dari 72 solar cell.



Gambar 4 Pemodelan Solar Cell Sebagai Dioda Ideal

Dari pemodelan solar cell sebagai dioda ideal pada gambar 4 diperoleh persamaan arus yang akan diproduksi oleh solar cell tersebut, yaitu:

$$\nabla \cdot u = 0 \quad (1)$$

$$I = I_{PH} - I_0 \left(e^{\frac{V+IR_s}{nKT}} - 1 \right) - \frac{V+IR_s}{R_p}, \quad (2)$$

$$I_{PH} = \frac{G}{G_{STC}} I_{sc} + K_i(T - T_{STC}) \quad (3)$$

dimana I_{PH} adalah arus yang dibangkitkan oleh solar cell (A), I_{sc} adalah arus short-circuit (A), V adalah tegangan (Volt), R_{sh} adalah rugi-rugi shunt (Ω), R_s adalah nilai rugi-rugi power (Ω), K_i adalah temperature solar panel, G jumlah irradiance matahari yang diterima oleh solar cell (KW/m^2), T adalah temperatur lingkungan ($^{\circ}K$), STC singkatan dari *standard operating condition*.

Tegangan open-circuit yang dibangkitkan oleh solar cell dapat dituliskan sebagai berikut:

$$\nabla \cdot u = 0 \quad (4)$$

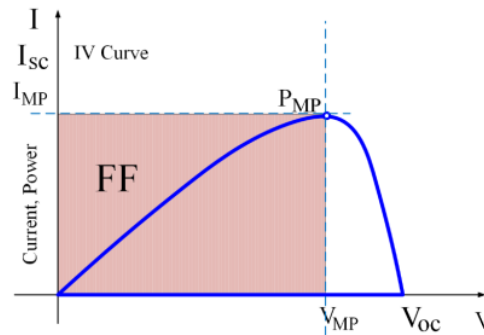
$$V_{oc} = \frac{nkT}{q} \ln \left(\frac{I_{out}}{I_o} + 1 \right) \quad (5)$$

dimana k adalah konstanta Boltzmann ($1.380649 \times 10^{-23} \text{ m}^2 \text{ kg s}^{-1} \text{ K}^{-1}$) dan nilai tegangan ini dipengaruhi oleh nilai temperatur lingkungan.

Efisiensi pv (η) didefinisikan sebagai perbandingan antara input daya (P_{in}) dan output daya yang dibangkitkan (P_{out}) atau dapat dituliskan sebagai berikut:

$$\eta = \frac{P_{out}}{P_{in}} \times 100\% = \frac{I_{mp} \cdot V_{mp}}{P_{in}} \times 100\% = \frac{I_{sc} V_{oc} FF}{P_{in}} \times 100\% \quad (6)$$

dimana I_{mp} dan V_{mp} adalah arus dan tegangan maksimum yang dibangkitkan solar panel, dan FF adalah fill factor yang didefinisikan sebagai jumlah maksimum daya yang bisa dibangkitkan oleh panel, sebagaimana diperlihatkan pada gambar 5.



Gambar 5 Fill Factor Sebagai Fungsi Daya Maksimum

2.7 *Smart Farming*

Pertanian moderen didefinisikan sebagai integrasi teknologi dengan pertanian serta mengatasi kekurangan-kekurangan pertanian, Sebagai hasilnya, diharapkan penerapan teknologi-teknologi ini akan membuat pekerjaan petani lebih mudah dilakukan dan meningkatkan produktivitas pertanian[37]-[40].__Komponen-komponen pertanian moderen adalah sensor, kendali, dan aktuator dengan bantuan Internet of Things (IoT). Monitoring digunakan untuk meningkatkan produktivitas dan memudahkan pekerjaan petani. Secara definisi, pertanian moderen dibagi menjadi : (a). Pertanian Presisi, (b). Pertanian Digital dan (c). Pertanian Pintar

Selama bertahun-tahun, pertanian telah mengalami banyak revolusi, baik itu perbaikan praktik pertanian atau perluasan bidang pertanian modern. Kemajuan teknis di bidang pertanian telah mendorong gelombang revolusi hijau yang menciptakan peluang bagi para petani untuk belajar dan mengadopsi cara ilmiah dalam mengoperasikan pertanian sehingga mengurangi bentuk kerja manual dan beralih ke otomatisasi. Pertanian dalam *greenhouse* telah menjadi kunci menuju pertanian cerdas dan berkelanjutan karena mengandalkan data. Pertanian yang berpusat pada data telah mengubah pertanian dengan menjadikannya lebih tepat dan akurat sehingga mengkonsolidasikan keseluruhan proses pertanian.

2.8 *Sensor-sensor Dalam Agrioltaic*

Sensor pertanian adalah sensor yang digunakan dalam bidang pertanian untuk pertanian cerdas. Sensor ini menyediakan data yang dapat digunakan oleh petani untuk memantau dan mengoptimalkan tanaman sebagai respons terhadap kondisi lingkungan dan tantangan yang dihadapi. Sensor-sensor ini dipasang dan dipasang tetap di stasiun cuaca, drone, dan robot pertanian. Mereka dapat dikendalikan secara presisi melalui aplikasi seluler yang dikembangkan khusus untuk tujuan ini. Sensor pertanian dengan konektivitas nirkabel dapat dikendalikan langsung melalui Wi-Fi atau menara seluler menggunakan aplikasi seluler.

Berbagai jenis sensor yang digunakan dalam pertanian untuk menerapkan pertanian cerdas dapat diklasifikasikan sebagai berikut:

a. Sensor Optik dalam Pertanian

²³ Sensor optik menggunakan cahaya untuk mengukur sifat tanah pada berbagai frekuensi cahaya. Sensor ini, yang dipasang pada kendaraan atau drone,

mengumpulkan dan memproses data reflektansi tanah dan warna tanaman. Kandungan tanah liat, bahan organik, dan kelembaban tanah dapat ditentukan menggunakan sensor optik.

b. **Sensor Elektrokimia untuk Deteksi Nutrisi Tanah**

Sensor elektrokimia untuk deteksi nutrisi tanah mengumpulkan data kimia tanah dan nutrisi. Penentuan pH dilakukan menggunakan elektroda ion-selektif yang mendeteksi aktivitas ion tertentu, seperti nitrat, kalium, atau hidrogen.

c. **Sensor Mekanis Tanah**

Sensor mekanis tanah menggunakan mekanisme yang mengebor tanah dan mencatat gaya yang diukur dengan skala tekanan atau sel beban. Ketika sensor memotong tanah, ia mengukur gaya tahanan yang dihasilkan oleh pemotongan, pemecahan, dan perpindahan tanah. Resistansi mekanis tanah diukur dalam satuan tekanan dan merupakan rasio gaya yang dibutuhkan untuk memasuki media tanah dengan luas depan alat yang berinteraksi dengan tanah.

d. **Sensor Kelembaban Tanah Dielektrik**

Sensor kelembaban tanah dielektrik menggunakan konstanta dielektrik untuk menghitung tingkat kelembaban di tanah, suatu sifat listrik yang berubah tergantung pada jumlah kelembaban dalam tanah. Sensor kelembaban ini digunakan bersama titik pengamatan curah hujan di seluruh lahan pertanian, memungkinkan analisis penempatan kelembaban tanah saat tingkat vegetasi rendah.

e. **Sensor Lokasi dalam Pertanian**

Sensor lokasi menggunakan satelit GPS untuk menentukan jarak, ketinggian, dan rentang posisi dalam suatu area tertentu.

f. **Sensor Elektronik**

Sensor elektronik dipasang pada traktor dan peralatan lapangan lainnya untuk memantau operasi peralatan. Pemantauan ini menggunakan sistem komunikasi seluler dan satelit untuk mengirim data langsung ke komputer atau melalui email kepada individu terkait. Data ini kemudian dapat diambil oleh eksekutif lapangan di komputer kantor mereka atau ponsel.

g. Sensor Aliran Udara

Pengukuran sensor aliran udara dapat dilakukan di lokasi tertentu saat bergerak. Output yang diinginkan adalah tekanan yang diperlukan untuk mendorong sejumlah udara yang telah ditentukan ke dalam tanah pada kedalaman yang telah ditentukan. Sifat tanah seperti pemadatan, struktur, jenis tanah, dan tingkat kelembaban semuanya menghasilkan tanda pengenal unik.

h. Sensor Pemantauan IoT

Pada interval waktu tertentu, sensor pemantauan IoT mengukur dan mencatat suhu udara, suhu tanah pada berbagai kedalaman, curah hujan, kelembaban daun, klorofil, kecepatan angin, suhu titik embun, arah angin, kelembaban relatif, radiasi matahari, dan tekanan atmosfer. Sensor yang digunakan dalam pemantauan IoT pertanian meliputi:

- Pemantauan Kondisi Iklim
- Otomasi Rumah Kaca
- Manajemen Tanaman
- Manajemen dan Pemantauan Ternak
- Pertanian Presisi Cerdas Berbasis Sensor
- Drone Pertanian

Contoh alat pintar dan aplikasi ponsel untuk pemantauan IoT adalah GPS untuk memberikan lokasi pemetaan tanaman, peringatan lokasi untuk penyakit tanaman dan hama, prediksi radiasi matahari, dan pemupukan, kamera untuk pemrosesan gambar guna mendeteksi kesehatan daun, pencahayaan, tingkat kecerahan, dan kematangan, mikrofon untuk memprediksi perawatan mesin, dan akselerometer untuk menentukan indeks sudut daun.

i. Stasiun Cuaca Pertanian

Stasiun cuaca pertanian adalah sensor yang berdiri sendiri dan terletak di seluruh area pertanian. Stasiun-stasiun ini memiliki berbagai sensor yang sesuai untuk tanaman dan iklim setempat. Pada interval waktu yang telah ditentukan, data seperti suhu udara, suhu tanah pada berbagai kedalaman, curah hujan, kelembaban daun, klorofil, kecepatan angin, suhu titik embun, arah angin, kelembaban relatif, radiasi matahari, dan tekanan atmosfer diukur dan dicatat.

2.9 Aktuator dalam Agrivoltaic

Aktuator adalah keluaran dalam sistem pengendalian iklim dalam *greenhouse* di mana pengontrol mengaktifkan aktuator berdasarkan masukan dari sensor yang dipasang di dalam *greenhouse*. Aktuator memainkan peran penting dalam pertanian cerdas, dan beberapa aplikasi umum dari aktuator adalah sebagai berikut:

a. Aplikasi Aktuator di Lapangan

Aplikasi aktuator di lapangan meliputi penyemprot yang mengontrol ketinggian dan sudut nosel, aktuator linier untuk membuka palka pada berbagai alat penanam, serta untuk mesin pertanian pada roda kemudi, pegangan, dan gigi transmisi.

b. Aplikasi Aktuator untuk Penyebar

Aktuator bekerja dengan baik dalam menyebarkan pupuk dan pestisida secara otomatis dengan bantuan sensor yang terpasang.

c. Aktuator untuk Pemanen Otomatis

Aktuator semi atau sepenuhnya otomatis dapat berfungsi dengan baik dalam cuaca yang ekstrem. Pengaturan aktuator yang tepat dapat memberikan hasil pemanenan yang halus dan akurat dengan bantuan masukan dari sensor. Pemanen otomatis dapat berupa traktor dengan lengan robot terpasang. Aktuator pada traktor dapat memberikan penyesuaian roda kemudi yang presisi, posisi kerja otomatis, dan ventilasi otomatis.

d. Aktuator untuk Alat Bor Benih

Aktuator dapat memberikan presisi dan posisi yang akurat untuk alat bor benih dalam pertanian modern. Aktuator dapat mengontrol jumlah benih yang harus disebarkan dengan cara yang tepat untuk mendapatkan hasil tanaman yang efisien, dengan menandai jalur alur untuk memastikan prosedur penanaman yang optimal serta menyesuaikan jumlah penanaman agar dosis benih tepat tanpa pemborosan.

2.10 Pemodelan Kontrol Iklim Mikro

Kontrol iklim mikro di dalam *greenhouse* merupakan contoh dari pertanian moderen dan pintar. *Greenhouse* didefinisikan sebagai ruang terbatas dimana iklim dimodifikasikan dan dipelihara agar ideal bagi bagi tanaman. Para petani dapat menumbuhkan tanaman yang seharusnya tidak tumbuh subur di lingkungan tersebut karena pengaturan lingkungan. Dibandingkan dengan tanaman yang tumbuh di luar *greenhouse*, ruang terbatas tersebut menjamin lingkungan tersebut bebas hama.

Iklim mikro yang terkendali dan terpantau di dalam rumah kaca membutuhkan beberapa faktor, termasuk pengontrol untuk mengaktifkan aktuator berdasarkan kondisi iklim mikro, sensor untuk merasakan kebutuhan di dalam rumah kaca, sistem pemantauan *IoT* untuk memungkinkan petani memperbarui situasi secara *online*, dan pengendalian hama untuk memastikan lingkungan yang aman.

Dukungan energi listrik dalam operasional kinerja pertanian moderen adalah sangat penting untuk menggeakkan perangkat elektronika yang terpasang dalam sistem tersebut. Penggunaan listrik selama 24 jam dalam satu hari merupakan tantangan tersendiri, untuk mengakomodir hal tersebut, digunakanlah energi terbarukan sebagai energi alternatif yang sangat bermanfaat bagi keberlanjutan pertanian modern.

Energi surya merupakan salah satu sumber energi yang paling cocok di terapkan di Indonesia, karena matahari bersinar sepanjang tahun. Pemodelan pembangkit listrik menggunakan energi surya disajikan dengan banyaknya listrik yang dihasilkan oleh panel surya (PV) dan listrik setelah dihubungkan ke MPPT. Luaran dari modul PV sebelum dihubungkan ke MPPT ($V_{pv,out}$ dan U_{pv}) [35]:

$$V_{pv,out}(t) = \beta_{bv,s} V_{pv}(t) \quad (7)$$

dan

$$u_{pv}(t) = \beta_{bv,s} \beta_{bv,p} V_{pv}(t) I_{pv}(t) \xi \quad (8)$$

Dalam persamaan tersebut, $\beta_{bv,s}$ dan $\beta_{bv,p}$ adalah jumlah sambungan seri dan paralel dari modul PV dan ξ adalah rugi-rugi. Arus I_{pv} dan tegangan V_{pv} yang dihasilkan ketika terhubung ke MPPT (Maximum Power Point Tracker) adalah:

$$I_{pv}(t) = I_{sc,ref} \left\{ 1 - A_{pv} \left[\exp \left(\frac{V_{mp,ref}}{B_{pv} V_{oc,ref}} \right) \right] \right\} + \Delta I(t) \quad (9)$$

Dimana V_{pv} merupakan tegangan nominal yang dihasilkan oleh panel surya. Penurunan tegangan yang diakibatkan oleh suhu yang meningkat menunjukkan bahwa, meskipun radiasi matahari tinggi, suhu operasional yang melebihi suhu referensi akan menyebabkan penurunan efisiensi output dari sistem panel surya. Hal ini sejalan dengan temuan sebelumnya di literatur, bahwa suhu yang lebih tinggi cenderung menurunkan kinerja modul panel surya.

$$V_{pv}(t) = V_{mp,ref} \left[1 + 0.0539 \log \frac{G_{in}(t)}{G_{st}} \right] + \mu \Delta T(t), \quad (10)$$

$$A_{pv} = \left(1 - \frac{I_{mp,ref}}{I_{sc,ref}} \right) \exp \left[- \frac{V_{mp,ref}}{B_{pv} V_{oc,ref}} \right], \quad (11)$$

$$B_{pv} = \frac{\frac{V_{mp,ref}}{V_{oc,ref}}}{\ln \left(1 - \frac{I_{mp,ref}}{I_{sc,ref}} \right)}, \quad (12)$$

$$\Delta(t) = \gamma \left(\frac{G_{in}(t)}{G_{st}} \right) \Delta T(t) \left(\frac{G_{in}(t)}{G_{st}} - 1 \right) I_{sc,ref}, \quad (13)$$

$$\Delta T(t) = T_a + 0.02 G_{in}(t), \quad (14)$$

di mana $V_{mp,ref}$ adalah tegangan daya maksimum (V), $V_{oc,ref}$ adalah tegangan sumber terbuka (V), $G_{in}(t)$, dan G_{st} adalah total irradiansi dan intensitas cahaya standar, serta μ dan γ adalah koefisien suhu tegangan dan arus modul. A_{pv} adalah koefisien atau konstanta yang digunakan untuk menggambarkan bentuk kurva karakteristik arus-tegangan (I-V) dari modul PV. Koefisien ini merupakan bagian penting dalam model yang menentukan seberapa tajam atau lebar kurva karakteristik modul PV. $I_{mp,ref}$ merupakan arus maksimum pada titik daya maksimum (Maximum Power Point Current) pada kondisi referensi, yang merupakan kondisi standar untuk pengukuran karakteristik modul PV.

Model matematika pengendalian mikro-iklim diperlukan untuk memprediksi kinerja pengendalian dan manajemen energi pada sebuah *greenhouse*. Prediksi sistem harus mencakup keseimbangan energi antara parameter-parameter *greenhouse*, intensitas radiasi matahari, dan proses pendinginan evaporatif.

Transfer energi terjadi karena adanya perbedaan suhu antara dua parameter fisik *greenhouse* dengan area suhu yang berbeda, seperti penutup *greenhouse*, udara di dalam *greenhouse*, permukaan tanah yang tidak tertutup, dan area tanah.

Keseimbangan energi fluks kalor radiasi bersih pada penutup *greenhouse* dapat dituliskan sebagai :

$$Q_{r,c}^{net} = \frac{-\epsilon_c \sigma T_c^4 S_c + \alpha_{ct} \epsilon_{sky} \sigma T_{sky}^4 S_c + \alpha_{ct} \epsilon_s T_s^4 S_s}{S_s} \quad (15)$$

di mana c menyatakan kondisi atap *greenhouse*, s adalah tanah, $Q_{r,c}^{net}$ adalah jumlah radiasi termal bersih (W/m^2), ϵ_c dan ϵ_s mewakili emisivitas penutup *greenhouse* dan permukaan tanah, σ adalah konstanta Stefan-Boltzmann (W/m^2K^4), T_c , T_s , dan T_{sky} mewakili suhu atap, lantai, dan langit, $T_{sky} = 0.0552 (T_a)^{1.5}K$, α_{ct} adalah absorptivitas radiasi matahari oleh penutup *greenhouse*, S_c , S_s mewakili luas penutup *greenhouse* dan permukaan lantai.

Keseimbangan energi dari udara internal per m^2 di dalam rumah kaca mencakup transfer panas konvektif dan energi pendinginan dari perangkat pendingin yang dipasang. Studi ini tidak mempertimbangkan penyerapan radiasi termal atau matahari oleh udara. Oleh karena itu, keseimbangan energi dapat ditulis sebagai :

$$\rho_a C_{pa} H \frac{dT_i}{dt} = Q_{co,s-1} + Q_{inf} - Q_{co,c-a} \quad (16)$$

di mana a menunjukkan parameter udara, ρ_a adalah densitas udara ($1,29 \text{ kg/m}^3$), c_{pa} adalah kapasitas panas udara ($1,0 \text{ J/kg-K}$), $Q_{co,s-1}$ adalah transfer panas konveksi dari tanah ke udara (W/m^2), Q_{inf} adalah laju transfer panas infiltrasi (W/m^2), dan $Q_{co,c-a}$ adalah transfer panas konveksi dari penutup ke udara sekitar (W/m^2).

Energi yang dilepaskan oleh kipas exhaust (Q_{ef}) adalah panas sensible dan laten, yang dapat dihitung sebagai :

$$Q_{ef} = Q_{si} Q_{Lt} = \frac{A_{ex} V_g \rho_a}{A} ((T_i - T_o)) C_p + (X_i - X_o) \quad (17)$$

di mana Q_{si} adalah panas sensible (W/m^2), Q_{Lt} adalah panas laten (W/m^2), A_{ex} adalah jumlah pertukaran udara (jam^{-1}), V_g adalah volume udara di dalam *greenhouse* (m^3), T_i dan T_o adalah suhu di dalam dan di luar *greenhouse* ($^{\circ}K$), dan X_i dan X_o adalah kandungan air di dalam dan di luar *greenhouse*. Dengan mempertimbangkan faktor konstan (ψ) dan kecepatan angin (v_w dalam ms^{-1}), A_{ex} dapat dihitung sebagai :

$$A_{ex} = \psi v_w + 0.25, \quad h - 1 \quad (18)$$

"Keseimbangan energi yang dipancarkan oleh tanaman di dalam rumah kaca (Q_{pl}) dapat dijelaskan sebagai:

$$Q_{pl} = -Q_{rd(pl-co)} - Q_{rd(pl-so)} - Q_{cv(pl)} - Q_{trans} \quad (19)$$

di mana $Q_{rd}(pl-co)$ adalah pertukaran radiasi matahari antara tanaman dan penutup *greenhouse* (W/m^2), $Q_{rd}(pl-so)$ adalah pertukaran radiasi matahari antara tanaman dan tanah (W/m^2), $Q_{cv}(pl)$ adalah fluks panas ke konveksi dari tanaman ke udara (W/m^2), dan Q_{trans} adalah aliran panas di dalam rumah kaca (W/m^2).

Hitung setiap energi yang disajikan dalam persamaan 7 seperti persamaan berikut ini :

$$Q_{pl} = \alpha_{pl} \tau S_t, \quad (20)$$

$$Q_{rd}(pl-co) = \epsilon_{(pl,co)} \left(\frac{A_{co}}{A_{pl}} \right) \sigma (T_{pl}^4 - T_{co}^4) \quad (21)$$

$$\epsilon_{(pl,co)} = \frac{1}{\frac{1}{\epsilon_{pl}} + \frac{A_{co}}{A_{pl}} \left(\frac{1}{\epsilon_o} \right)}, \quad (22)$$

$$Q_{trans} = \frac{\alpha_{ins}}{c_p} r \zeta_{pl} (X_{sat}(pl) - X_i) \quad (23)$$

A_{pl} adalah penyerapan permukaan tanaman, τ adalah transmisivitas selubung *greenhouse*. S_t adalah penyinaran matahari di luar rumah kaca (W/m^2), $\epsilon_{(pl,co)}$ adalah emisivitas antara tanaman dan penutup rumah kaca, A_{co} adalah luas permukaan penutup (m^2), A_{pl} adalah luas permukaan tanaman, σ adalah konstanta Stefan Boltzman ($Wm^{-2}K^{-4}$), ϵ_{pl} dan ϵ_{co} adalah emisivitas tanaman dan penutup *greenhouse*, α_{ins} adalah koefisien perpindahan panas ($Wm^{-2}K^{-1}$), c_p adalah perpindahan panas spesifik tanaman/tanaman pada tekanan konstan ($JKg^{-1}K^{-1}$), r adalah panas laten penguapan (Whg^{-1}), ζ_{pl} adalah jarak permukaan penguapan dari tanaman permukaan, dan $X_{sat}(pl)$ adalah kadar air jenuh pada suhu tanaman.[41].

2.11 Desain Kendali Iklim Mikro

Saat ini, terjadi pertumbuhan besar di sektor pertanian dengan penggunaan komputer, kecerdasan buatan, robotika, dan *Internet of Things (IoT)*. Di era pertanian cerdas, penerimaan sejumlah besar data dari berbagai sumber untuk berbagai waktu dan lokasi, telah membantu memantau dan mengelola tanaman dengan lebih baik, menghasilkan penghematan sumber daya alam dan mengurangi konsumsi energi. Pertanian cerdas dengan bantuan teknik dan teknologi inovatif dapat mendapat manfaat dari setiap aspek proses produksi, dari tahap penanaman hingga tahap akhir panen.

Desain pengontrolan iklim mikro sangat bergantung pada metode pengontrolan untuk memastikan energi yang dibutuhkan lebih rendah dan operasional yang lancar tanpa mengorbankan kebutuhan pertumbuhan tanaman. Pengendalian rumah kaca di pulau-

pulau tropis memerlukan sistem pendingin yang efektif karena suhu di dalam rumah kaca bisa lebih tinggi daripada suhu di luar, meskipun tujuan rumah kaca adalah menciptakan lingkungan yang ideal untuk pertumbuhan tanaman. Mengontrol dan memantau lingkungan *geenhouse* secara efektif dapat meningkatkan produktivitas dan mengurangi risiko kegagalan.


Pengendalian lingkungan dapat meliputi beberapa parameter lingkungan, seperti cahaya, suhu, kelembaban. Untuk kondisi di kawasan yang beriklim tropika pengendalian suhu udara sangatlah penting. Kondisi lingkungan di sekitar tanaman perlu dijaga agar selalu mendekati keadaan optimum bagi pertumbuhan tanaman.

Karena aplikasi sensor yang menghasilkan data besar dalam pertanian digital, pengontrol berbasis kecerdasan buatan (AI) biasanya diimplementasikan, dan AI dapat membuat keputusan cerdas berdasarkan input data dari sensor. *Convolutional Neural Network* (CNN) adalah implementasi AI yang cukup mudah untuk diterapkan.

Neural network ini meniru jaringan saraf biologis manusia dengan memasukkan arsitektur dan algoritma baru ke dalam komputer konvensional. Ini memungkinkan penggunaan operasi komputasi yang sangat sederhana, seperti penambahan, pengurangan, dan elemen logika fundamental, untuk memecahkan masalah yang kompleks, matematis yang tidak jelas, nonlinear, atau stokastik, kemampuan otak manusia memiliki beberapa ciri:

- a. Mengingat
- b. Menghitung
- c. Mengeneralisasi
- d. Adaptasi
- e. Konsumsi energi yang rendah

Gambar dibawah menggambarkan kemiripan arsitektur ANN dengan dengan sistem jaringan saraf pada tubuh manusia :



Gambar 6 Jaringan Syaraf Manusia dan Jaringan Syaraf Tiruan

Label A pada gambar 4 diatas merupakan struktur susunan sel neuron pada tubuh manusia. Sel neuron berfungsi sebagai pengantar informasi dari satu sel, ke sel lainnya dengan urutan sebagai berikut :

- a. Dendrit merupakan bagian yang berfungsi untuk menerima rangsangan atau informasi
- b. Badan sel bertugas menerima dan mengakumulasi rangsangan dari dendrit, memproses informasi tersebut dan lalu meneruskannya ke akson.
- c. Akson berfungsi meneruskan rangsangan yang telah diproses badan sel ke neuron lain.

Label B menggambarkan struktur ANN, dimana juga terdapat tiga bagian didalamnya yaitu input layer (x), hidden layer ($f()$) dan output layer (y). Informasi akan diterima oleh input layer menggunakan bobot yang ditentukan. Bobot akan dikumpulkan dan diakumulasi oleh hidden layer. Kemudian hasil penjumlahan tersebut dibandingkan dengan threshold yang ditentukan sebagai nilai aktivasi. Informasi yang masuk memenuhi syarat akan dilanjutkan ke output layer.

Pada ANN, neuron diasumsikan dapat dikelompokkan dalam layer seperti yang telah dijelaskan sebelumnya. Berdasarkan jumlah hidden layer yang digunakan pada ANN, struktur ANN dibagi menjadi dua yaitu single layer network dan multilayer network.

1. Jaringan lapis tunggal (single layer network) Jaringan lapis tunggal terdiri dari satu layer dari bobot yang saling terhubung. Pada jaringan lapis tunggal, informasi yang masuk akan langsung diproses menjadi sinyal keluaran tanpa melalui hidden layer terlebih dahulu. Label B pada gambar 5 merupakan contoh dari bentuk ANN single layer.


2. Jaringan lapis jamak (multilayer network) ANN dengan tipe ini memiliki lebih dari satu layer yang diberi nama hidden layer. Semua layer yang terletak diantara input layer dan output layer merupakan hidden layer, karena jumlah hidden layer yang bisa lebih dari satu layer. ANN lapis jamak ini menggunakan fungsi aktivasi nonlinear yang dapat digunakan untuk menyelesaikan berbagai tipe permasalahan yang lebih rumit dan kompleks. Arsitektur multilayer network dapat dilihat pada gambar 5 di bawah ini.



Gambar 7 Multilayer ANN

2 Dalam basis neural network diawali dengan proses training. Proses training adalah proses pengenalan pola berdasarkan nilai input yang diberikan dan nilai output yang diinginkan. Proses ini bertujuan untuk didapatkan hasil keluaran dengan nilai kesalahan paling kecil. Basis neural network dibagi menjadi tiga bagian desain yaitu input layer, hidden layer dan output layer. Nilai input yang dimasukkan untuk pengenalan pola dalam proses training berada dalam input layer. Lapisan setelah input layer yang menghubungkan nilai input dengan neuron-neuron disebut hidden layer. Output layer berisikan hasil keluaran yang sesuai dengan pola dalam hidden layer.

Cara kerja dari neural network yang pertama adalah disusun neuron dengan jumlah yang dibutuhkan dari kumpulan data yang diolah. Kemudian dilakukan sebuah proses untuk ditentukan karakteristik setiap neuron. Kekuatan penghubung antara neuron atau disebut karakteristik sinapsis ini digunakan sebagai tempat informasi disimpan. Data-data yang masuk dikalikan dengan nilai karakteristik yang ada pada setiap neuron. Setelah itu dijumlahkan semua kemudian ditambah dengan nilai bias. Didapatkan hasil akhir yang akan dimasukkan ke dalam fungsi aktivasi dan dihasilkan data keluaran dari neuron.




Gambar 8 Neural Network Model

Berdasarkan konstruksi jaringan, basis neural network dibedakan menjadi dua yaitu single layer perceptron dan multi-layer perceptron. Yang dimaksud single layer perceptron adalah jaringan yang terkonstruksi dengan digunakan satu input layer, satu hidden layer dan satu output layer. Untuk masukan bisa satu atau beberapa masukan. Dengan satu neuron atau beberapa neuron. Sedangkan yang dimaksud multi-layer perceptron adalah jaringan yang terkonstruksi atas beberapa masukan dalam satu input layer dan digunakan beberapa hidden layer yang banyaknya disesuaikan dengan output yang diinginkan. Ada dua proses dalam basis neural network yaitu proses trial dan error sehingga didapatkan nilai error yang paling kecil.

Dari gambar 6, fungsi transfer berfungsi mengubah sejumlah input (1, 2, 3...n) yang memiliki bobot (w_{1j} , w_{2j} , . . . w_{nj}) dan bias menjadi nilai input (net_j) bagi fungsi aktivasi. Selanjutnya fungsi aktivasi memproses nilai input untuk dibandingkan dengan threshold yang ditentukan dan mengaktivasi nilai menjadi output (o_j).

Dalam jaringan syaraf tiruan, fungsi aktivasi dipakai untuk menentukan output suatu neuron. Beberapa fungsi aktivasi yang sering dipakai dalam jaringan syaraf tiruan adalah sebagai berikut :

1. Fungsi aktifasi linier/identitas



Gambar 9 Fungsi aktivasi linier

Fungsi identitas sering dipakai apabila kita menginginkan output jaringan berupa sembarang bilangan riil (bukan hanya pada range $[0,1]$ atau $[-1, 1]$). Fungsi aktivasi ini

2 menghasilkan nilai output yang sama dengan nilai input. Fungsi aktivasi linear dapat digunakan dengan rumus :


$$f(x) = x \quad (24)$$

3
2. Fungsi threshold (batas ambang)

Fungsi threshold atau kadang disebut fungsi heaviside dapat dirumuskan sebagai berikut :

$$f(x) = 1, \text{ jika } x \geq a \quad (25)$$

$$f(x) = 0, \text{ jika } x < a \quad (26)$$




Gambar 10 Fungsi threshold (batas ambang)

3
Untuk beberapa kasus, fungsi threshold yang dibuat tidak berharga 0 atau 1, tapi berharga -1 atau 1 (sering disebut bipolar). Fungsinya berubah menjadi

$$f(x) = 1, \text{ jika } x \geq a \quad (27)$$

$$f(x) = -1, \text{ jika } x < a \quad (28)$$




36
Gambar 11 Fungsi Aktivasi Threshold Bipolar

3. Fungsi aktivasi sigmoid

Fungsi sigmoid sering dipakai karena nilai fungsinya yang terletak antara 0 dan 1 dan dapat diturunkan dengan mudah, fungsi sigmoid biner dirumuskan sebagai

$$y = f_t(x) = \frac{1}{1 + \exp(-x)} \quad (29)$$

Dengan turunan $f_1(x) = f_1(x)(1 - f_1(x)) \quad (30)$




Gambar 12 Fungsi aktivasi sigmoid biner

4. Fungsi aktivasi sigmoid bipolar

Selain sigmoid biner, sigmoid bipolar juga sering digunakan dan memiliki range $(-1, 1)$ yang dirumuskan sebagai

$$f_2(x) = 2f_1(x) - 1 \quad (31)$$

Dengan turunan $f'(x) = f(x)(1 - f(x))$ (32)



Gambar 13 Fungsi aktivasi sigmoid bipolar

2.11.1 Teknik Peramalan

Peramalan dapat bersifat kualitatif maupun kuantitatif. Peramalan bersifat kualitatif artinya tidak berbentuk angka. Sedangkan, peramalan yang bersifat kuantitatif berbentuk angka dan biasanya dinyatakan dalam bentuk bilangan.

a. Model Kualitatif

Model kualitatif berupaya memasukkan faktor-faktor subjektif dalam model prediksi, contohnya hasil pemikiran intuitif, perkiraan, dan pengetahuan yang telah didapat. Metode kualitatif dibagi menjadi dua bagian, yaitu :

- Metode Eksploratoris

Dimulai dengan masa lalu dan masa kini sebagai titik awalnya dan bergerak ke arah masa depan secara heuristik, seringkali dengan melihat semua kemungkinan yang ada.

- Metode Normatif

Dimulai dengan menetapkan sasaran dan tujuan yang akan datang, kemudian bekerja mundur untuk melihat apakah hal ini dapat dicapai berdasarkan kendala, sumber daya dan teknologi yang tersedia

- Metode kuantitatif

Metode kuantitatif dapat diterapkan bila terdapat tiga kondisi berikut :

1. Tersedia informasi tentang masa lalu.
2. Informasi tersebut dapat dikuantitatifkan dalam bentuk data numerik.
3. Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut dimasa mendatang.

Metode kuantitatif dapat dibagi menjadi dua bagian yaitu:

1. Metode Deret Berkala (Time Series) Metode deret berkala berarti peramalan masa depan akan bergantung kepada nilai seluruh variabel masa lalu ataupun kesalahan yang dilakukan sebelumnya. Tujuan dari metode ini adalah meneliti pola data yang dipakai untuk meramal dan melakukan ekstrapolasi ke masa depan. Metode ini menggunakan time series sebagai dasar peramalan data aktual masa lalu yang akan diramalkan untuk mengetahui pola data yang diperlukan dalam menentukan metode peramalan yang sesuai. Metode-metode prediksi yang menggunakan time series yaitu: Metode Smoothing, Metode Box-Jenkins, Metode Perkiraan dengan Regresi
2. Metode Kausal Metode ini adalah metode yang mengasumsikan bahwa faktor yang diramalkan menunjukkan suatu hubungan sebab akibat dengan satu atau lebih variabel bebas. Metode-metode peramalan dengan kausalitas yaitu: Metode Regresi dan Korelasi, Metode Ekonometrika.

2.11.2 Ukuran Statistik Standar

Jika X_i merupakan data aktual untuk periode i dan F_i adalah hasil peramalan untuk periode yang sama, maka kesalahan didefinisikan sebagai

$$e_i = X_i - F_i \quad (33)$$

Jika terdapat nilai aktual dan ramalan untuk n periode waktu, maka akan terdapat n buah kesalahan. Terdapat beberapa ukuran statistik standar, yaitu :

- a. Mean Error (ME) Mean Error (ME) adalah rata-rata kesalahan meramal dengan menghitung kesalahan dengan banyaknya data

$$ME = \sum_{i=1}^n \frac{e_i}{n} \quad (34)$$

3
Keterangan:

ME = rata-rata kesalahan

e_i = kesalahan peramalan

n = banyaknya data

b. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah rata-rata absolute dari kesalahan meramal, tanpa menghiraukan tanda positif atau negatif

$$MAE = \sum_{i=1}^n \frac{|e_i|}{n} \quad (35)$$

3
Keterangan:

MAE = rata-rata absolut kesalahan

$|e|$ = nilai absolut dari kesalahan peramalan

n = banyaknya data

c. Sum Of Squared Error (SSE)

Sum Of Squared Error (SSE) adalah penjumlahan dari kuadrat kesalahan

$$SSE = \sum_{i=1}^n e_i^2 \quad (36)$$

3
d. Mean Squared Error (MSE) Mean Squared Error (MSE) adalah metode lain untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau sisa dikuadratkan kemudian dijumlahkan dan dibagi dengan jumlah observasi.

$$MSE = \sum_{i=1}^n e_i^2 / n \quad (37)$$

3
Tujuan optimalisasi statistik seringkali dilakukan untuk memilih suatu model agar nilai MSE minimal, tetapi ukuran ini mempunyai dua kelemahan. Pertama ukuran ini menunjukkan pencocokkan (fitting) suatu model terhadap data historis. Pencocokan seperti ini tidak selalu mengimplikasikan peramalan yang baik. Suatu model yang terlalu cocok (over fitting) dengan deret data berarti sama dengan memasukkan unsur random sebagai bagian proses bangkitan, adalah sama buruknya dengan dengan tidak berhasil mengenai pola non acak dalam data. Kekurangan kedua dalam MSE sebagai ukuran ketepatan model adalah

berhubungan dengan kenyataan bahwa metode berbeda akan menggunakan prosedur yang berbeda pula dalam fase pencocokan.

2.11.3 Ukuran-ukuran Relatif

Keterbatasan MSE sebagai suatu ukuran ketepatan peramalan, membuat diusulkannya ukuran-ukuran alternatif, yang diantaranya menyangkut kesalahan persentase. Terdapat tiga ukuran yang sering digunakan.

a. Percentage Error (PE) Percentage Error (PE) adalah persentase dari kesalahan peramalan.

$$PE_t = \left(\frac{x_t - F_t}{x_t} \right) (100) \quad (38)$$

Keterangan:

PE_t = persentase kesalahan periode ke-t

X_t = Nilai data periode ke-t

F_t = Nilai ramalan periode ke-t

b. Mean Percentage Error (MPE), Mean Percentage Error (MPE) adalah rata-rata dari persentase kesalahan hasil peramalan.

$$MPE = \sum_{i=1}^n PE_t / n \quad (39)$$

Keterangan:

MPE = rata-rata persentase kesalahan

PE_t = persentase kesalahan pada periode ke-t

n = banyaknya data

c. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui nilai rata-rata kesalahan persentase absolute dari suatu peramalan.

$$MAPE = \sum_{i=1}^n |PE_t| / n \quad (40)$$

Keterangan:

MAPE = rata-rata absolut persentase kesalahan

$|PE_t|$ = nilai absolut dari persentase kesalahan peramalan

n = banyaknya data

Karena keterbatasan MSE sebagai ukuran ketepatan peramalan, maka dipakai ukuran alternatif sebagai salah satu indikasi ketepatan dalam peramalan, yaitu MAPE.

109

2.12 *Long-Short Time Memory (LSTM)-Artificial Neural Networks (ANN)*

Meningkatnya ketergantungan pada energi terbarukan, khususnya tenaga surya, telah menyoroti pentingnya mengembangkan model peramalan energi surya yang akurat [18,19]. Model-model ini sangat penting untuk menerapkan energi surya ke dalam jaringan listrik dan meningkatkan manajemen penyimpanan dan distribusi energi.

Teknik seperti jaringan saraf tiruan (ANN) dan model memori jangka pendek panjang (LSTM) umumnya digunakan untuk prediksi iradiasi matahari, masing-masing dengan kelebihan yang unik. Model LSTM, yang dikenal karena kemampuannya untuk memproses data deret waktu, sangat efektif dalam mengidentifikasi pola temporal, menjadikannya alat yang lebih disukai untuk memperkirakan radiasi matahari dan keluaran sistem PV [2,5]. Sebaliknya, ANN terampil dalam menangkap hubungan nonlinier yang kompleks antara variabel, membuatnya sangat berguna untuk prediksi daya surya jangka pendek [3,29].

Dalam beberapa tahun terakhir, minat terhadap model hibrida yang menggabungkan keunggulan model temporal seperti LSTM dengan model feedforward seperti ANN semakin meningkat. Pendekatan hibrida ini efektif dalam menangkap pola berbasis waktu dan hubungan nonlinier kompleks yang ditemukan dalam data energi surya. Penelitian telah menunjukkan bahwa menggabungkan LSTM dengan teknik pembelajaran mesin lainnya menghasilkan akurasi prediksi yang lebih baik. Misalnya, Battisti et al. pada tahun 2022 mengembangkan model LSTM hibrida untuk memprediksi penuaan perangkat lunak, yang menunjukkan kemampuannya untuk mengelola data yang bergantung pada waktu, sementara Agga et al. pada tahun 2022 dan Ibrahim & Morkos pada tahun 2024 memperkenalkan model CNN-LSTM hibrida untuk memperkirakan daya PV, yang memanfaatkan informasi spasial dan temporal untuk prediksi yang lebih tepat [1,4,9].

Arsitektur jaringan saraf hibrida yang mengintegrasikan jaringan saraf berulang (RNN), seperti LSTM, dengan jaringan saraf dangkal telah terbukti meningkatkan kemampuan prediksi untuk peramalan iradiasi matahari harian dan jangka pendek [5]. Model hibrida tersebut sangat berharga untuk meningkatkan akurasi prediksi output daya fotovoltaik (PV). Chen et al. pada tahun 2024 menunjukkan bahwa menggabungkan

model pembelajaran mendalam dengan data berbasis satelit secara signifikan meningkatkan peramalan jangka pendek, terutama ketika memperhitungkan kondisi cuaca dan lingkungan yang beragam [6].

Selain itu, model hybrida telah digunakan untuk mengatasi variabilitas dalam keluaran energi surya akibat kondisi cuaca dan faktor lingkungan yang berfluktuasi. Dengan mengintegrasikan model LSTM, yang mengkhususkan diri dalam menangani data sekuensial, dengan model ANN, yang secara efektif memodelkan hubungan nonlinier, pendekatan ini memberikan kerangka kerja yang lebih kuat untuk memprediksi energi surya [8,10]. Integrasi ini efektif dalam memprediksi pembangkitan listrik sistem PV untuk jaringan pintar dan dalam mengoptimalkan sistem energi surya-angin hybrida [10, 31].

Komponen LSTM sangat penting untuk menangkap ketergantungan berbasis waktu melalui penggunaan sel memori yang menyimpan informasi penting di beberapa langkah waktu. Komponen ini menggabungkan tiga gerbang utama: *the forget gate*, yang menghilangkan informasi yang tidak perlu dari status sel sebelumnya, gerbang masukan, yang mengendalikan informasi baru yang akan disimpan, dan gerbang keluaran, yang menentukan bagian mana dari memori tersimpan yang diteruskan ke lapisan atau langkah waktu berikutnya [17,30]. Fungsionalitas ini memungkinkan model LSTM untuk mengelola ketergantungan jangka panjang secara efektif, sehingga menjadikannya ideal untuk memprediksi keluaran energi PV mengingat fluktuasi temporal dalam iradiasi matahari dan kondisi cuaca [33].

Rumusan matematika model LSTM disediakan sebagai berikut [15,27]:

$$f_t = \sigma(W_f[h_t - 1, X_t] + b_f) \quad (41)$$

$$i_t = \sigma(W_i[h_t - 1, X_t] + b_i) \quad (42)$$

$$g_t = \tanh(W_g[h_t - 1, X_t] + b_g) \quad (43)$$

$$c_t = f_t \times c_{t-1} + i_t \times g_t \quad (44)$$

$$o_t = \sigma(W_o[h_t - 1, X_t] + b_o) \quad (45)$$

$$h_t = o_t \times \tanh(c_t) \quad (46)$$

di mana f_t , i_t dan g_t adalah *forget gate*, gerbang masukan, dan gerbang keluaran pembaruan, σ adalah fungsi aktivasi sigmoid, c_t adalah sel memori, h_t dan o_t adalah vektor keluaran sel memori, $b_{f,i,g,o}$ adalah vektor bias dan $W_{f,i,g,o}$ adalah matriks fungsi bobot.

Setelah lapisan LSTM, output dilewatkan ke Jaringan Syaraf Tiruan (JST), yang terdiri dari lapisan-lapisan padat untuk memproses data lebih lanjut. Lapisan-lapisan padat ini, seperti yang diilustrasikan dalam gambar, memiliki dua lapisan dengan masing-masing 36 neuron, dan lapisan-lapisan tersebut melakukan pemetaan non-linier dari output LSTM ke nilai-nilai yang diprediksi, seperti iradiasi, tegangan, arus, dan daya [5,20]. JST melengkapi LSTM dengan mempelajari pola-pola kompleks yang mungkin tidak ditangkap semata-mata oleh memori temporal, yang menghasilkan akurasi model yang lebih baik.

Model LSTM-ANN hybrida telah menunjukkan kinerja yang lebih unggul dalam memprediksi output PV dibandingkan dengan model individual. Penelitian menunjukkan bahwa pendekatan gabungan ini lebih efektif dalam menangkap pola temporal dan interaksi fitur daripada menggunakan model LSTM atau ANN saja [16,29]. Dengan mengintegrasikan metode ini, model tersebut meningkatkan akurasi prakiraan pembangkitan energi surya, yang memainkan peran penting dalam mengoptimalkan manajemen energi dan meningkatkan stabilitas jaringan [26,34].


Dengan menggabungkan kekuatan pemrosesan temporal LSTM dengan kemampuan deteksi pola nonlinier ANN, model hybrida ini memberikan solusi yang lebih tepat dan tangguh untuk memprediksi keluaran sistem fotovoltaik (PV). Komponen LSTM sangat efektif dalam mengenali pola berbasis waktu, seperti variasi dalam penyinaran matahari dan kondisi cuaca, dengan mempertahankan data sekuensial yang penting. Sementara itu, komponen ANN unggul dalam mengungkap hubungan nonlinier yang kompleks di antara berbagai variabel masukan, yang memungkinkannya untuk memetakan masukan ke keluaran secara akurat. Pendekatan hybrida ini tidak hanya meningkatkan akurasi prediksi tetapi juga meningkatkan kemampuan model untuk beradaptasi dengan kondisi dinamis, menjadikannya alat yang lebih efektif untuk memperkirakan pembangkitan energi PV dan mengoptimalkan kinerja jaringan [25,28].

2.13 *Convolutional Neural Network (CNN)*

CNN adalah variasi dari Multilayer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. CNN juga merupakan jenis dari deep neural network yang didesain untuk mengolah data dua dimensi dengan kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra.

66 Salah satu jenis neural network yang paling umum digunakan dalam data image adalah *convolutional neural network* (CNN), yang memiliki kemampuan untuk mendeteksi dan mengenali objek dalam suatu gambar. Seperti halnya NN, CNN terdiri dari neuron yang memiliki *weight*, *bias*, dan *activation function*. *Convolutional layer* juga terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (*pixels*). 91 32

2.13.1 Konsep Convolutional Neural Network




Gambar 14 Arsitektur Multilayer Sederhana

1 Sebuah MLP seperti pada Gambar 12 memiliki i layer (kotak merah dan biru) dengan masing-masing layer berisi j neuron (lingkaran putih). MLP menerima input data satu dimensi dan mempropagasikan data tersebut pada jaringan hingga menghasilkan output. Setiap hubungan antar neuron pada dua layer yang bersebelahan memiliki parameter bobot satu dimensi yang menentukan kualitas mode.

Di setiap data input pada layer dilakukan operasi linear dengan nilai bobot yang ada, kemudian hasil komputasi akan ditransformasi menggunakan operasi non-linear yang disebut sebagai fungsi aktivasi. Pada CNN, data yang dipropagasikan oleh jaringan adalah data dua dimensi, sehingga operasi linear dan parameter bobot pada CNN berbeda. Pada CNN operasi linear menggunakan operasi konvolusi dan bobot berbentuk empat dimensi yang merupakan kumpulan kernel konvolusi.

1 CNN merupakan suatu layer yang memiliki susunan neuron 3D (lebar, tinggi, kedalaman). Lebar dan tinggi merupakan ukuran layer sedangkan kedalaman mengacu pada jumlah layer. Dengan demikian, CNN merupakan metode untuk mentransformasikan gambar original layer by layer dari nilai pixel gambar kedalam nilai skoring kelas untuk klasifikasi.

Gambar 13 menunjukkan model konseptual dasar CNN, yang terdiri dari sekumpulan lapisan pemrosesan terbatas yang masing-masing memiliki kemampuan untuk mempelajari dan mengekstrak fitur tingkat tinggi (dengan abstraksi lebih rendah) dan fitur tingkat rendah (dengan abstraksi lebih tinggi).[43]



Gambar 15 Konsep Model CNN

Berdasarkan Gambar 13, arsitektur CNN terbagi menjadi dua bagian besar yaitu: convolutional layer (terdiri dari pooling layer, activation function dan hyperparameter) dan fully connected layer.

b. Convolution Layer

Convolution layer merupakan bagian dari tahap pada arsitektur CNN. Tahap ini melakukan operasi konvolusi pada output dari layer sebelumnya. Layer tersebut adalah proses utama yang mendasari jaringan arsitektur CNN.

Konvolusi adalah istilah matematis dimana pengaplikasian sebuah fungsi pada output fungsi lain secara berulang. Operasi konvolusi merupakan operasi pada dua fungsi argumen bernilai nyata. Operasi ini menerapkan fungsi output sebagai feature map dari input citra. Input dan output ini dapat dilihat sebagai dua argumen bernilai riil. Convolutional Layer terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (pixels).

Layer pertama pada feature extraction layer biasanya adalah conv. Layer dengan ukuran $5 \times 5 \times 3$. Panjang 5 pixels, tinggi 5 pixels dan tebal/jumlah 3 buah sesuai dengan channel dari image tersebut. Ketiga filter ini akan digeser keseluruh bagian dari gambar. Setiap pergeseran akan dilakukan operasi "dot" antara input dan nilai dari filter tersebut sehingga menghasilkan sebuah output atau biasa disebut sebagai activation map atau feature map.

c. Pooling

Pooling merupakan pengurangan ukuran matriks dengan menggunakan operasi pooling. Pooling layer biasanya berada setelah lapisan konvolusi. Pada dasarnya pooling layer terdiri dari sebuah filter dengan ukuran dan stride tertentu yang akan secara bergantian bergeser pada seluruh area feature map. Dalam pooling layer terdapat dua macam pooling yang biasa digunakan yaitu average pooling dan max-pooling. Nilai yang diambil pada average pooling adalah nilai rata-rata, sedangkan pada max-pooling adalah nilai maksimal.

Lapisan Pooling yang dimasukkan diantara lapisan konvolusi secara berturut-turut dalam arsitektur model CNN dapat secara progresif mengurangi ukuran volume output pada feature map, sehingga mengurangi jumlah parameter dan perhitungan di jaringan, untuk mengendalikan overfitting. Lapisan pooling bekerja di setiap tumpukan feature map dan melakukan pengurangan pada ukurannya. Bentuk lapisan pooling umumnya dengan menggunakan filter dengan ukuran 2×2 yang diaplikasikan dengan langkah sebanyak dua dan beroperasi pada setiap irisan dari inputnya.

d. Dropout


Dropout merupakan sebuah teknik regulasi jaringan syaraf dengan tujuan memilih beberapa neuron secara acak dan tidak akan dipakai selama proses pelatihan, dengan kata lain neuron-neuron tersebut dibuang secara acak. Hal ini berarti bahwa kontribusi neuron

yang dibuang akan diberhentikan sementara jaringan dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan backpropagation.

e. Fully-Connected Layer

Fully-Connected Layer adalah sebuah lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya sama seperti halnya dengan neural network biasa. Pada dasarnya lapisan ini biasanya digunakan pada MLP (Multi Layer Perceptron) yang mempunyai tujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linier.

Perbedaan antara lapisan fully-connected dan lapisan konvolusi biasa adalah neuron di lapisan konvolusi terhubung hanya ke daerah tertentu pada input, sementara lapisan fully-connected memiliki neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoperasikan produk dot, sehingga fungsinya tidak begitu berbeda.



Gambar 16 Proses Fully-Connected Layer

2.14 IoT Monitoring

Iklim di dunia semakin panas akibat berbagai aktivitas manusia dan meningkatnya kadar CO₂ yang mengakibatkan timbulnya efek rumah kaca. Gas rumah kaca merupakan faktor penting dalam ketidakstabilan pada pergantian musim karena penggunaan energi yang berlebihan. Berbagai tingkat iklim mikro mempengaruhi berbagai tanaman di rumah kaca pintar. Untuk melindungi tanaman maka iklim mikro harus diatur sedemikian rupa agar sesuai dan optimal bagi pertumbuhan tanaman cabai

Oleh karena itu, kondisi lingkungan di dalam rumah kaca pintar harus melindungi tanaman dari iklim mikro seperti suhu, kelembapan; pH; radiasi sinar matahari; media tanah, serta hama dan penyakit


Tujuan utama pertumbuhan tanaman terlindungi di rumah kaca cerdas adalah untuk menciptakan lingkungan potensial optimal bagi berbagai tanaman, bahkan dalam kondisi

iklim mikro yang buruk. Ada dua iklim mikro utama yang menguntungkan di rumah kaca pintar yaitu suhu dan kelembapan untuk kelangsungan pertumbuhan tanaman yang pada akhirnya memberikan kuantitas dan kualitas pertumbuhan tanaman

Modifikasi iklim mikro bertujuan untuk mewujudkan kondisi optimal pada rumah kaca pintar untuk meningkatkan hasil tomat. Beberapa petani yang hingga saat ini melakukan pengendalian iklim mikro masih dilakukan secara manual pada smart green house, ⁶¹ namun sangat disayangkan kondisinya masih belum bisa terpantau dan berubah sifat sehingga hasil tanaman masih belum bisa maksimal.

Pengelolaan *greenhouse* yang cerdas harus mampu melindungi tanaman dari iklim mikro yang berlebihan seperti panas dan dingin; suhu, kelembapan, pH, dan semua parameter akan diproses secara otomatis oleh teknologi informasi. Salah satu alternatifnya adalah Internet of Thing yang menggunakan sistem pendingin kabut. Perkembangan teknologi informasi modern diharapkan dapat membantu mengatasi beberapa permasalahan pada kondisi iklim mikro di *greenhouse* dan lebih mudah dalam pengendaliannya.

Internet of Thing merupakan sebuah platform yang menggunakan sensor kabel dan nirkabel untuk memproses data secara indrawi hingga menjadi informasi, dan komunikasi sehari-hari menjadi presisi. ⁴⁵ IoT merupakan sebuah konsep monitoring yang bertujuan memperluas manfaat dari konektivitas internet yang tersambung secara terus-menerus. Penerapan IoT pada sektor pertanian menjadi ²² gagasan baru untuk memonitor dan mengendalikan sistem pertanian dari jarak jauh. IoT yang harus dikembangkan dan sangat tepat untuk direalisasikan pada sektor pertanian. IoT dapat dimanfaatkan untuk memantau kondisi tanaman dan lingkungan dalam *greenhouse* melalui sensor-sensor dan semua komponen elektronika yang terpasang pada *greenhouse*.




Gambar 17 Diagram Arsitektur IoT Dalam Pertanian Greenhouse

22 Teknologi IoT mampu melakukan penjadwalan otomatisasi penyiraman, penyemprotan pestisida dan pemupukan, sehingga IoT memiliki potensi dan solusi yang sangat besar untuk mendukung dan membantu petani di Indonesia, diantaranya juga untuk 22 mewujudkan pertanian presisi (*precision farming*) dan irigasi pintar.

Solusi berbasis IoT yang diusulkan bertanggung jawab untuk mengoptimalkan sumber daya, mengkoordinasikan aktivitas, manajemen waktu, manajemen upaya manusia, mengumpulkan informasi, dan mengambil keputusan dengan menggunakan analisis data menggunakan platform Node-Red.

8 Node-RED adalah sebuah tool berbasis browser untuk membuat aplikasi Internet of Things (IoT) yang mana lingkungan pemrograman visualnya mempermudah penggunaannya untuk membuat aplikasi sebagai “flow”. Flow ini terbentuk dari node-node yang saling berhubungan di mana tiap node melakukan tugas tertentu. Walaupun Node-RED didesain untuk Internet of Things (IoT), ia juga dapat digunakan untuk keperluan umum dan untuk berbagai macam jenis aplikasi. Platform Node-Red digunakan untuk 24 melakukan pemantauan dengan mengimplementasikan beberapa komponen antarmuka yang telah disediakan



Gambar 18 Tampilan Layar Kerja Aplikasi Node-RED

2.15 Flow Editor

Sistem pengendalian iklim mikro pada *greenhouse* ini berbasis IoT menggunakan platform Node-RED sebagai *tool* yang menyediakan editor berbasis browser yang memudahkan untuk menyatukan aliran menggunakan berbagai macam node dalam palet yang dapat digunakan ke runtime dalam satu klik. Node-RED adalah alat pemrograman untuk menyatukan perangkat keras, API, dan layanan online dengan cara baru dan 35

menarik. Node-RED menyediakan flow editor berbasis browser yang memudahkan untuk menyatukan flow menggunakan berbagai macam node dalam palet. Flow kemudian dapat digunakan ke runtime dalam satu klik. [<https://nodered.org/>],[42]



Gambar 19 Komunikasi Sensor Melalui Aplikasi Node-RED

2 BAB 3. METODELOGI PENELITIAN

Bab ini menjelaskan metodologi yang akan digunakan pada penelitian ini bagaimana mengendalikan iklim mikro dalam suatu *greenhouse* menggunakan metode Neural Network dan Node-RED sebagai aplikasi IoT. Dari pertanyaan dan tujuan penelitian yang sudah disusun di bab 1 maka di bab 3 ini akan disusun kegiatan dan apa yang akan dicapai pada setiap kegiatan. Dimulai dengan menyusun kerangka kerja penelitian dan tahapan-tahapan penelitian yang akan dijelaskan pada masing-masing sub bab secara detail.


46 3.1 Kerangka Kerja Penelitian

Dalam penyusunan penelitian ini diperlukan susunan kerangka kerja yang jelas tahapan-tahapannya. Untuk itu dari kerangka kerja diterjemahkan dalam bentuk tahapan-tahapan penelitian yang digunakan dapat dilihat pada gambar 20.


Metode dan diagram alir penelitian Sistem Kendali Iklim Mikro Pada *Greenhouse* Tenaga Surya Melalui Pendekatan Neural Network dan Iot Monitoring dalam Skema Agrivoltaic diperlihatkan pada gambar 20.

Tahapan rancangan penelitian dapat di uraikan sebagai berikut:


1. Penelitian dimulai dengan studi literatur dan menyusun *feasibility study* untuk memastikan kemungkinan Sistem Kendali Iklim Mikro Pada *Greenhouse* Tenaga Surya Melalui Pendekatan *Neural Network* dan *Iot Monitoring* dalam Skema *Agrivoltaic* berjalan dengan baik.
2. Studi literatur yang terdiri dari teori Desain Sistem *Agrivoltaic*, PV System off-grid (PLTS) untuk suplai sistem *Agrivoltaic*, Syarat Tumbuh Tanaman, Metode Neural Network, *IoT monitoring*.
3. Penelitian dilanjutkan dengan pembangunan fisik sistem *Agrivoltaic* dan dilanjutkan sistem *IoT monitoring* untuk *Agrivoltaic*.
4. Setelah diperoleh sistem *IoT monitoring smart greenhouse*, maka dilaksanakan pertanian/bercocok tanam cabai karena memiliki daya jual tinggi dan menyukai tumbuh dibawah naungan. Tumbuh kembang dan hasil panel tanaman juga akan menjadi tolak ukur efektifitas *IoT monitoring Smart Greenhouse* dibandingkan dengan pertanian konvensional.



17
 Gambar 20 Diagram Alir Pelaksanaan Penelitian



Gambar 21 Blok Diagram Sistem



Gambar 22 Flowchart Tahapan Prediksi

3.2 Eksperimental Setup Greenhouse Untuk Aplikasi Agrivoltaik

Greenhouse dirancang berdasarkan kondisi iklim regional dan jenis tanaman. Pada dasarnya, dibentuk oleh struktur berbingkai yang ditutupi dengan lapisan plastik transparan.

Pada penelitian ini dirancang *greenhouse* dengan tipe *even-span* dengan ukuran dimensi 4mx4mx3,5m. Struktur pendukung terdiri dari rangka baja ringan yang ditutupi dengan satu lembar plastik film (UV) dengan ketebalan 200 mikron yang direntangkan


dari sisi ke sisi. Paragnet digunakan pada atap sebagai lapisan pelindung dari panas matahari. Jenis rumah kaca ini adalah solusi paling ekonomis untuk tanaman produksi.



Gambar 23 Visualisasi Eksperimental Setup Greenhouse

Pertanian dalam greenhouse dianggap sebagai salah satu teknik yang paling intensif energi untuk produksi tanaman. Memang, sejumlah besar energi diperlukan untuk menyediakan kondisi iklim yang optimal - dalam hal suhu, radiasi insiden, kelembapan, dan konsentrasi CO₂ - untuk pertumbuhan tanaman.

Smart greenhouse akan dibuat dengan plastik UV dan kerangka baja ringan. Ukuran greenhouse direncanakan 4x4x3,5m. Greenhouse akan dilengkapi sistem cooling untuk menurunkan dan menjaga suhu didalam *greenhouse* yang ideal untuk tanaman.



Gambar 24 Smart Greenhouse Monitoring

Rancangan mekanik sistem Agrivoltaic yang diteliti pada penelitian ini yang diilustrasikan pada gambar 25 dan 26, difokuskan pada monitoring iklim mikro greenhouse melalui Node-Red IoT software platform sehingga benar-benar terwujud pertanian pintar Agrivoltaic. Sensor-sensor yang akan diaplikasikan pada greenhouse adalah sebagai berikut:

1. Sensor suhu
2. Sensor kelembapan lingkungan dan kelembapan tanah
3. Sensor irradiasi matahari


Apabila nilai suhu atau nilai kelembapan tidak sesuai dengan kebutuhan tanaman, aktuator akan merespons sesuai dengan kondisi iklim mikro yang diperlukan di dalam *greenhouse*. Dalam *greenhouse* ini, terdapat dua jenis aktuator yang masing-masing memiliki peran penting sebagai perangkat untuk menggerakkan suatu komponen, yaitu Aktuator yang digunakan dalam *greenhouse* yaitu 4 unit *exhaust fan*, 43 buah *nozzle fogging sprayer*, 20 buah *dripper nozzle*.




Gambar 25 Peletakan Aktuator Dalam *Greenhouse*

3.3 Desain PV System Off-grid

Gambar 20 memperlihatkan diagram skematik desain PV System off-grid untuk mensuplai listrik pompa. Pompa diperlukan untuk irigasi pada sistem *Agrivoltaic*, dan gambar 24 memperlihatkan rangkaian lengkap desain PV System off-grid pada penelitian ini.



Gambar 26 Rangkaian Pompa Tenaga Surya



Gambar 27 Rangkaian PV System Off-Grid Pada Penelitian Ini

Desain PV system off-grid pada penelitian ini dimulai dengan melihat hubungan antara supply dan demand kebutuhan listrik greenhouse yang diajukan penelitian difokuskan pada pembangunan smart greenhouse dengan sistem IoT monitoring, sehingga segala sesuatunya otomatis. Desain demand atau kebutuhan listrik pada penelitian ini diperlihatkan pada tabel 2.

Tabel 2 Daftar Kebutuhan Beban Pertanian Pintar Agrivoltaic

No	Nama Komponen	Jumlah Unit	Daya (W)	Operasi (hour) ²¹	Wh
1	Pompa Irigasi	1	38	4	152
2	Pompa Sprayer	1	60	2	120
3	Pompa Leveling Nutrisi	1	38	2	76
4	Board Controller Arduino	1	9	2	18
5	Sensor Temperatur dan Kelembapan Lingkungan	2	5	24	240
6	Sensor Kelembapan Tanah	6	5	24	720
7	Sensor pH Tanah	6	21	24	720
8	Sensor arus dan tegangan	2	5	24	240
9	Irradiance meter	1			0
Total Daya (W)			165		
Total Beban Energi (TE)					2,286
20% TE					457,2
TE+20%					2,743,2

Berdasarkan kebutuhan listrik smart greenhouse pada tabel 1, maka penghitungan untuk desain PV system off-grid sebagai berikut:

1. Sizing PV Panel untuk Smart Greenhouse

Jumlah kebutuhan energi (E_r) untuk smart greenhouse adalah:

$$E_r = \frac{TE + 20\%}{\eta_{\text{panel}}} = \frac{19298}{0.8} = 24123 \text{ Wh}$$

dimana $TE + 20\%$ dari tabel 1 dan η_{panel} adalah koefisien panel. Sehingga jumlah panel (N_p) yang diperlukan untuk Smart Greenhouse pada penelitian ini adalah:

$$N_p = \frac{E_r}{\text{intensitas matahari} \times 180} = \frac{24123}{4.67 \times 180} = 28.7 \text{ Panel.}$$

Dari perhitungan diatas maka Jumlah panel yang dibutuhkan adalah 29 Panel sebagai pembulatan dari 28.7 Panel.

2. Sizing Baterai

Jumlah baterai (N_B) yang dibutuhkan untuk menyimpan energi pada sistem smart *greenhouse* untuk mengantisipasi keadaan No sun days adalah:

$$N_B = \frac{(TE + 20\%) \times \text{No Sun Days}}{V_B \times \text{Kapasitas Baterai} \times M_{\text{DOD}}} = \frac{19298 \times 4}{12 \times 200 \times 0.8} = 40 \text{ Baterai}$$

dimana No sun days adalah asumsi jumlah hari mendung dalam satu minggu, rencana kapasitas baterai pada penelitian ini adalah 200 mAh dan M_{DOD} (Maksimum charging baterai) adalah 80%.

3. Sizing Charge Controller

Charge controller yang direncanakan dipakai dalam penelitian memiliki spesifikasi DC12V/24V/36V/48V 60A, sehingga:

$$I_{\text{rata-rata SSC}} = I_{\text{SC}} \times N_p \times F_{\text{safe}}$$

$$I_{\text{rata-rata SSC}} = 12.28 \times 29 \times 1.25 = 441 \text{ A}$$

dimana I_{sc} panel adalah 12.28 A, sehingga jumlah charge controller (N_{CC}) yang diperlukan adalah

$$N_{\text{CC}} = \frac{441}{60} = 7 \text{ charge controller.}$$

4. Sizing Inverter

Inverter yang digunakan dalam penelitian ini hanya satu untuk mengakomodir total daya peralatan 1125 W, maka inverter yang digunakan inverter dengan kapasitas 3000 W, yang tersedia di pasaran.

3.4 Publikasi

Publikasi dari hasil penelitian ini adalah :

- a. Konferensi, diseminarkan pada konferensi internasional terindeks Scopus :
 - **Solar Power Greenhouse for Smart Agriculture** yang telah dipresentasikan pada **International Conference on Electrical (IEIT) 2023** pada tanggal 14-15 September 2023 di Malang secara daring dan dipublikasikan di IEEE Publisher pada tanggal 6 Desember 2023. (sertifikat dan karya tulis terlampir).

Karya ilmiah ini membahas penggunaan sistem pemantauan berbasis IoT dan model kontrol iklim mikro untuk meningkatkan hasil tanaman dalam lingkungan *greenhouse*.

¹¹
Y. Oktarina, Z. Nawawi, B. Y. Suprpto and T. Dewi, "Solar Powered Greenhouse for Smart Agriculture," *2023 International Conference on Electrical and Information Technology (IEIT), Malang, Indonesia, 2023*, pp. 36-42,

doi:10.1109/IEIT59852.2023.10335599.

<https://ieeexplore.ieee.org/abstract/document/10335599>

- ³¹
 - **Digitized Smart Solar Power Agriculture Implementation in Palembang, Sumatera Selatan** yang telah dipresentasikan pada seminar internasional **Electrical Engineering, Computer Science, and Informatics (EECSI) 2023** pada tanggal 20-21 September 2023 di Palembang secara daring dan telah dipublikasikan di IEEE Publisher pada 31 Oktober 2023 (sertifikat dan karya tulis terlampir).

Karya ilmiah ini menguraikan tentang data iradiasi matahari dan hasil implementasi sistem irigasi otomatis berbasis sensor di dalam *greenhouse*.

¹¹
Oktarina, Y., Nawawi, Z., Suprpto, B. Y., & Dewi, T. (2023, September).


³³
Digitized Smart Solar Powered Agriculture Implementation in Palembang, South Sumatra. In 2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI) (pp. 60-65). IEEE.

doi:10.1109/EECSI59885.2023.10295805


⁴⁴
<https://ieeexplore.ieee.org/abstract/document/10295805>


b. Paper dari data hasil eksperimen, telah dipublikasikan ke jurnal internasional terindex Scopus.

- **Towards Ecological Sustainability: Harvest Prediction In Agrivoltaic Chili Farming With CNN Transfer Learning** yang telah dipublish pada jurnal **Iraqi Journal Of Agricultural Sciences (IJAS)** University of Baghdad. Q1, SJR : 0,64 (2023).

 <https://orcid.org/0000-0002-5774-5906>

- **Integrating Temporal and Feedforward Models for Solar Energy Prediction: LSTM and ANN Hybrid Approaches** yang telah dipublish pada jurnal **International Journal of Research in Vocational Studies (IJRVOCAS)**

 <https://journal.gpp.or.id/index.php/ijrvocas/article/view/317>

 **DOI:** <https://doi.org/10.53893/ijrvocas.v4i2.317>

BAB IV KONTROL IKLIM MIKRO *GREENHOUSE* DALAM SKEMA AGRIVOLTAIK

4.1 Pendahuluan

Bab ini membahas dan menganalisis secara komprehensif berbagai dimensi dari konsep dan aplikasi *greenhouse* dalam konteks pertanian modern yang digunakan dalam penelitian ini. Penelitian ini bertujuan untuk mengevaluasi efektivitas penerapan teknologi agrivoltaik dan IoT dalam meningkatkan efisiensi pertanian di wilayah tropis, khususnya di Palembang, Sumatera Selatan, berfokus pada pemetaan evolusi desain yang didorong oleh berbagai kebutuhan ekologis dan ekonomis untuk kepentingan dalam penelitian ini.

Sistem pertanian tertutup seperti *greenhouse* memungkinkan memproduksi hasil pertanian secara optimal sepanjang tahun dengan mengatur kondisi lingkungan mikro yang mendukung pertumbuhan tanaman terlepas dari kondisi iklim makro yang tidak menentu, seperti cuaca ekstrim atau musim yang kurang mendukung.

Sistem iklim mikro di dalam *greenhouse* merujuk pada kondisi lingkungan yang dapat dikontrol secara spesifik, yaitu meliputi iradiasi matahari, suhu lingkungan dan kelembapan udara. Lebih lanjut, bab ini mengeksplorasi peran dan penerapan teknologi sensor dalam *greenhouse*. Analisis akan mencakup berbagai jenis sensor, seperti sensor suhu, kelembapan tanah dan udara serta sistem kontrol otomatis yang terintegrasi dengan teknologi terbaru untuk memaksimalkan pertumbuhan tanaman secara efisien.

Penerapan Internet of Things (IoT) sebagai sistem monitoring iklim mikro di dalam *greenhouse* memungkinkan pemantauan dan pengendalian berbagai parameter iklim, seperti suhu, kelembapan tanah dan udara, arus dan tegangan secara real-time melalui perangkat terhubung. Dengan menggunakan jaringan sensor yang terhubung ke platform cloud maka dapat memperoleh data secara kontinu dan melakukan penyesuaian otomatis untuk menjaga kondisi ideal bagi pertumbuhan tanaman cabai di dalam *greenhouse*.

4.2 Kondisi Lingkungan

Iklim mikro pertanian mengacu pada kondisi atmosfer lokal yang berbeda dari iklim umum di sekitarnya. Suhu, kelembapan dan radiasi matahari merupakan faktor-faktor yang mempengaruhi iklim mikro dalam suatu *greenhouse*.

a. Suhu tanah dan udara

Mempengaruhi proses fisiologis tanaman, seperti pertumbuhan akar, penyerapan nutrisi dan fotosintesis.

Pengendalian suhu dalam lingkungan *greenhouse* didasarkan pada penggunaan sensor suhu yang berfungsi untuk memantau dinamika suhu di dalam *greenhouse* secara real-time. Hasil pengukuran tersebut digunakan untuk mengaktifkan mekanisme regulasi seperti *exhaust fan* yang berfungsi menurunkan suhu melalui peningkatan sirkulasi udara. Pengurangan suhu ini sangat diperlukan pada saat suhu internal melebihi ambang batas yang dapat ditoleransi oleh tanaman.

b. Kelembapan tanah dan udara

Berhubungan dengan irigasi dan manajemen air yang sangat penting untuk pertanian di iklim kering. Kelembapan udara di dalam *greenhouse* merupakan salah satu parameter yang berhubungan dengan laju transpirasi dan efisiensi penyerapan air oleh tanaman. Regulasi kelembapan dilakukan melalui sistem kontrol otomatis yang dapat meningkatkan atau menurunkan kelembapan relatif sesuai kebutuhan tanaman, dengan metode sistem pengabutan (*misting system*), pengabutan air partikel halus ke udara untuk meningkatkan kelembapan secara cepat terutama dalam kondisi iklim mikro kering, metode lainnya adalah irigasi tetes (*drip irrigation*), metode ini dapat berfungsi untuk menjaga kelembapan tanah dan meningkatkan kelembapan udara di sekitar tanaman melalui penguapan air dari permukaan tanah.

c. Iradiasi matahari

Menentukan intensitas fotosintesis dan laju pertumbuhan tanaman. Iradiasi matahari merupakan faktor eksternal yang signifikan dalam pengendalian iklim mikro, baik di dalam maupun di luar *greenhouse*. Pengaruh ini dapat dilihat dari dua perspektif utama yaitu pengaruh pada sistem terbuka (di luar *greenhouse*) dan sistem tertutup (di dalam *greenhouse*).

4.3 Implementasi Sistem Agrivoltaik

Sistem agrivoltaik menggabungkan produksi energi matahari dengan pertanian di lahan yang sama. Sistem ini mengoptimalkan penggunaan lahan dengan menghasilkan listrik dari panel surya sekaligus memungkinkan kegiatan pertanian berlangsung di

bawahnya. Pada penelitian ini, sistem agrivoltaik dilakukan dalam dua kondisi yaitu agrivoltaik yang tidak dikondisikan dan agrivoltaik yang dikondisikan.

4.3.1 Agrivoltaik Yang Tidak Dikondisikan

Agrivoltaik ini menempatkan sistem panel surya yang dipasang di atas atau disekitar pertanian tanpa pengaturan otomatis yang mengendalikan kondisi iklim mikro secara *real-time*, dimana suhu dan kelembapan bergantung pada variasi alami yang terjadi karena adanya perubahan cuaca harian dan musiman.

Gambar 26 memperlihatkan sistem agrivoltaik yang tidak dikondisikan, dimana panel surya (PV panel) dipasang di atas area pertanian untuk menghasilkan energi listrik, tanpa integrasi langsung dengan sistem otomatis untuk pengendalian iklim mikro.



(a). Kondisi Awal

(b). Kondisi Setelah 3 Bulan

Gambar 28 Penerapan Sistem Pertanian Agrivoltaik Yang Tidak Dikondisikan

Tanaman yang ditanam di bawah panel surya mendapat manfaat dari sistem agrivoltaik di mana area pertanian memanfaatkan ruang di bawah panel surya, yang membantu mengurangi penguapan air dari tanah dan memberikan sedikit peneduhan pada tanaman pada saat siang hari.

Data kelembapan tanah dikumpulkan melalui sensor kelembapan (sensor A, sensor B dan sensor C) yang memungkinkan sistem penyiraman tanaman hanya ketika diperlukan melalui pompa dan alat penyiraman. Hal ini meningkatkan efisiensi air dan mengoptimalkan pertumbuhan tanaman di bawah naungan panel surya. Dalam implementasi di lapangan, sistem agrivoltaik ini energi listrik disalurkan melalui *combiner box* untuk keperluan operasional seperti pompa air dan perangkat lainnya. Karakteristik dari sistem ini adalah bahwa panel surya selain berfungsi untuk memberikan energi yang digunakan untuk berbagai keperluan non-iklimat, seperti penyiraman melalui


sprinkle atau penerangan, selain itu panel surya berperan memberikan efek shading alami, yang mengurangi intensitas cahaya langsung yang diterima tanaman.

Secara umum, sistem agrivoltaik yang tidak dikondisikan lebih rentan terhadap perubahan lingkungan yang tidak terduga yang pada akhirnya dapat berdampak negatif pada produktivitas tanaman dan efisiensi energi secara keseluruhan. Kurangnya otomatisasi dan kontrol iklim mikro yang tidak dikondisikan ini membuat agrivoltaik ini kurang ideal di wilayah yang memerlukan stabilitas iklim untuk pertumbuhan tanaman yang optimal.

4.3.2 Sistem Agrivoltaik Yang Dikondisikan

Agrivoltaik yang dikondisikan dalam sistem *greenhouse* menunjukkan keunggulan yang signifikan dalam hal optimalisasi penggunaan energi dan produktivitas tanaman. Dalam sistem ini, kontrol iklim mikro diintegrasikan dengan panel surya, dimana energi yang dihasilkan tidak hanya digunakan untuk kebutuhan eksternal tetapi juga mendukung operasi internal *greenhouse* seperti pengaturan suhu, kelembapan, irigasi otomatis dan lain-lain.

Data yang diperoleh dari sensor-sensor tersebut memungkinkan pengendalian yang presisi, menghasilkan lingkungan yang lebih stabil untuk pertumbuhan tanaman. Hasil ini diperkuat oleh kemampuan panel surya untuk menyediakan energi tambahan guna mempertahankan kondisi optimal, khususnya selama periode perubahan iklim yang ekstrem, seperti peningkatan suhu pada siang hari dan penurunan drastis di malam hari.



(a) Panel Surya Pada Green House

(b). Visualisasi Tata Letak Komponen Utama Dalam *Greenhouse*

Gambar 29 Sistem Agrivoltaik Yang Dikondisikan Dalam Greenhouse

Pada gambar 28 (a), instalasi fisik panel surya sebagai sumber daya utama untuk menjalankan sistem kendali iklim mikro dan kondisi lingkungan di dalam greenhouse sebagai sistem agrivoltaik yang dikondisikan. Terlihat pada gambar 28 (b), tanaman cabai yang tersusun rapi di atas rak dengan masing-masing sensor *capacitive soil moisture* sebagai pendeteksi tingkat kelembapan tanah dan juga *combiner box* sistem kelistrikan.

Gambar 28 menunjukkan bagaimana sistem agrivoltaik yang dikondisikan dapat diimplementasikan secara efektif dalam lingkungan *greenhouse*. Integrasi antara panel surya dan pengendalian otomatis iklim mikro memberikan keuntungan dalam hal efisiensi energi, stabilitas lingkungan untuk tanaman dan mengurangi ketergantungan pada energi eksternal.

Dalam menunjang proses pengendalian iklim mikro dalam *greenhouse*, diperlukan beberapa sensor dan aktuator seperti sensor suhu, sensor kelembapan, sensor ultrasonik, pompa, kipas pembuangan dan alat ukur. Semua perangkat ini bekerja secara otomatis untuk mengelola iklim mikro. Untuk memastikan suplai energi yang stabil dan berkelanjutan, penelitian ini menganalisis kebutuhan energi harian sistem dan menghitung jumlah panel surya yang dibutuhkan.

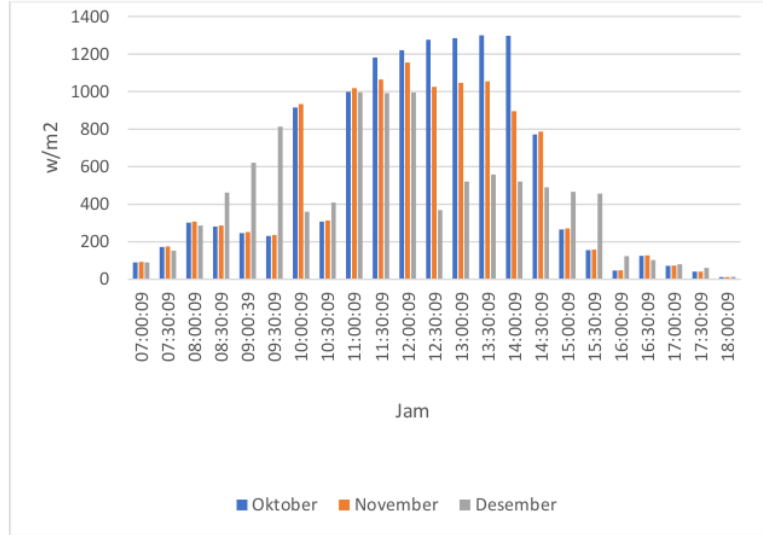
Dari data-data yang dihasilkan selama satu minggu di lokasi penelitian Talang Kemang, Gandus-Palembang, di dapati bahwa intensitas iradiasi tertinggi mencapai 1278,8 W/m², yang terjadi sekitar pukul 12.00 WIB dan terjadi pada hari keempat pengukuran. Nilai ini melebihi nilai iradiasi rata-rata global, yang memberikan indikasi kuat bahwa sistem ini beroperasi pada kondisi optimal untuk sebagian besar waktu yaitu dengan rentang waktu 10.00 WIB–14.00 WIB sebagai periode kritis dimana intensitas radiasi berada pada level tertinggi.

Nilai rata-rata intensitas radiasi yang tinggi ini memberikan dasar yang kuat bagi implementasi sistem pertanian pintar berbasis energi surya. Dengan ketersediaan sinar matahari sepanjang tahun di wilayah tropis seperti Palembang, potensi ini dapat dimanfaatkan secara optimal untuk memenuhi kebutuhan energi dalam sistem pertanian otomatis.

Secara keseluruhan, iradiasi harian menunjukkan bahwa intensitas radiasi mulai meningkat sejak pukul 08.00 WIB, mencapai puncaknya pada tengah hari dan kemudian berangsur-angsur menurun setelah pukul 14.00 WIB. Variabilitas antar hari juga diamati, dengan beberapa hari menunjukkan intensitas puncak yang lebih rendah dibanding hari lainnya, kemungkinan besar disebabkan oleh perubahan cuaca atau kondisi awan.

Sistem agrivoltaik di Talang Kemang mampu memanfaatkan potensi energi surya yang tinggi di wilayah tersebut, namun kinerja optimalnya masih dipengaruhi oleh faktor suhu yang harus dikelola dengan hati-hati. Berdasarkan data yang dihasilkan, penggunaan MPPT berperan penting dalam menjaga stabilitas keluaran daya, meskipun terdapat fluktuasi suhu lingkungan. Tanpa adanya koreksi dari MPPT, sistem ini akan mengalami efisiensi energi secara keseluruhan.

Panel surya yang dipasang dalam sistem agrivoltaik ini menghasilkan energi rata-rata 4,78 kWh per hari selama percobaan satu minggu dengan energi total yang dihasilkan selama percobaan adalah 33,46 kWh. Sementara itu kebutuhan energi total dari sistem ini adalah 24,5 kWh untuk perminggu waktu operasi. Artinya panel surya menghasilkan energi 36 % lebih banyak daripada kebutuhan sistem yang bisa digunakan sebagai cadangan untuk operasional di malam hari dan saat cuaca mendung.



Gambar 30 Hasil Pengukuran Radiasi Matahari (W/m²)

Gambar 29 menunjukkan hasil pengukuran radiasi matahari pada tiga bulan yang berbeda, yaitu Oktober, November dan Desember 2023, memaparkan fluktuasi radiasi matahari yang terjadi setiap bulan pada interval waktu mulai dari pukul 07.00 WIB hingga 10.00 WIB.

Radiasi matahari mengikuti pola yang serupa setiap harinya, dimana intensitas radiasi secara bertahap meningkat mulai dari 7.00 WIB dan mencapai puncaknya sekitar pukul 11.00 WIB hingga 13.30 WIB. Setelah mencapai pundaknya, radiasi matahari mulai menurun secara bertahap hingga sore hari pukul 15.00 WIB dan seterusnya hingga sangat rendah menjelang pukul 17.00 WIB-18.00 WIB.

Grafik ini juga memperlihatkan bahwa intensitas radiasi matahari bervariasi tidak hanya sepanjang hari, tetapi juga antar bulan. Pada bulan Desember, intensitas radiasi cenderung lebih rendah dibandingkan bulau-bulan sebelumnya, terutama pada rentang waktu pagi hari hingga siang hari yang mencerminkan berkurangnya durasi dan intensitas sinar matahari di akhir tahun.

Perbedaan intensitas radiasi antara satu hari dengan hari lainnya menunjukkan bahwa sistem panel surya harus dirancang untuk dapat mengatasi variabilitas ini. Pada hari keempat, dengan intensitas radiasi tertinggi, sistem beroperasi pada kapasitas maksimum, namun pada hari-hari dengan intensitas radiasi yang lebih rendah, daya yang

dihasilkan juga akan lebih rendah. Sebagaimana yang telah diuraikan dalam model listrik yang diadopsi, ¹⁰ tegangan dan arus keluaran yang dihasilkan oleh panel surya sebelum dihubungkan ke MPPT dirumuskan pada persamaan (1).

Pada intensitas radiasi matahari tertinggi tercatat, panel surya seharusnya menghasilkan tegangan sebesar 30 V di bawah kondisi ideal. Namun, dengan peningkatan suhu yang signifikan akibat radiasi matahari yang tinggi, tegangan aktual yang dihasilkan oleh panel akan mengalami penurunan, yang dihitung dengan menggunakan faktor koreksi β_{bvs} .

Jika suhu panel yang telah diukur mengalami peningkatan 10°C di atas suhu referensi, faktor koreksi ini menurun dari 1 menjadi 0,95 yang menghasilkan tegangan keluaran sebesar :

$$V_{pv,out} = 0,95 \times 30 \text{ V} = 28,5 \text{ V}$$

Penurunan ini menunjukkan bahwa, meskipun intensitas radiasi tinggi, sistem ini tidak dapat mempertahankan efisiensi maksimal karena pengaruh suhu terhadap kinerja modul panel surya. Penurunan tegangan ini secara langsung mempengaruhi ³⁷ daya yang dihasilkan oleh sistem, jika ⁵⁷ arus yang dihasilkan oleh panel surya tetap konstan 10 A, daya keluaran yang dihasilkan oleh panel surya dengan tegangan keluaran 28,5 V adalah 285 W.

Dengan demikian terdapat penurunan daya yang cukup signifikan dimana daya keluaran seharusnya 300 W atau lebih. Faktor koreksi ini harus diperhitungkan dalam desain sistem tenaga surya di wilayah tropis yang secara alami memiliki suhu lingkungan yang tinggi.

4.3.3 Sistem Pengendalian Iklim Mikro

Pengendalian iklim mikro dalam *greenhouse* sangat penting ¹⁸ untuk menciptakan kondisi lingkungan yang optimal bagi pertumbuhan tanaman cabai. Suhu dalam *greenhouse* dan kelembapan merupakan faktor utama yang mempengaruhi perkembangan tanaman, dan karenanya harus dikendalikan secara tepat.

Sistem pengendalian suhu berperan dalam menjaga kestabilan suhu di dalam *greenhouse*. Suhu yang tepat memungkinkan tanaman mencapai potensi pertumbuhan optimal, sementara perubahan suhu yang terlalu ekstrim dapat menghambat pertumbuhan

atau menyebabkan suhu internal berdasarkan kondisi eksternal dengan menggunakan teknologi sensor yang memantau suhu secara *real-time*.

Selain suhu, kelembapan juga merupakan elemen penting yang mempengaruhi kesehatan tanaman. Kadar kelembapan yang tidak sesuai, baik terlalu rendah maupun terlalu tinggi dapat memicu berbagai masalah fisiologis pada tanaman. Untuk menjaga keseimbangan kelembapan, sistem ini mengandalkan sensor yang memantau kondisi udara dan sistem irigasi untuk mempertahankan tingkat kelembapan yang optimal bagi tanaman.

4.4 Analisa Model Matematika Iklim Mikro *Greenhouse*


Pada penelitian ini, dilakukan pemodelan iklim mikro di dalam *greenhouse* dengan tujuan utama untuk memaksimalkan kondisi lingkungan yang ideal bagi pertumbuhan tanaman. Pemodelan ini dilakukan dengan menyeimbangkan beberapa parameter lingkungan penting, termasuk suhu, kelembapan, dan aliran energi yang terjadi di dalam ruang tertutup tersebut. Sistem ini sangat bergantung pada optimalisasi keseimbangan energi antara radiasi matahari dan transfer panas.

4.4.1 Model Energi Transfer Dalam *Greenhouse*

Gambar 30 menunjukkan skema mekanisme perpindahan energi dalam *greenhouse* yang mencerminkan konsep keseimbangan energi dan mekanisme perpindahan panas. Elemen-elemen dalam gambar tersebut

a. Iradiasi Matahari (*Solar Irradiation*):

Radiasi matahari memasuki *greenhouse* melalui penutup yang transparan. Sebagian dari radiasi ini diserap oleh berbagai elemen di dalam *greenhouse*, termasuk permukaan tanah dan tanaman, sementara sebagian lainnya dipantulkan atau dilepaskan kembali sebagai radiasi termal. Radiasi yang diserap membantu meningkatkan suhu di dalam *greenhouse*, mendukung pertumbuhan tanaman dengan menjaga suhu lingkungan yang lebih hangat pada siang hari.



Gambar 31 Mekanisme Perpindahan Energi Dalam Greenhouse

b. **Penyerapan dan Emisi Panas (*Absorption and Emission*):**

Penutup *greenhouse* dan permukaan lainnya, seperti tanah, menyerap radiasi matahari dan kemudian melepaskannya dalam bentuk emisi panas ke lingkungan. Dalam gambar 30 ini diilustrasikan oleh panah yang menunjukkan penyerapan dan emisivitas radiasi termal, sebagaimana dijelaskan dalam persamaan keseimbangan energi yang melibatkan suhu penutup, suhu tanah, dan suhu udara luar.

c. **Konveksi Panas (*Heat Convection*):**

Udara di dalam *greenhouse* mengalami konveksi panas dari permukaan tanah dan dari penutup *greenhouse* itu sendiri. Panas yang dihasilkan oleh radiasi matahari dipindahkan melalui konveksi udara, yang membantu menjaga suhu udara di sekitar tanaman tetap stabil. Konveksi panas ini dijelaskan dalam model keseimbangan energi udara, di mana panas ditransfer dari tanah ke udara di dalam *greenhouse* dan dari penutup ke udara di luar melalui kipas pembuangan (*exhaust fan*).

d. **Sistem Pengkabutan (*Fogging System*):**

Sistem pengkabutan digunakan untuk mengatur kelembaban di dalam *greenhouse*, yang sangat penting untuk menjaga iklim mikro yang optimal bagi tanaman. Pengendalian kelembapan melalui sistem ini membantu mencegah overheating dan menjaga keseimbangan suhu, terutama saat radiasi matahari berlebih. Ini berkaitan dengan proses transpirasi dan pendinginan evaporatif yang juga telah dibahas dalam model perpindahan energi tanaman.

e. **Sistem Irigasi (*Irrigation System*)**

Sistem irigasi terhubung dengan tanaman melalui tabung irigasi, yang memastikan tanaman mendapatkan air yang cukup. Pengendalian irigasi ini terkait dengan model manajemen air dan energi dalam *greenhouse*, di mana penggunaan sensor IoT dan AI dapat mengoptimalkan penyiraman berdasarkan kebutuhan air tanaman dan kondisi cuaca.

f. **Kipas Pembuangan (*Exhaust Fan*)**

Kipas pembuangan berfungsi untuk membuang udara panas dari dalam *greenhouse* dan memungkinkan pertukaran udara dengan lingkungan luar. Ini membantu dalam mengatur suhu dan menjaga sirkulasi udara yang sehat.

Penelitian ini mengadopsi model pengelolaan iklim mikro berbasis Internet of Things (IoT) dan energi surya. Model ini didasarkan pada pengumpulan data dari berbagai elemen fisik yaitu sensor yang terpasang di dalam *greenhouse*, termasuk sensor kelembapan tanah, sensor suhu dan kelembapan udara serta sensor ultrasonik.

Secara keseluruhan, gambar 30 menunjukkan bagaimana elemen-elemen fisik tersebut saling berinteraksi untuk menjaga iklim mikro yang ideal, dan memberikan representasi visual bagaimana mekanisme perpindahan energi, seperti penyerapan, emisi dan konveksi termal yang bekerja di lingkungan *greenhouse*.

Dengan pemodelan matematika yang mencakup keseimbangan energi, konveksi panas, dan penggunaan sistem pendingin seperti *fogging* dan *exhaust fan*, *greenhouse* dapat mempertahankan kondisi yang optimal untuk pertumbuhan tanaman sepanjang tahun, bahkan di lingkungan yang penuh dengan variabilitas cuaca.

Greenhouse berfungsi sebagai ruang tertutup yang menerima radiasi dari matahari melalui penutupnya dan kemudian energi tersebut ditransfer ke permukaan lantai dan dilepaskan ke atmosfer. Perpindahan panas melalui atap *greenhouse* dapat dihitung dengan persamaan energi radiasi (3). Jumlah radiasi termal $Q_{r,c}^{net}$ merupakan jumlah radiasi termal bersih yang terjadi antara permukaan penutup atap dan tanah di dalam *greenhouse* dalam satuan Watt per meter persegi (W/m^2). Nilai ini menggambarkan keseimbangan antara radiasi yang dipancarkan oleh atap dan permukaan tanah dengan radiasi yang diterima. Selain kondisi atap dan tanah, nilai radiasi ini juga dipengaruhi oleh material yang digunakan dan kondisi atap *greenhouse*, dan kondisi tanah di dalam *greenhouse* (s).

Dari gambar 29 dan persamaan (3) menunjukkan hubungan fundamental antara iradiasi termal dan penyerapan energi di dalam *greenhouse* sebagai bagian dari sistem pengendalian iklim mikro. Komponen emisi radiasi oleh atap $-\epsilon_c \sigma T_c^4 S_c$ menunjukkan seberapa banyak radiasi yang dipancarkan oleh atap dengan berdasarkan nilai emisivitas, luas atap dan suhunya, Dimana nilai emisivitas berkisar antara 0 hingga 1 dengan nilai 1 berarti memancarkan seluruh radiasi yang diterima.

Komponen lainnya adalah nilai absorpsi radiasi oleh atap yang dipengaruhi oleh emisivitas dan suhu langit, serta luas permukaan atap yang menerima radiasi dari langit. Selain itu komponen absorpsi radiasi tanah juga berperan dalam menentukan nilai radiasi termal ini yang terdiri dari nilai emisivitas permukaan tanah, suhu tanah dan luas permukaan tanah.

Secara keseluruhan, persamaan (3), menunjukkan keseimbangan energi yang terjadi antara penutup atap dan tanah di dalam *greenhouse*, dengan mempertimbangkan emisivitas (kemampuan memancarkan radiasi) dan absorptivitas (kemampuan menyerap radiasi) masing-masing permukaan. Persamaan ini mengkalkulasi total energi bersih yang dipertukarkan di antara kedua permukaan, di mana energi radiasi yang dipancarkan oleh atap dikurangi dari total energi radiasi yang diterima dari langit dan tanah.

Nilai $Q_{r,c}^{net}$ menunjukkan apakah sistem *greenhouse* mengalami surplus atau defisit energi termal, jika nilainya positif maka berarti memiliki lebih banyak energi yang diterima daripada yang dipancarkan sehingga suhu di dalam *greenhouse* akan cenderung meningkat. Namun jika nilainya adalah negative, maka berarti lebih banyak energi yang dipancarkan daripada energi yang di terima hal ini dapat menyebabkan penurunan suhu di dalam *greenhouse*.

4.4.2 Model Energi Udara dan Pendinginan Dalam *Greenhouse*

Penelitian ini menganalisis keseimbangan energi dalam udara internal rumah kaca, di mana perpindahan panas konvektif dan energi pendinginan dari perangkat pendingin yang terpasang turut diperhitungkan, keseimbangan energi dapat dinyatakan sebagai berikut:

$$\rho_{\alpha} C_{p\alpha} H \frac{dT_i}{dt} = Q_{co,s-1} + Q_{inf} - Q_{co,c-\alpha}$$

dengan ρ_a menunjukkan densitas udara ($1,29 \text{ kg/m}^3$), C_{pa} adalah kapasitas panas udara ($1,0 \text{ JKg}^{-1}\text{K}^{-1}$), H adalah tinggi ruang udara dalam rumah kaca, dTi/dt adalah laju perubahan suhu udara terhadap waktu, $Q_{\{co,s-i\}}$ merupakan perpindahan panas konveksi dari tanah ke udara (Wm^{-2}), Q_{inf} adalah laju perpindahan panas akibat infiltrasi udara (Wm^{-2}), dan $Q_{co,c-a}$ adalah perpindahan panas konveksi dari penutup rumah kaca ke udara sekitar (Wm^{-2}). Keseimbangan ini menjelaskan interaksi berbagai komponen energi di dalam rumah kaca, yang relevan untuk mengoptimalkan pengendalian suhu dan efisiensi energi dalam sistem.

Pelepasan energi oleh kipas pembuangan, Q_{ef} memainkan peranan penting dalam menjaga keseimbangan termodinamika. Energi yang dilepaskan oleh kipas terdiri dari dua komponen panas nyata (sensible heat) dan panas laten yang dapat dihitung menggunakan persamaan berikut :

$$Q_{ef} = Q_{si}Q_{Lt} = \frac{A_{ex}V_{gp}}{A}((T_i - T_o))C_p + (X_i - X_o)$$

A_{ex} mengindikasikan laju pertukaran udara per jam yang menggambarkan berapa kali volume udara di *greenhouse* yang berganti per jam sedangkan V_{gp} mengacu pada volume udara dalam *greenhouse* (m^3).

Perbedaan suhu yang terjadi di bagian dalam dan luar *greenhouse* (T_o) dan bagian dalam (T_i)nya serta perbedaan kandungan uap air di luar yaitu X_o dan dalam *greenhouse* yaitu X_i dapat juga mempengaruhi perpindahan energi dalam bentuk panas nyata dan panas laten. Parameter C_p menunjukkan kapasitas panas spesifik dari udara, yang menentukan jumlah energi yang diperlukan untuk menaikkan suhu per satuan massa udara.

Faktor konstanta-konstanta seperti ψ dan kecepatan angin v_ω digunakan untuk menghitung laju pertukaran udara A_{ex} . A_{ex} memegang peranan yang sangat penting dalam pengelolaan pertukaran panas karena angin dan faktor eksternal lainnya dapat mempengaruhi nilai pertukaran udara, sehingga pada akhirnya berpengaruh terhadap kondisi iklim mikro dalam *greenhouse*.

$$A_{ex} = \psi v_\omega + 0.25, h - 1$$

Keseimbangan energi yang dipancarkan oleh tanaman di dalam *greenhouse* Q_{pl} merupakan aspek kritis yang harus diperhatikan dalam pengelolaan lingkungan *greenhouse* secara keseluruhan. Keseimbangan ini ditentukan oleh pertukaran radiasi matahari dan aliran panas antara tanaman, penutup *greenhouse*, tanah dan udara sekitarnya.

$$Q_{pl} = -Q_{rd(pl-co)} - Q_{rd(pl-so)} - Q_{cv(pl)} - Q_{trans}$$

Parameter $Q_{rd(pl-co)}$ dan $Q_{rd(pl-so)}$ masing-masing mengukur pertukaran radiasi matahari antara tanaman dengan penutup *greenhouse* serta antara tanaman dengan tanah. Kedua proses ini cukup penting untuk memahami bagaimana tanaman menerima dan memancarkan energi radiasi. Di sisi lain $Q_{cv(pl)}$ menggambarkan aliran panas konversi dari tanaman ke udara di sekitarnya, yang berperan dalam pengelolaan suhu mikro di sekitar tanaman. Selain itu, Q_{trans} mengukur aliran panas yang terjadi di dalam *greenhouse* melalui berbagai mekanisme perpindahan panas, termasuk radiasi.

Pada sistem pembangkit listrik yang menggunakan tenaga surya berfungsi sebagai komponen utama yang mengkonversi radiasi matahari menjadi energi listrik. Tegangan dan arus yang dihasilkan oleh panel surya (fotovoltaik) sangat dipengaruhi oleh intensitas cahaya matahari serta faktor lingkungan lainnya seperti suhu lingkungan dan karakteristik material dari modul panel itu sendiri.

Dalam penerapan di lapangan, perhitungan energi dan keseimbangan termal di dalam *greenhouse* sangat penting untuk memastikan lingkungan yang mendukung pertumbuhan tanaman secara optimal. Sesuai dimensi *greenhouse* dalam penelitian ini dengan volume 56 m³, 275,52^oK adalah selisih suhu di dalam dan luar *greenhouse*, nilai standar kapasitas panas spesifik, C_p adalah 1005 J/kg.^oK, maka laju pertukaran udara, A_{ex} adalah 2,25 h⁻¹. Maka, pertukaran udara setiap jam akan menghasilkan aliran panas yang cukup signifikan dalam *greenhouse*.

Atap atau penutup *greenhouse* menerima energi radiasi matahari melalui permukaannya dengan nilai rata-rata 537W/m², dengan menganggap permukaan tersebut rata dengan luas 16 m² maka energi radiasi total yang diterima oleh atap adalah 8.592 W, dan energi yang dipancarkan oleh tanaman di dalam *greenhouse*, $Q_{rd(pl-so)}$ adalah 25% dari total radiasi yang diterima yaitu 2.148 W.

Pengelolaan iklim mikro ini melibatkan faktor-faktor seperti suhu udara, kelembapan dan aliran udara. Kipas pembuangan/exhaust harus diatur sedemikian rupa untuk membuang panas berlebih tanpa mengorbankan kelembapan yang dibutuhkan oleh tanaman, dengan laju pertukaran udara sebesar 2,25 kali per jam, maka kipas beroperasi pada kapasitas yang cukup untuk menjaga suhu optimal di dalam *greenhouse*.

Hasil eksperimen menunjukkan bahwa sistem pengendalian iklim mikro otomatis yang diterapkan di *greenhouse* berbasis agrivoltaik mampu menjaga suhu di dalam *greenhouse* pada kisaran optimal untuk pertumbuhan tanaman cabai, yaitu antara 25^o-30^oC. Hal ini dicapai melalui pengaturan otomatis yang mengandalkan sensor suhu dan kelembapan serta sistem IoT untuk mengaktifkan kipas pembuangan dan sistem fogging, terutama saat terjadinya lonjakan suhu akibat tingginya nilai radiasi matahari. Sistem ini terbukti efektif dalam merespon perubahan suhu eksternal, memungkinkan kegiatan dalam *greenhouse* berjalan dengan baik meskipun terjadi fluktuasi cuaca.

4.4.3 Analisis Penggunaan Energi Surya dalam *Greenhouse*

Berdasarkan hasil perhitungan, total kebutuhan energi harian dari sistem otomatis adalah 1992 Wh, yang merupakan gabungan dari daya yang dibutuhkan untuk mengoperasikan sensor dan perangkat aktuator. Kipas pembuangan menjadi salah satu beban terbesar, dengan daya konsumsi 150 W dn menyumbang sekitar 1200 Wh dari total kebutuhan energi harian. Selain itu pompa juga menambah beban sebesar 60 Wh. Beban-beban lainnya memiliki daya yang relatif lebih kecil, tetapi tetap memberikan kontribusi pada total konsumsi energi.

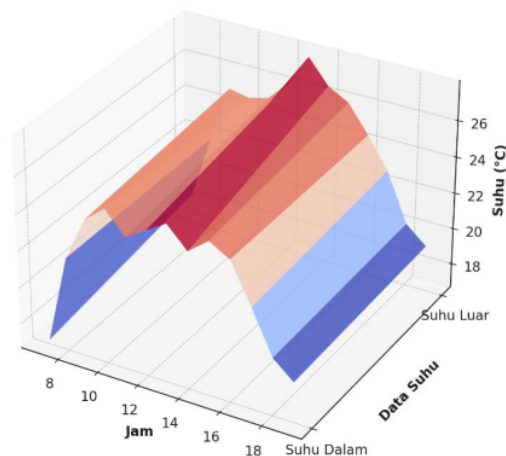
Dari perhitungan data, bahwa total energi yang dibutuhkan dari panel surya adalah 13280 Wh, dengan asumsi jam matahari efektif sebanyak 5 jam perhari, setiap panel surya berkapasitas 130 Wp dapat menghasilkan 650 Wh perhari. Dengan demikian, diperlukan 21 panel surya untuk memastikan suplai energi yang stabil dan memadai untuk sistem otomatisasi *greenhouse*.

Untuk memastikan bahwa energi yang disuplai oleh panel surya mencukupi, faktor efisiensi sistem perlu diperhitungkan. Dalam penelitian ini efisiensi panel surya diasumsikan sebesar 18% dan margin tambahan sebesar 20% untuk mengkompensasi kerugian energi akibat berbagai faktor eksternal, seperti debu, suhu tinggi atau inefisiensi dalam sistem konversi.

4.4.4 Model Pengendalian Suhu dan Kelembapan

Suhu dan kelembapan merupakan parameter kritis yang mempengaruhi fotosintesis dan pertumbuhan tanaman. Dalam model ini, pengendalian suhu dilakukan dengan memanfaatkan kipas pembuangan. Pengaktifan kipas ini bertujuan untuk melepaskan kelebihan panas dan kelembapan dari dalam *greenhouse*, yang dapat dihitung menggunakan nilai rata-rata suhu yang dihasilkan oleh sistem dalam penelitian ini adalah 28°C dengan fluktuasi minimum dan maksimum berada pada rentang 25^o-35^oC.

Dari data yang diambil selama pengujian selama 1 bulan, 95 % dari total waktu pengujian, suhu dalam *greenhouse* berada di dalam kisaran optimal yaitu 95% dari waktu operasi sistem, suhu terjaga dalam batas optimal untuk pertumbuhan cabai.



Gambar 32 Perbandingan Suhu Dalam dan Luar Greenhouse

Grafik pada gambar 31 menggambarkan hubungan antara suhu dalam dan luar *greenhouse* yang diambil pada tanggal 1 Januari 2024 memberikan wawasan penting yang relevan dengan kebutuhan pertumbuhan optimal tanaman cabai di daerah tropis. Fluktuasi suhu luar yang cukup signifikan terlihat dengan kenaikan suhu yang tajam pada pagi hari dan mencapai puncaknya antara pukul 09.00 WIB hingga 12.00 WIB, dapat mempengaruhi kondisi fisiologis tanaman jika tidak diatur dengan baik. Hal ini sangat penting karena tanaman cabai membutuhkan suhu optimal antara 20°C hingga 30°C untuk tumbuh dengan baik.

Suhu di luar *greenhouse* mulai menurun sementara suhu dalam *greenhouse* terlihat lebih stabil hingga mengalami sedikit penurunan setelah jam 16.00 WIB. Di akhir hari, sekitar jam 18.00 WIB hingga 19.00 suhu di dalam dan di luar *greenhouse* kembali mendekati nilai yang sama, menunjukkan proses pendinginan pada malam hari.

Suhu di atas 30°C, yang mungkin terjadi dalam iklim tropis pada siang hari dapat menyebabkan stres termal yang merugikan, seperti gangguan proses fotosintesis, peningkatan respirasi dan kegagalan pembentukan buah. Sebaliknya suhu dalam ruangan yang lebih stabil seperti yang terlihat pada grafik menunjukkan lingkungan yang lebih terkendali yang penting dalam budidaya cabai di lingkungan terkontrol yaitu dalam *greenhouse*.

Fenomena *thermal lag* yang terlihat pada grafik, dimana suhu dalam ruangan meningkat lebih lambat daripada suhu luar *greenhouse*. *Thermal lag* ini menunjukkan bahwa struktur bangunan *greenhouse* mampu menyerap panas dan melepaskannya secara bertahap, melindungi tanaman dari perubahan suhu yang terjadi secara tiba-tiba.

Secara keseluruhan, stabilitas suhu dalam ruangan yang ditunjukkan pada gambar 30 membuktikan bahwa pengelolaan suhu yang tepat dapat mengurangi dampak fluktuasi suhu luar. Menjaga suhu tetap dalam kisaran optimal antara 20°C dan 30°C sangat penting untuk mengoptimalkan pertumbuhan cabai, terutama di wilayah tropis yang rentan terhadap perubahan suhu ekstrim.

Data sensor kelembapan tanah menunjukkan bahwa kadar kelembapan tanah rata-rata dipertahankan pada nilai 65% yang berada dalam rentang ideal kelembapan tanah untuk tanaman cabai (sekitar 60-80%). Penggunaan air per hari dalam kegiatan ini adalah 50 liter perhari dengan penghematan 20% dibanding dengan metode irigasi manual yang rata-rata membutuhkan 62,5 liter per hari. Penghematan ini berkat sistem irigasi berbasis sensor yang menyiram tanah hanya ketika kadar kelembapan tanah turun di bawah 60%.

Pada kegiatan irigasi otomatis ini, sistem irigasi aktif selama 12 % dari total waktu operasi *greenhouse*, memastikan bahwa air diberikan secara efisien sesuai kebutuhan tanaman cabai.

Gambar 32 menunjukkan respon sistem terhadap perubahan kelembapan tanah yang diukur pada berbagai waktu. Data ini digunakan untuk mengendalikan pengoperasian pompa secara otomatis berdasarkan kategori kelembapan tanah yang terdeteksi. Data ini menunjukkan nilai rata-rata yang diukur pada interval waktu tertentu

sepanjang hari. Pengukuran kelembapan tanah dilakukan di beberapa waktu yang berbeda dari pukul 08.00 WIB hingga 19.00 WIB.

Tujuan dari analisis ini adalah untuk mengevaluasi kinerja sistem penyiraman otomatis berbasis energi surya dalam kondisi optimal untuk pertumbuhan tanaman, serta mempelajari hubungan antara parameter lingkungan atau iklim mikro yaitu kelembapan udara dan suhu dan sistem penyiraman yang diaktifkan berdasarkan kelembapan tanah.

Selama periode pengamatan satu bulan, kelembapan tanah menunjukkan variasi yang konsisten sepanjang hari, dengan nilai terendah tercatat pada pukul 09.00 WIB sebesar 35,6% yang menghasilkan kategori tanah kering dan memicu aktivitas pompa penyiraman secara otomatis. Sistem ini memastikan bahwa ambang batas kritis, pompa penyiraman segera diaktifkan untuk menjaga tanah tetap lembab. Setelah kelembapan tanah kembali ke level yang optimal, yaitu diatas 50 %, sistem penyiraman akan dihentikan.

Data-data menunjukkan bahwa pada sebagian besar waktu antara 08.00 WIB hingga 19.00 WIB, kelembapan tanah berada dalam kategori lembab atau basah, kecuali pada rentang waktu 09.00 WIB dan 15.00 WIB, dimana kondisi tanah dikategorikan sebagai kering, dengan nilai kelembapan turun hingga di bawah 40%. Hal ini menunjukkan bahwa sistem bekerja efektif dalam mendeteksi perubahan kondisi tanah dan menjaga kelembapan dalam kisaran yang diinginkan.

Suhu lingkungan berkisar antara 16°C pada pagi hari hingga mencapai puncaknya pada 27°C pada pukul 14.00 WIB. Kenaikan suhu ini meningkatkan laju penguapan dari permukaan tanah, yang menyebabkan penurunan kelembapan tanah, terutama pada siang hari. Misalnya pada pukul 15.00 WIB, suhu lingkungan tercatat sebesar 26°C dengan kelembapan tanah yang menurun hingga 39,7%, memicu aktivitas pompa penyiraman untuk mengembalikan tanah ke kondisi optimal.

Hal ini menunjukkan bahwa suhu lingkungan yang tinggi selama siang hari berpengaruh signifikan terhadap penurunan kelembapan tanah dan sistem otomatisasi penyiraman berfungsi untuk mengatasi kondisi ini.


Kelembapan tanah kembali meningkat setelah penyiraman otomatis aktif, yang dapat dilihat dari kenaikan nilai kelembapan tanah hingga 63,4% pada pukul 16.00 WIB yang kemudian menyebabkan pompa penyiraman dinonaktifkan.

Kelembapan udara, seperti yang tercatat, berfluktuasi antara 74% pada pagi hari hingga 26% pada malam hari. Penurunan kelembapan udara yang drastis, khususnya pada siang hari, mengakibatkan penguapan air yang lebih tinggi dari tanah. Pada siang hari, dengan suhu tinggi dan kelembapan udara yang rendah (sekitar 50 % hingga 59%), tanah *loss* lebih banyak air, menyebabkan penurunan kelembapan yang lebih cepat. Ini secara langsung berhubungan dengan frekuensi aktivasi sistem penyiraman otomatis pada periode tersebut.

Pada sore hari, kelembapan udara mulai meningkat, dan penguapan dari tanah menurun. Pada pukul 19.00 WIB, kelembapan udara tercatat sebesar 89% dan suhu lingkungan menurun hingga 18°C, yang menunjukkan berkurangnya kebutuhan penyiraman karena tanah dapat mempertahankan kelembapan yang cukup dengan kondisi lingkungan yang lebih dingin dan kelembapan udara yang lebih tinggi.

Berdasarkan data-data yang ada, sistem penyiraman otomatis ini terbukti bekerja efisien dalam menjaga kondisi tanah tetap optimal. Pompa penyiraman diaktifkan hanya ketika kondisi tanah diklasifikasikan sebagai kering, yaitu ketika kelembapan tanah turun di bawah 40%, seperti yang terlihat ⁸³ pada pukul 09.00 WIB dan 15.00 WIB. Pada waktu lainnya, sistem tetap off, yang menunjukkan bahwa tanah mencapai kelembapan yang cukup atau basah.

Efisiensi sistem ini tidak hanya terlihat dari aktivitas yang presisi berdasarkan nilai sensor kelembapan tanah, tetapi juga dari pengaturan penggunaan air yang tepat. Pompa penyiraman dan sprinkle hanya bekerja ketika diperlukan, yang mengoptimalkan penggunaan air dan mengurangi pemborosan.



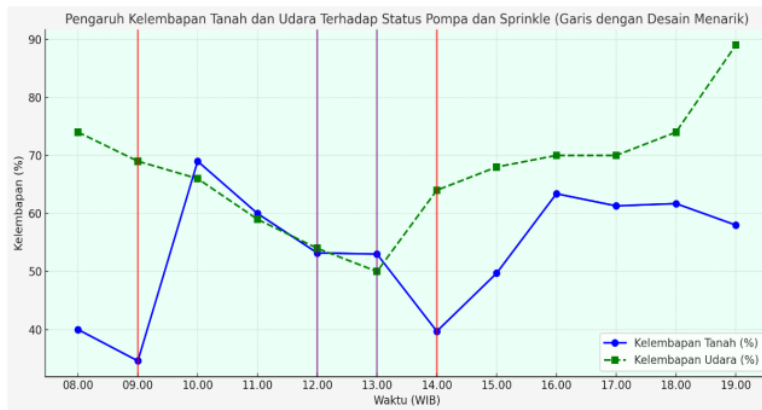
(a) Kelembapan Udara Rata-rata

(b). Kelembapan Tanah Rata-rata

Gambar 33 Variabel Lingkungan Mikro Rata-Rata Dalam 1 Minggu

4.4.5 Respon Pompa Terhadap Perubahan Kelembapan

Efek kelembapan pada iklim mikro, baik yang bersumber dari tanah maupun udara secara langsung mempengaruhi kondisi operasional pompa dalam sistem pertanian pintar di *greenhouse*. Berdasarkan grafik 32 yang menggabungkan kelembapan tanah dan kelembapan udara rata-rata, terdapat suatu hubungan antara tingkat kelembapan dan status pompa dan sprinkle berdasarkan waktu.



Gambar 34 Efek Kelembapan Iklim Mikro Rata-rata Terhadap Kondisi Pompa

Kelembapan tanah (ditampilkan dalam garis solid warna biru dengan lingkaran) dan kelembapan udara (ditampilkan dalam garis putus-putus warna hijau dengan kotak). Pompa dan sprinkle diwakili oleh garis vertikal merah dan ungu, yang menandakan kapan masing-masing diaktifkan.

a. Garis Biru (Kelembapan Tanah)

- Garis ini menunjukkan bagaimana kelembapan tanah berubah sepanjang hari, dari pukul 08.00 WIB hingga 19.00 WIB.
- Titik biru menunjukkan nilai kelembapan tanah pada titik waktu tertentu
- Kelembapan tanah mulai dari nilai rendah di sekitar 40 % pada pukul 08.00 WIB, lalu fluktuatif naik hingga mencapai puncak mendekati 70% pada pukul 10.00 WIB, sebelum menurun dan stabil antara 50%-60% pada sore hari.

b. Garis Hijau Putus-Putus (Kelembapan Udara)

- Garis ini menunjukkan perubahan kelembapan udara sepanjang hari.
- Tiik hijau menandakan nilai kelembapan udara pada setiap titik waktu
- Kelembapan udara dimulai pada level yang cukup tinggi (sekitar 70%) dan kemudian secara perlahan menurun hingga mencapai titik terendah sekitar 50% pada pukul 13.00 WIB, sebelum kembali naik secara signifikan pada sore hari hingga mencapai hampir 90% pada pukul 19.00 WIB.

c. Garis Vertikal Berwarna Merah dan Ungu

- Garis merah menandakan waktu ketika pompa diaktifkan. Pompa pertama kasli diaktifkan pada pukul 09.00 WIB saat kelembapan tanah rendah, lalu kembali aktif pada pukul 14.00 WIB saat kelembapan tanah menurun.
- Garis ungu menandakan waktu ketika sprinkle diaktifkan. Sprinkle diaktifkan dua kali, yaitu pada pukul 12.00 WIB dan 13.00 WIB, ketika kelembapan tanah mulai menurun dan kelembapan udara juga berada pada titik terendah. Mulai pukul 08.00 Wib hingga pukul 10.00 WIB, kelembapan tanah meningkat secara signifikan setelah aktivasi pompa pertama. Ini menunjukkan bahwa pompa berfungsi untuk menambah air ke tanah. Kelembapan udara berkurang secara bertahap dari pukul 08.00 WIB hingga mencapai titik terendah pada pukul 13.00 WIB. Hal ini terjadi disebabkan oleh proses penguapan air atau kondisi cuaca yang kering.

Pompa diaktifkan pada pukul 09.00 WIB ketika kelembapan tanah rendah (35 %) dan setelah aktivasi, kelembapan tanah ⁸⁹meningkat secara signifikan hingga mencapai puncaknya pada pukul 10.00 WIB (70 %).

Sprinkle diaktifkan ⁸⁰pada pukul 12.00 WIB dan 13.00 WIB. Kedua aktivasi ini terjadi karena kelembapan udara berada pada titik terendah, meskipun kelembapan tanah belum terlalu rendah. Hal ini menunjukkan bahwa sprinkle diaktifkan untuk menambah kelembapan udara dalam kondisi kering.

Pompa lebih cenderung diaktifkan ketika kelembapan tanah mencapai titik rendah tertentu. Sprinkle diaktifkan dalam situasi dimana kelembapan udara menurun secara drastis, terlepas dari kelembapan tanah. Ini menunjukkan bahwa kelembapan udara juga mempengaruhi strategi irigasi.

Sistem penyiraman otomatis tampaknya berfungsi dengan baik, memicu pompa hanya ketika kelembapan tanah mencapai titik kritis (kategori *Kering*). Dengan adanya lonjakan kelembapan tanah setelah penyiraman, sistem berhasil mengembalikan tanah ke kondisi yang lebih optimal untuk tanaman (*Basah*). Hal ini menunjukkan bahwa sistem penyiraman otomatis dapat meminimalisasi penggunaan air secara berlebih, karena hanya diaktifkan saat kelembapan mencapai ambang batas yang rendah, yaitu sekitar 40%.

4.4.6 Publikasi

Hasil penelitian yang dilakukan terkait implementasi pertanian digital berbasis tenaga surya dan sistem *greenhouse* pintar berbasis IoT yang ada di Palembang, Sumatera Selatan, telah dipublikasikan dalam seminar dan jurnal internasional. ¹⁸Penelitian ini berfokus pada penerapan sistem agrivoltaik dan IoT untuk meningkatkan efisiensi energi, sumber daya dan hasil pertanian di wilayah tropis.

Hasil penelitian ini telah dipresentasikan dan dipublish pada :

- 1) **Solar Power Greenhouse for Smart Agriculture** yang telah dipresentasikan pada **International Conference on Electrical (IEIT) 2023** pada tanggal 14-15 September 2023 di Malang dan dipublikasikan di IEEE Publisher pada tanggal 6 Desember 2023. (sertifikat dan karya tulis terlampir). Penelitian ini membahas penggunaan sistem pemantauan berbasis IoT dan model kontrol iklim mikro untuk meningkatkan hasil tanaman dalam lingkungan *greenhouse*.

¹¹ Y. Oktarina, Z. Nawawi, B. Y. Suprpto and T. Dewi, "Solar Powered Greenhouse for Smart Agriculture," ²⁷ 2023 International Conference on Electrical and Information Technology (IEIT), Malang, Indonesia, 2023, pp. 36-42, doi:10.1109/IEIT59852.2023.10335599.

<https://ieeexplore.ieee.org/abstract/document/10335599>

- ³¹ 2) **Digitized Smart Solar Power Agriculture Implementation in Palembang, Sumatera Selatan** yang telah dipresentasikan pada seminar internasional **Electrical Engineering, Computer Science, and Informatics (EECSI) 2023** pada tanggal ³³ 20-21 September 2023 di Palembang dan telah dipublikasikan di IEEE Publisher pada 31 Oktober 2023 (sertifikat dan karya tulis terlampir). Penelitian ini menguraikan tentang data iradian matahari dan hasil implementasi sistem irigasi otomatis berbasis sensor di dalam *greenhouse*.

¹¹ Oktarina, Y., Nawawi, Z., Suprpto, B. Y., & Dewi, T. (2023, September). *Digitized Smart Solar Powered Agriculture Implementation in Palembang, South Sumatra. In 2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI) (pp. 60-65). IEEE.*

⁴⁴ doi:10.1109/EECSI59885.2023.10295805

<https://ieeexplore.ieee.org/abstract/document/10295805>

- 3) **Towards Ecological Sustainability: Harvest Prediction In Agrivoltaic Chili Farming With CNN Transfer Learning** yang telah dipublish pada jurnal **Iraqi Journal Of Agricultural Sciences (IJAS)** ⁹² University of Baghdad.

⁴⁴ <https://orcid.org/0000-0002-5774-5906>

Semua publikasi tersebut tidak hanya menghasilkan gambaran mengenai potensi penggunaan energi surya dalam mendukung pertanian berkelanjutan, tetapi juga mampu menunjukkan tantangan dan solusi yang bersifat teknis yang muncul selama implementasi.

BAB V PREDIKSI ENERGI SURYA DENGAN PENDEKATAN LSTM-ANN

5.1 Prediksi Energi Surya

Urgensi pembahasan dalam bab ini adalah untuk menunjukkan bagaimana mengelola energi surya yang fluktuatif atau terputus-putus agar dapat memenuhi kebutuhan beban tetap secara efisien.

Seperti diketahui, bahwa sifat alami energi surya adalah jumlahnya yang berfluktuatif, karena bergantung pada intensitas cahaya matahari yang tidak selalu konsisten sepanjang hari. Faktor-faktor seperti kondisi cuaca, waktu dalam sehari, dan musim mempengaruhi jumlah energi yang dihasilkan oleh panel surya. Akibatnya, pasokan listrik dari panel surya dapat terputus-putus atau berfluktuasi, terutama selama malam hari atau saat langit berawan.

Namun di sisi lain, sistem membutuhkan pasokan energi yang stabil dan berkelanjutan untuk mendukung operasional perangkat-perangkat yang memerlukan listrik terus-menerus. Dalam *greenhouse* yang menjadi beban tetap ini adalah sensor-sensor, pompa air dan *exhaust fan* yang menerima listrik dengan daya konstan. Tantangannya adalah bagaimana cara mengelola energi surya yang fluktuatif tersebut agar dapat memenuhi kebutuhan beban tetap secara efisien dan andal.

Model prediksi yang akurat sangat penting untuk memperkirakan jumlah energi yang akan dihasilkan dalam periode waktu tertentu, mengingat faktor-faktor eksternal seperti cuaca dan intensitas radiasi matahari yang bersifat dinamis. Prediksi yang tepat memungkinkan pengelolaan sistem secara lebih efisien, terutama dalam penyesuaian strategi operasional yang optimal. Dengan menggunakan model yang akurat, dapat dihindari ketidakseimbangan antara suplai dan kebutuhan, serta membantu dalam pengambilan keputusan yang lebih baik terkait alokasi sumber daya dan perencanaan jangka panjang.

Model prediksi energi surya yang dikembangkan dalam penelitian ini menggabungkan dua pendekatan *deep learning* yaitu Long Short-Term Memory (LSTM) dan Artificial Neural Network (ANN). Model hybrid ini dirancang untuk mengatasi fluktuasi energi yang dihasilkan dari panel surya akibat perubahan cuaca yang tidak menentu serta variabilitas temporal. Pendekatan LSTM dipilih karena kemampuannya dalam menangkap pola temporal pada data deret waktu yang memiliki ketergantungan jangka panjang, sementara ANN digunakan untuk menangani hubungan non-linear yang

kompleks antara variabel input, seperti suhu, radiasi matahari, kelembaban, dan kecepatan angin, dengan output berupa prediksi energi surya yang dihasilkan.

Selain itu, penelitian ini memanfaatkan data historis dari output energi surya yang dihasilkan serta data cuaca yang relevan untuk membangun model prediksi yang lebih akurat. Tujuan utama dari penelitian ini adalah meningkatkan akurasi prediksi energi surya yang diperlukan untuk optimasi manajemen energi, serta mendukung implementasi sistem energi terbarukan yang lebih efisien dan andal. Dengan demikian, penelitian ini berkontribusi pada pemanfaatan teknologi kecerdasan buatan untuk aplikasi energi terbarukan, sekaligus memberikan solusi untuk meningkatkan stabilitas dan prediktabilitas sistem energi surya di berbagai kondisi cuaca.

Studi ini meneliti seberapa efektif model LSTM-ANN hybrid dalam memprediksi keluaran sistem PV dalam berbagai kondisi lingkungan. Model hybrid sangat cocok untuk mengatasi kompleksitas prediksi iradiasi matahari, karena menggabungkan kemampuan pemrosesan deret waktu LSTM dengan daya prediksi ANN untuk data nonlinier [16,21]. Lebih jauh, studi telah menunjukkan bahwa model hybrid mengungguli pendekatan model tunggal, yang mengarah pada peningkatan kinerja peramalan baik dalam prediksi jangka pendek maupun jangka panjang [20,25].

Tabel 3 Penyetelan Hyperparameter

Layer (tipe)	Bentuk Luaran	Param #
LSTM	(None, 64)	17,664
Dropout	(None, 64)	0
Dense	(None, 64)	4,160
Dropout_1	(None, 64)	0
Dense_1	(None, 64)	4,160
Dense_2	(None, 4)	260

Arsitektur model LSTM-ANN yang dipertimbangkan dalam penelitian ini memiliki 66 neuron dengan 500 epoch, dan penyetelan hiperparameter lengkap diberikan dalam tabel 3. Total parameter adalah 26.244 (102,52 KB), parameter latihan adalah 26.244 (102,52 KB), dan parameter yang tidak dapat dilatih adalah 0. Tabel 3 memberikan rincian yang lengkap tentang lapisan-lapisan dalam model hybrid LSTM-ANN yang menunjukkan kompleksitas dan fungsionalitas arsitektur tersebut.

Lapisan pertama, yaitu LSTM, memiliki bentuk output [None, 64], yang menunjukkan bahwa lapisan ini menghasilkan urutan dengan 64 unit. Lapisan ini mengandung 17.664 parameter yang dapat dilatih, yang menyoroti perannya dalam mempelajari ketergantungan temporal dari data deret waktu yang diinput. Setelah LSTM, dua lapisan dropout diperkenalkan untuk mencegah overfitting dengan secara acak menonaktifkan unit-unit selama pelatihan. Lapisan-lapisan dropout ini memiliki bentuk output [None, 64], tetapi tidak menambah parameter yang dapat dilatih.

Model ini juga mencakup tiga lapisan dense (fully connected). Dua lapisan dense pertama, masing-masing dengan bentuk output [None, 64], mengandung 4.160 parameter yang dapat dilatih pada setiap lapisan. Lapisan-lapisan ini lebih lanjut menyempurnakan output dengan menangkap pola kompleks melalui pemetaan non-linear. Lapisan dense terakhir, dengan bentuk output [None, 4], memiliki 260 parameter yang dapat dilatih dan bertanggung jawab untuk menghasilkan prediksi model pada empat output—tegangan, arus, daya, dan iradiasi.

Secara keseluruhan, arsitektur ini menyeimbangkan penggunaan LSTM untuk ekstraksi fitur temporal dan lapisan dense untuk pemrosesan non linear, dengan lapisan dropout yang memastikan kekuatan model dengan mengurangi overfitting. Jumlah total parameter mencerminkan model yang dirancang untuk menangkap baik hubungan berurutan maupun non linear yang ada dalam dataset energi surya.


Lapisan input adalah data deret waktu untuk memprediksi keluaran sistem PV (tegangan, arus, dan daya) serta data iradiasi surya. Data tersebut direkam oleh pengukur iradiasi surya serta sensor tegangan dan arus yang dipasang di rumah kaca seperti yang ditunjukkan pada gambar 5.2. Lapisan ini memproses data deret waktu untuk menangkap ketergantungan jangka panjang antara pola iradiasi surya di masa lalu dan kondisi meteorologi. Komponen ANN terdiri dari 64 neuron dan menggunakan fungsi aktivasi ReLu (rectified linear unit).

5.2 Data Collection

Data yang digunakan dalam penelitian ini dikumpulkan dari sistem photovoltaic (PV) yang terpasang di dalam greenhouse bertenaga surya yang berlokasi di Talang Kemang, Gandus, Palembang, Indonesia (Latitude: -2.990934; Longitude: 104.756554). Dataset ini terdiri dari beberapa parameter penting yang berhubungan dengan energi surya, seperti:

- Irradiasi matahari (solar irradiance): data mengenai radiasi matahari yang diterima pada permukaan panel surya.
- Voltase (Voltage): tegangan listrik yang dihasilkan oleh panel surya.
- Arus (Current): aliran listrik yang dihasilkan.
- Daya (Power): jumlah energi listrik yang dihasilkan oleh sistem PV.

Sistem pemantauan untuk mengukur kurva I-V dari susunan PV dan parameter lingkungan waktu nyata ditunjukkan pada Gambar 33. Dengan memanfaatkan kekuatan model LSTM dan ANN, penelitian ini memajukan penciptaan alat yang lebih canggih untuk memprediksi energi surya, yang dapat secara signifikan meningkatkan keandalan sistem energi terbarukan dan mendukung integrasinya yang lancar ke dalam infrastruktur energi saat ini [11,12]. Hasilnya memberikan perspektif baru tentang teknik pembelajaran mesin hibrida untuk peramalan energi terbarukan, memberikan kontribusi yang berarti bagi upaya yang lebih luas yang bertujuan untuk meningkatkan keberlanjutan energi [14,23].



Gambar 35 Pengaturan Percobaan Untuk Prediksi Daya PV

Data ini dikumpulkan selama periode 7 hari, dari tanggal 22 hingga tanggal 29 Juli 2024, menggunakan perangkat pengukur seperti SPM-11165SD untuk irradiasi matahari dan sensor tegangan serta arus yang dipasang pada PV di greenhouse.

5.3 Preprocessing Data

Pada penelitian ini, langkah-langkah preprocessing data dilakukan untuk mengoptimalkan dataset sebelum digunakan dan memastikan bahwa dataset siap digunakan dalam proses pelatihan dan pengujian model prediksi energi surya. Proses preprocessing ini melibatkan dua tahap utama, yaitu normalisasi fitur dan pembagian data.

1) Normalisasi fitur:

Dalam langkah ini, data dinormalisasi menggunakan teknik MinMax Scaler seluruh fitur dipetakan dalam rentang nilai [0,1]. Langkah normalisasi ini dilakukan untuk memastikan bahwa setiap fitur memiliki peran yang setara dalam proses pelatihan model. Skala yang digunakan adalah antara 0 dan 1, yang bertujuan untuk menghindari dominasi satu fitur terhadap fitur lainnya selama proses pelatihan model.

Misalnya, fitur-fitur yang memiliki skala lebih besar, seperti tegangan atau arus listrik, dapat mendominasi proses pembelajaran jika tidak dinormalisasi. Dengan melakukan normalisasi, seluruh fitur mendapatkan bobot yang seimbang, yang memungkinkan model mempelajari pola yang lebih representatif dari keseluruhan dataset

2) Pembagian Data

Dataset dibagi menjadi 50% data pelatihan dan 50% data pengujian. Pemilihan pembagian 50/50 ini dilakukan untuk memastikan bahwa kedua set data (pelatihan dan pengujian) mencakup fluktuasi cuaca yang cukup beragam, sehingga evaluasi performa model menjadi lebih akurat. Pembagian ini dipilih karena ukuran dataset yang terbatas.

Dengan membagi data seperti ini, model dapat diuji pada berbagai skenario cuaca dan variabilitas input, sehingga kinerja prediksi yang dihasilkan lebih akurat dan tidak overfitting pada pelatihan saja. Pembagian dataset ini mempertimbangkan kebutuhan untuk mempelajari pola jangka panjang sekaligus memvalidasi model pada skenario cuaca yang lebih luas.

Normalisasi fitur dan pembagian data merupakan langkah krusial yang mendukung proses pelatihan model LSTM-ANN agar menghasilkan prediksi yang akurat dan efisien dalam memproses data energi surya.

5.4 Arsitektur Model LSTM-ANN

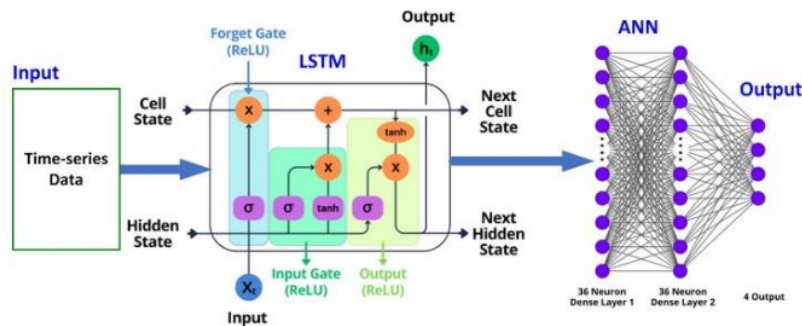
Model yang digunakan dalam penelitian ini merupakan gabungan dari LSTM dan ANN. Arsitektur model hybrid ini mengkombinasikan Long Short-Term Memory (LSTM) untuk menangkap pola temporal pada data deret waktu (time series) seperti fluktuasi irradiansi dan kondisi cuaca, serta Artificial Neural Network (ANN) untuk memodelkan hubungan non-linear antara variabel input dan output seperti terlihat pada gambar 35.

1) LSTM Layer

Memiliki 64 unit dengan tiga gate utama (forget gate, input gate, output gate), yang dirancang untuk menangkap pola temporal dalam data deret waktu (*time series*). LSTM memiliki kemampuan jangka panjang pada data, yang sangat penting dalam memprediksi energi surya dimana pola energi yang dihasilkan sangat dipengaruhi oleh kondisi cuaca yang bersifat dinamis dan berubah-ubah dari waktu ke waktu. LSTM dilengkapi dengan mekanisme gate seperti forget gate, input gate, dan output gate, yang berfungsi untuk mengelola informasi mana yang disimpan, diperbarui, atau dilupakan selama proses pelatihan model.

2) ANN Layer

Lapisan ANN terdiri dari beberapa lapisan dense yang bertujuan untuk memproses lebih lanjut output dari LSTM, dengan 36 neuron pada setiap lapisan. ANN ini berfungsi untuk menangani hubungan non-linear antara variabel input dan output. Dalam konteks penelitian ini, ANN berfungsi memproses data yang telah diolah oleh LSTM untuk menghasilkan prediksi yang lebih presisi terkait energi surya yang dihasilkan berdasarkan data cuaca dan parameter-parameter terkait lainnya.



Gambar 36 Arsitektur model LSTM-ANN diterapkan dalam penelitian ini.

Seperti terlihat pada gambar 35, studi ini mengeksplorasi peramalan energi surya dengan menggunakan pendekatan hibrida yang menggabungkan teknik LSTM dan ANN. Jaringan LSTM digunakan untuk menangkap pola yang bergantung pada waktu dalam data, seperti fluktuasi iradiasi surya dan kondisi cuaca, sementara komponen ANN berfokus pada pemodelan hubungan nonlinier yang kompleks antara variabel masukan dan keluaran yang diprediksi.

Model hybrid yang diilustrasikan dalam Gambar 34 dibangun berdasarkan penelitian sebelumnya yang menunjukkan manfaat menggabungkan LSTM dengan jaringan saraf lain untuk meningkatkan prediksi energi surya [4,5]. **IJRVOCAS** Model ini menggabungkan komponen Memori Jangka Panjang dan Jangka Pendek (LSTM) dan Jaringan Saraf Buatan (ANN) untuk memprediksi keluaran sistem fotovoltaik (PV) secara akurat. Dirancang untuk data deret waktu seperti tegangan, arus, daya, dan iradiasi surya, arsitektur ini bergantung pada lapisan LSTM untuk menangkap ketergantungan temporal, diikuti oleh lapisan ANN yang menyempurnakan data untuk menghasilkan prediksi keluaran yang tepat.

5.5 Model Training

Untuk pelatihan model menggunakan Adam Optimizer yang diketahui memiliki kemampuan mempercepat konvergensi model dan menyeimbangkan kecepatan pelatihan dengan menetapkan learning rate awal sebesar 0.001 yang merupakan nilai standar untuk menjaga stabilitas pembelajaran model tanpa terlalu cepat atau terlalu lambat dalam mengurangi loss. sebagai fungsi loss untuk mengukur kesalahan prediksi selama pelatihan. Dataset yang sudah dinormalisasi dimasukkan ke dalam model hybrid LSTM-

ANN, di mana arsitektur ini dirancang untuk menangkap pola temporal dari data iradiasi surya serta mengolah hubungan non-linear dari data input menjadi prediksi keluaran yang lebih akurat.

Model ini dilatih menggunakan Mean Squared Error (MSE) sebagai fungsi loss, yang bertujuan untuk meminimalkan kesalahan antara prediksi model dan data aktual. MSE dipilih karena fungsinya yang menghitung rata-rata kuadrat dari perbedaan antara nilai prediksi dan nilai aktual, sehingga memberikan penalti yang lebih besar untuk kesalahan yang lebih besar. Konfigurasi ini secara keseluruhan dioptimalkan untuk menangkap pola temporal dan non-linear yang terdapat dalam data prediksi energi surya, sehingga model dapat mempelajari dan memprediksi jumlah energi surya yang dihasilkan secara lebih akurat dan efisien.

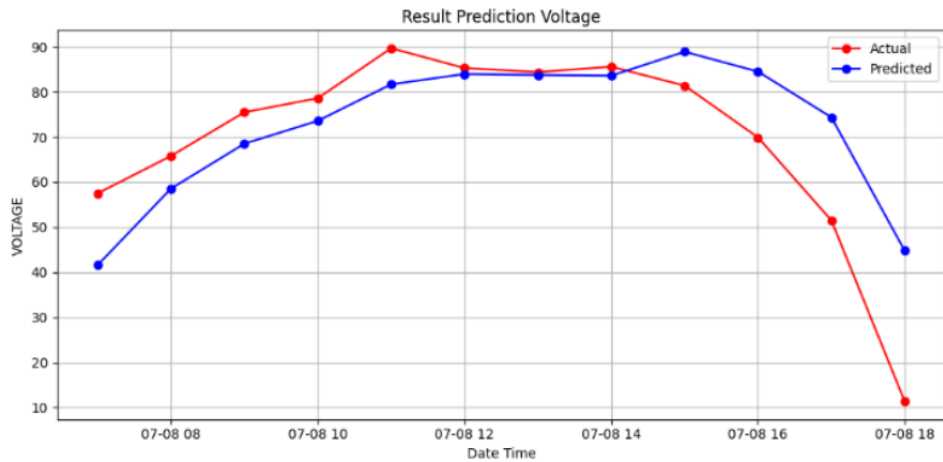
5.6 Hasil Pelatihan dan Model

Bagian ini menjelaskan hasil model *hybrid* LSTM-ANN dalam memprediksi keluaran energi sistem fotovoltaik (PV), dengan fokus pada kinerjanya dibandingkan dengan model individual. Analisis ini menyoroti potensi dampak terhadap konversi energi dalam sistem PV. Arsitektur model mencakup ANN dengan max-pooling, lapisan LSTM, dan lapisan fully connected (dense). Model ini dikembangkan menggunakan pustaka Keras dan TensorFlow di Python, dengan semua perhitungan dilakukan di Google Colab untuk meningkatkan efisiensi komputasi.

5.6.1 Prediksi Pada Data Uji

Hasil prediksi model untuk beberapa parameter utama, yaitu dataset yang berisi data iradiasi, tegangan (volt), arus (ampere), dan daya (power) dibagi menjadi dua bagian: 50% untuk pelatihan dan 50% untuk pengujian. Gambar 36, 37, 38 dan 39 menampilkan prediksi keluaran PV (tegangan, arus, dan daya) serta prediksi iradiasi.

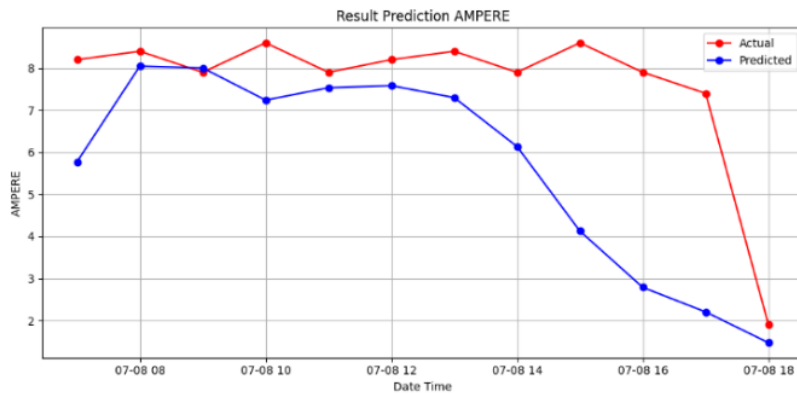
Gambar 36, 37, 38 dan 39 menggambarkan perbandingan antara nilai aktual dan nilai prediksi untuk empat parameter: tegangan, arus (dalam ampere), daya, dan iradiasi, yang diambil selama 8 Juli 2024, dari pukul 07:00 hingga 18:00.



Gambar 37 Nilai Tegangan yang diprediksi (Volt) menggunakan LSTM-ANN


Gambar 36-39 memberikan dasar untuk menilai efektivitas model dalam memprediksi keluaran energi sistem fotovoltaik (PV), memberikan wawasan tentang akurasi di berbagai parameter.

- a. Tegangan (Volt): Tren tegangan aktual dan prediksi menunjukkan pola yang serupa seperti yang ditunjukkan pada Gambar 35, dengan keduanya mencapai puncaknya antara pukul 11:00 WIB dan 14:00 WIB. Namun, nilai prediksi secara konsisten berada di bawah pengukuran aktual, terutama setelah pukul 14:00 WIB, di mana nilai prediksi mengalami penurunan nilai tegangan. Secara umum, model mengikuti tren tegangan secara keseluruhan tetapi cenderung dibawah nilai prediksi sepanjang hari, terutama pada sore hari.
- b. Arus (Ampere): Arus aktual dan prediksi menunjukkan keselarasan yang lebih dekat di awal hari, tetapi perbedaan yang signifikan muncul seiring berjalannya waktu (ditunjukkan pada Gambar 36). Nilai arus yang diprediksi umumnya lebih rendah dari nilai aktual, terutama setelah pukul 14:00 WIB. Arus aktual tetap relatif stabil di sekitar 8 ampere saat tengah hari, sedangkan nilai prediksi secara konsisten dibawah nilai prediksi, terutama pada sore hari ketika arus turun tajam setelah pukul 16:00 WIB.

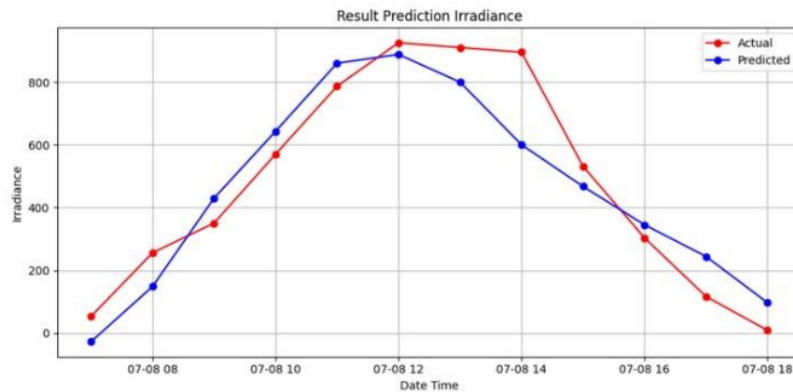


Gambar 38 Nilai Arus yang diprediksi (Ampere) menggunakan LSTM-ANN.

- c. Daya (Watt): Prediksi daya menunjukkan tren yang serupa dengan tegangan dan arus dalam Gambar 38. Daya aktual mencapai puncaknya antara pukul 11:00 WIB dan 14:00 WIB, tetapi nilai prediksi secara signifikan lebih rendah sepanjang hari. Perbedaan ini menjadi lebih jelas pada sore hari (setelah pukul 14:00 WIB) ketika prediksi daya turun lebih cepat dibandingkan dengan nilai aktual. Model ini menangkap siklus keseluruhan pembangkitan daya, tetapi secara konsisten memprediksi lebih rendah, terutama selama jam puncak dan sore hari.



Gambar 39 Daya yang diprediksi (Watt) menggunakan LSTM-ANN.



Gambar 40 Prediksi iradiasi menggunakan LSTM-ANN

- d. Iradiasi (W/m^2): Grafik iradiasi juga mengikuti pola yang serupa dengan daya dan tegangan (ditunjukkan pada Gambar 39). Iradiasi aktual mencapai puncaknya sekitar tengah hari, sementara model *underestimates* nilainya terjadi sepanjang hari. Perbedaan antara iradiasi aktual dan prediksi meningkat selama periode puncak iradiasi dan tetap signifikan hingga sore hari. Meskipun model menangkap tren keseluruhan, model ini kesulitan untuk memprediksi nilai iradiasi secara akurat pada level yang lebih tinggi dan selama fase penurunan di sore hari.

Dalam hal prediksi daya, model mengikuti keluaran daya aktual dengan baik, menunjukkan bahwa model ini efektif dalam menangani fluktuasi energi surya. Prediksi iradiasi juga cukup selaras dengan data aktual, meskipun ada sedikit variasi yang menunjukkan bahwa memasukkan fitur yang lebih rinci dapat lebih meningkatkan kinerja model. Secara keseluruhan, model hybrid ini menunjukkan akurasi yang kuat di semua parameter, dengan hanya sedikit variasi yang dapat diatasi melalui penyempurnaan lebih lanjut.

Hasil prediksi untuk variabel energi surya adalah sebagai berikut:

1) Tegangan (Volt):

- Nilai Puncak Aktual: Sekitar 90 V pada pukul 12:00.
- Nilai Puncak Prediksi: Sekitar 80 V pada pukul 12:00.
- Akurasi: Prediksi tegangan cukup akurat selama pagi dan siang hari. Kurva prediksi mengikuti tegangan aktual dengan baik, dengan kesalahan terbesar

terjadi pada akhir hari ketika nilai prediksi meremehkan tegangan aktual sekitar 10-20 V. Ini dianggap sebagai salah satu prediksi yang lebih akurat.

2) Arus (Ampere):


- Nilai Puncak Aktual: 8 A antara pukul 09:00 dan 15:00.
- Nilai Puncak Prediksi: Sekitar 6,5 A pada periode yang sama.
- Akurasi: Arus yang diprediksi secara signifikan lebih rendah dari arus aktual, terutama selama jam puncak, dengan kesalahan sekitar 1,5-2 A pada siang hari. Setelah pukul 15:00 WIB, prediksi menyimpang tajam dari nilai aktual, di bawah nilai prediksi penurunan arus. Parameter ini menunjukkan tingkat ketidakakuratan yang tinggi, terutama pada sore hari.

3) Daya (Watt):

- Nilai Puncak Aktual: Sekitar 700 W pada tengah hari.
- Nilai Puncak Prediksi: Sekitar 600 W pada waktu yang sama.
- Akurasi: Model meremehkan keluaran daya sekitar 100 W selama puncak tengah hari. Prediksi daya juga menurun lebih cepat daripada daya aktual di sore hari. Tren keseluruhan ditangkap dengan baik, tetapi ini masih merupakan prediksi yang kurang akurat dibandingkan tegangan.

4) Iradiasi (W/m^2):

- Nilai Puncak Aktual: Mendekati $900 W/m^2$ pada tengah hari.
- Nilai Puncak Prediksi: Sekitar $800 W/m^2$.
- Akurasi: Prediksi iradiasi relatif akurat di pagi hari, dengan perbedaan sekitar $100 W/m^2$ selama jam puncak. Model mengikuti tren keseluruhan tetapi gagal menangkap besaran iradiasi selama periode puncak dan sore hari. Prediksi ini cukup akurat, meskipun masih ada ruang untuk perbaikan.



Gambar 41 Training and validation loss LSTM-ANN.

5.6.2 Evaluasi Kinerja Model

Kurva *training dan validasi loss* dalam Gambar 40 memberikan informasi penting tentang proses pembelajaran model untuk 500 epoch. Pada awalnya, kedua nilai *loss* cukup tinggi, menunjukkan bahwa prediksi awal model menunjukkan kesalahan yang signifikan dibandingkan dengan nilai aktual. Namun, seiring berjalannya *training*, terjadi penurunan tajam pada *loss*, terutama selama 50 epoch pertama. Penurunan tajam ini menunjukkan bahwa model secara efektif mempelajari dan beradaptasi dengan fitur dan pola utama dalam data, yang menyebabkan peningkatan akurasi prediksi seiring waktu.

Setelah sekitar 50 epoch, *training loss* dan validasi mencapai tingkat yang lebih rendah, menunjukkan bahwa model telah secara efektif mempelajari pola utama dalam data. *Training Loss* terus menurun sedikit, sementara *validation loss* mengalami fluktuasi kecil di sekitar titik stabil. Fluktuasi ini umum terjadi ketika model diuji dengan data baru yang belum pernah dilihat, yang menggambarkan tantangan dalam memastikan generalisasi yang konsisten di berbagai dataset. Pola ini menunjukkan bahwa model telah berhasil belajar tetapi mengalami kesulitan umum dalam menangani data baru selama validasi.

Menjelang akhir proses *training*, *training loss* menjadi sangat rendah, hampir mencapai nol, menunjukkan bahwa model telah mempelajari data pelatihan dengan sangat baik. Meskipun *validation loss* sedikit lebih tinggi daripada nilai *training loss*, keduanya tetap dekat, tanpa celah yang signifikan di antara mereka. Perbedaan kecil ini

menunjukkan bahwa model tidak mengalami *overfitting* dan telah mencapai keseimbangan yang baik antara pencocokan data pelatihan dan kemampuannya untuk digeneralisasi pada data validasi baru yang belum pernah dilihat.

Secara keseluruhan, hasilnya menunjukkan bahwa model berkinerja baik, mencapai nilai *loss* akhir yang rendah baik dalam dataset pelatihan maupun validasi. Perbedaan kecil antara kedua kurva *loss* menunjukkan bahwa model telah digeneralisasi dengan efektif, mempertahankan kinerja yang konsisten saat diterapkan pada dataset yang berbeda.

Tabel 4 Model kinerja LSTM-ANN

Metric	Tegangan	Arus	Daya	Iradiasi
MAE	0,1016	0,1971	0,1506	0,0895
MSE	0,0201	0,0832	0,0382	0,0132
RMSE	0,1417	0,2884	0,1954	0,1149
R ²	0,9799	0,9618	0,9168	0,9868

Metrik kinerja yang dijelaskan dalam Tabel 4 menunjukkan efektivitas model LSTM-ANN dalam berbagai tugas prediksi energi. Akurasi model dinilai menggunakan tiga metrik utama: Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE). Hasilnya memberikan gambaran rinci tentang kinerja model, yang dibandingkan dengan temuan dari studi lain. Perbandingan ini menunjukkan bahwa model *hybrid* berkinerja efisien, memberikan prediksi energi yang andal dan akurat ketika diukur dengan pendekatan serupa dalam literatur.

1. **Tegangan:**

- MAE: 0,1016, MSE: 0,0201, RMSE: 0,1417, R²: 0,9799
- Prediksi tegangan menunjukkan tingkat kesalahan terendah di semua metrik. Ini menunjukkan bahwa model berkinerja terbaik dalam prediksi tegangan. Dibandingkan dengan studi serupa seperti yang dilakukan oleh Tufail et al. pada 2023 untuk memprediksi konsumsi energi, kesalahan ini tergolong rendah, mencerminkan tingginya akurasi model dalam prakiraan tegangan [28].

2. **Arus:**

- MAE: 0,1971, MSE: 0,0832, RMSE: 0,2884, R²: 0,9618

- Prediksi arus memiliki nilai kesalahan tertinggi, menunjukkan bahwa model paling kesulitan dalam aspek ini. Hal ini sesuai dengan temuan dari model lain seperti Phan et al. pada 2022 [20], di mana arus atau aliran daya sering kali lebih menantang bagi model prediktif karena sifatnya yang volatil selama beban puncak.

3. Daya:

- **MAE: 0,1506, MSE: 0,0382, RMSE: 0,1954, R²: 0,9168**
- Prediksi daya, meskipun tidak seakurat tegangan, menunjukkan kesalahan moderat dengan RMSE sebesar 0,1954. Ini sebanding dengan hasil yang diperoleh oleh Zafar et al. pada 2022 dalam model autoencoder LSTM *hybrid* untuk prediksi daya, di mana mereka mengamati nilai RMSE yang sedikit lebih tinggi [30].

4. Iradiasi:

- **MAE: 0,0895, MSE: 0,0132, RMSE: 0,1149, R²: 0,9868**
- Prediksi iradiasi model menunjukkan akurasi yang sangat baik, dengan MAE sebesar 0,0895 dan MSE sebesar 0,0132, yang terendah di antara metrik yang dievaluasi. Hasil ini selaras dengan studi sebelumnya oleh Mukhtar et al. pada 2020 dan Wentz et al. pada 2022, yang menggunakan model *hybrid* untuk prakiraan iradiasi dan melaporkan nilai kesalahan yang sama rendahnya [17,29]. Ini menunjukkan kekuatan dan keandalan pendekatan LSTM-ANN *hybrid* dalam memprediksi iradiasi surya secara efektif.

²⁰ Berdasarkan evaluasi terhadap model LSTM-ANN, performa prediksi dianalisis menggunakan beberapa metrik kesalahan, termasuk Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE).¹⁰ Dari hasil evaluasi, prediksi untuk tegangan (voltage) menunjukkan kesalahan terendah, dengan nilai MAE sebesar 0.1016 dan RMSE sebesar 0.1417. Nilai kesalahan yang rendah ini mengindikasikan bahwa model sangat akurat dalam memprediksi tegangan yang dihasilkan oleh sistem photovoltaic (PV), terutama selama kondisi radiasi matahari yang stabil di siang hari.

Sebaliknya, hasil prediksi untuk arus (current) menunjukkan tingkat kesalahan yang lebih tinggi, dengan MAE sebesar 0.1971 dan RMSE sebesar 0.2884. Kesalahan yang lebih tinggi ini menandakan bahwa model memiliki kesulitan dalam memprediksi arus yang bersifat lebih fluktuatif dibandingkan tegangan. Fluktuasi ini kemungkinan

disebabkan oleh perubahan yang lebih tidak teratur pada kondisi cuaca dan variasi intensitas matahari, yang mempengaruhi arus secara lebih dinamis daripada tegangan.

Perbedaan tingkat kesalahan antara prediksi tegangan dan arus menunjukkan bahwa meskipun pendekatan LSTM-ANN mampu memprediksi tren keseluruhan dengan cukup baik, model ini cenderung lebih sulit dalam menangani parameter yang memiliki tingkat variabilitas lebih tinggi, seperti arus. Fluktuasi yang lebih signifikan dalam data arus menimbulkan tantangan yang lebih besar dalam proses prediksi, yang tercermin dalam nilai kesalahan yang lebih besar.

Secara keseluruhan, hasil ini menunjukkan bahwa pendekatan hybrid LSTM-ANN memberikan akurasi yang baik dalam prediksi tegangan, sementara peningkatan lebih lanjut diperlukan untuk memperbaiki kinerja model dalam memprediksi arus yang fluktuatif. Penggunaan teknik tambahan, seperti pengolahan data yang lebih detail atau penyesuaian parameter model, mungkin diperlukan untuk meningkatkan akurasi prediksi arus.

5.7 Perbandingan dengan Studi Peneliti Terdahulu

Model *hybrid* LSTM-ANN menunjukkan kinerja yang sangat baik dalam memprediksi tegangan dan iradiasi, dengan nilai kesalahan yang rendah. Hal ini sejalan dengan hasil dari studi lain yang telah menggunakan model *hybrid* untuk prediksi keluaran energi surya, seperti yang dilakukan oleh Sun et al. pada 2021 dan Zhou et al. pada 2023. Temuan ini menyoroti efektivitas dan keandalan model dalam memprediksi parameter utama sistem energi surya dengan akurat.

Nilai kesalahan yang lebih tinggi pada prediksi arus menunjukkan bahwa perbaikan lebih lanjut, seperti mengoptimalkan parameter LSTM atau menggunakan fitur tambahan, mungkin diperlukan untuk meningkatkan akurasi. Hal ini sesuai dengan tantangan yang dicatat dalam penelitian lain, seperti karya Krishnan et al. pada 2020, di mana daya dan arus rentan terhadap fluktuasi yang lebih besar, yang mengakibatkan peningkatan kesalahan prediksi.

Model *hybrid* LSTM-ANN menunjukkan kinerja prediksi yang kuat untuk tegangan dan iradiasi, akurasi moderat untuk daya, dan masih memerlukan perbaikan dalam prediksi arus. Ini konsisten dengan kinerja yang diamati dalam penelitian terkait di bidang prediksi energi surya menggunakan model pembelajaran mendalam.

Penelitian ini mengevaluasi efektivitas model *hybrid* LSTM-ANN dalam memprediksi keluaran energi untuk sistem fotovoltaik (PV). Kombinasi Long Short-Term Memory (LSTM) dan Artificial Neural Networks (ANN) memungkinkan model ini menangkap hubungan temporal dan pola non-linear yang kompleks, menjadikannya cocok untuk memprediksi tegangan, arus, daya, dan iradiasi. Kinerja model dinilai menggunakan metrik utama seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE), yang menunjukkan akurasi yang bervariasi di berbagai parameter.

Prediksi tegangan mencapai tingkat akurasi tertinggi, dengan MAE sebesar 0,1016 dan RMSE sebesar 0,1417, yang tetap selaras dengan nilai aktual sepanjang hari. Prediksi iradiasi menunjukkan kinerja yang kuat dengan MAE sebesar 0,0895 dan RMSE sebesar 0,1149. Hasil ini konsisten dengan studi sebelumnya, seperti yang dilakukan oleh Mukhtar et al. pada 2020 dan Wentz et al. pada 2022, yang juga menemukan bahwa model *hybrid* unggul dalam memprediksi iradiasi surya dan tegangan.

Sebaliknya, model menghadapi tantangan dalam memprediksi arus, dengan tingkat kesalahan tertinggi tercatat pada MAE sebesar 0,1971 dan RMSE sebesar 0,2884. Kesalahan prediksi terutama terlihat pada sore hari, ketika nilai arus menunjukkan fluktuasi yang lebih besar. Kesulitan dalam prediksi arus ini mirip dengan masalah yang diamati dalam penelitian lain, seperti Krishnan et al. pada 2020, di mana sifat arus dan daya yang tidak dapat diprediksi, terutama selama waktu puncak, membuat prakiraan menjadi lebih kompleks.

Prediksi daya mencapai akurasi moderat, dengan MAE sebesar 0,1506 dan RMSE sebesar 0,1954, mengikuti tren yang serupa dengan prediksi tegangan dan iradiasi. Model ini mampu menangkap pola keseluruhan pembangkitan daya tetapi cenderung underpredict selama periode puncak, masalah umum yang dicatat dalam model prediksi daya.

Secara keseluruhan, model *hybrid* LSTM-ANN memberikan hasil yang kuat, terutama dalam prakiraan tegangan dan iradiasi. Integrasi analisis deret waktu dan pemodelan non-linear terbukti menjadi pendekatan yang efektif untuk memprediksi keluaran energi surya. Namun, peningkatan lebih lanjut diperlukan dalam bidang prediksi arus dan daya, yang dapat dicapai melalui penambahan lebih banyak fitur atau dengan penyesuaian hyperparameter model. Penelitian ini berkontribusi pada bidang yang

berkembang dalam model pembelajaran mendalam *hybrid* untuk prakiraan energi terbaru, menawarkan wawasan berharga tentang bagaimana arsitektur ini dapat meningkatkan efisiensi dan keandalan sistem energi surya.

5.8 Publikasi

Hasil penelitian ini telah dipresentasikan dan dipublish pada :

- a. **Digitized Smart Solar Power Agriculture Implementation in Palembang, Sumatera Selatan** yang telah dipresentasikan pada seminar internasional **Electrical Engineering, Computer Science, and Informatics (EECSI) 2023** pada tanggal 20-21 September 2023 di Palembang dan telah dipublikasikan di IEEE Publisher pada 31 Oktober 2023 (sertifikat dan karya tulis terlampir). Penelitian ini menguraikan tentang data iradian matahari dan hasil implementasi sistem irigasi otomatis berbasis sensor di dalam *greenhouse*.

Oktarina, Y., Nawawi, Z., Suprpto, B. Y., & Dewi, T. (2023, September).

Digitized Smart Solar Powered Agriculture Implementation in Palembang, South Sumatra. In 2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI) (pp. 60-65). IEEE.

doi:10.1109/EECSI59885.2023.10295805

<https://ieeexplore.ieee.org/abstract/document/10295805>

- b. **Integrating Temporal and Feedforward Models for Solar Energy Prediction: LSTM and ANN Hybrid Approaches** yang telah dipublish pada jurnal **The International Journal of Research in Vocational Studies (IJRVOCAS)**. (LoA dan karya tulis terlampir)

<https://journal.gpp.or.id/index.php/ijrvocas/article/view/317>

DOI: *<https://doi.org/10.53893/ijrvocas.v4i2>*

Published: 2024-08-31

BAB VI PREDIKSI PERTUMBUHAN DAN HASIL PANEN CABAI DENGAN *TRANSFER LEARNING CNN*

6.1 Pendahuluan

Bab ini membahas implikasi yang lebih luas dari temuan untuk pertanian agrivoltaik dan keberlanjutan pertanian. Dalam sistem pertanian agrivoltaik, dimana produksi tanaman dan energi surya diintegrasikan, prediksi hasil panen memiliki peran krusial dalam memastikan efisiensi dan keberlanjutan. Prediksi hasil panen yang akurat tidak hanya membantu petani dalam merencanakan waktu panen dan distribusi hasil, tetapi juga berperan dalam pengelolaan sumber daya seperti air, pupuk dan tenaga kerja.

Salah satu keuntungan utama dari sistem agrivoltaik adalah optimasi penggunaan lahan untuk tujuan ganda-pertanian dan pembangkitan energi. Dalam konteks ini, prediksi hasil panen memungkinkan petani untuk mengukur dampak energi surya terhadap pertumbuhan tanaman. Tanaman di bawah panel surya mengalami perubahan pola radiasi matahari, suhu dan kelembapan, yang secara langsung mempengaruhi produktivitas. Dengan memanfaatkan prediksi hasil panen, petani dapat menyesuaikan parameter-parameter lingkungan dan teknologi yang ada untuk meningkatkan produksi tanaman.

Selain itu, prediksi hasil panen membantu dalam pengelolaan rantai pasokan pertanian. Dengan mengetahui estimasi jumlah dan waktu panen, petani dapat membuat keputusan lebih baik mengenai penyimpanan, transportasi dan pemasaran hasil pertanian. Hal ini sangat penting dalam sistem agrivoltaik yang berbasis teknologi tinggi dimana variabilitas kondisi lingkungan lebih kompleks dibandingkan pertanian konvensional.

Di dalam sistem agrivoltaik, pemanfaatan teknologi seperti CNN yang digunakan untuk memprediksi pertumbuhan tanaman dan hasil panen memberikan keunggulan kompetitif bagi petani dalam mengintegrasikan data cuaca, kondisi mikroiklim dan citra tanaman ke dalam proses pengambilan keputusan.

Teknologi prediktif ini membantu meminimalkan kesalahan panen terlalu awal atau terlambat, yang dapat menyebabkan kerugian ekonomi. Selain itu prediksi yang akurat dapat mengurangi pemborosan sumber daya melalui pengelolaan irigasi dan distribusi pupuk yang lebih tepat waktu berdasarkan kebutuhan tanaman.

Untuk meningkatkan akurasi dalam memprediksi pertumbuhan dan hasil panen cabai digunakan pendekatan transfer learning melalui model pre-trained seperti EfficientNetV2M, EfficientNetV2L, dan ResNet50. Model pre-trained ini dilatih pada

dataset yang memungkinkan model untuk mengenali berbagai fitur visual yang kompleks. Setelah mendapatkan dasar dari pelatihan ini, model kemudian disesuaikan atau fine-tuned menggunakan dataset spesifik cabai.


Penelitian ini diharapkan dapat menghasilkan model prediksi pertumbuhan tanaman cabai dan hasil panen yang lebih akurat, dengan tingkat kesalahan prediksi yang lebih rendah dibandingkan dengan metode konvensional. Dengan demikian, sistem ini akan sangat berguna dalam sistem pertanian agrivoltaik dimana prediksi yang tepat dapat membantu dalam pengaturan waktu panen, pengelolaan sumber daya serta meningkatkan efisiensi operasional secara keseluruhan.

Bab ini berisi tentang pembahasan pre-training model, analisa hasil prediksi, performa/kinerja model, serta analisis simulasi dampak penilaian ekologis.

6.2 Desain Model

6.2.1 Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari citra buah cabai yang dikumpulkan dari lahan pertanian agrivoltaik eksperimental yang berada di Talang Kemang, Gandus-Palembang, Indonesia. Gambar-gambar ini diambil menggunakan Webcam Logitech tipe C920 dengan resolusi 1920x1080 piksel, yang memungkinkan pengambilan gambar-gambar dengan kualitas tinggi dari tanaman cabai.



Gambar 42 Dataset Pertumbuhan Tanaman Cabai

Jarak saat pengambilan gambar yaitu antara kamera dan buah cabai dipertahankan pada 20 cm. Dataset ini mencakup ratusan gambar, pada pertumbuhan tanaman di bagi menjadi 10 kelas yaitu ¹¹⁰ Week 1, Week 2, Week 3 hingga Week 10, sedangkan dataset buah cabai sebanyak 200 gambar, yang dibagi merata menjadi tiga kelas berdasarkan jumlah buah cabai yang terlihat dalam setiap citra, yaitu Buah Cabai 2 (2 buah cabai), Buah Cabai 3 (3 buah cabai), dan Buah Cabai 6 (6 buah cabai).

Setiap kelas diberi label dengan akurat untuk memastikan model dapat mengenai jumlah cabai dalam setiap gambar. Penamaan dan pemberian label dilakukan secara konsisten dalam bahasa Indonesia, misalnya, “Buah Cabai” merujuk pada istilah cabai dalam penelitian ini. Pengelompokan kelas ini bertujuan untuk melatih model agar mampu mengenali perbedaan jumlah buah cabai, yang relevan untuk estimasi hasil panen yang akurat.



Gambar 43 Dataset Buah Cabai

Pengambilan gambar dilakukan dalam berbagai kondisi seperti sudut pengambilan gambar dan pencahayaan untuk memperkaya variasi dalam dataset ini dan memastikan daya adaptasi model terhadap kondisi lingkungan yang berbeda di lapangan pertanian agrivoltaik. Beberapa aspek variasi yang diperhatikan dalam pengambilan gambar meliputi:

- a. Variasi Pencahayaan: Gambar diambil dalam berbagai kondisi pencahayaan, termasuk pencahayaan langsung, pencahayaan redup, dan cahaya difusi dari bayangan panel surya. Hal ini penting untuk memastikan model dapat mengenali cabai di berbagai intensitas cahaya yang berbeda, mengingat cahaya di lapangan dapat berubah sepanjang hari.
- b. Kondisi Cuaca: Pengumpulan data mencakup gambar yang diambil pada kondisi cuaca yang berbeda, seperti cuaca cerah, berawan, dan hujan ringan. Ini membantu model untuk mempelajari variasi visual yang disebabkan oleh perubahan cuaca, sehingga meningkatkan kemampuan model untuk melakukan prediksi dalam kondisi lingkungan yang dinamis.
- c. Sudut Pandang dan Jarak Kamera: Pengambilan gambar dilakukan pada sudut dan jarak yang bervariasi untuk memastikan bahwa model dapat mengenali cabai dalam berbagai orientasi dan posisi pada gambar. Jarak yang konsisten pada 20 cm dipilih untuk meminimalkan distorsi visual, namun variasi sudut pandang tetap dipertahankan untuk memberikan perspektif yang lebih luas terhadap tanaman cabai.

Setelah proses pengambilan gambar, data diolah dan diklasifikasikan menjadi 3 kelas, yaitu Buah Cabai 2, Buah Cabai 3 dan Buah Cabai 6. Klasifikasi ini didasarkan pada jumlah buah cabai yang terlihat pada setiap gambar, misalnya :

- Buah Cabai 2 : Gambar yang mengandung dua buah cabai yang terlihat jelas.
- Buah Cabai 3: Gambar dengan tiga buah cabai dalam satu frame.
- Buah Cabai 6: Gambar yang menunjukkan enam buah cabai, biasanya diambil pada cabang tanaman yang lebih lebat.

Klasifikasi ini bertujuan untuk melatih model agar mampu mengidentifikasi dan menghitung jumlah cabai dengan akurasi tinggi. Penggunaan tiga kelas ini didasarkan pada asumsi bahwa jika model dapat mengenali enam cabai, maka akan lebih mudah baginya untuk mengenali jumlah cabai yang lebih sedikit (dua atau tiga). Selain itu, variasi jumlah cabai di setiap gambar memungkinkan model untuk mempelajari pola pertumbuhan dan perkembangan buah cabai dalam kondisi lapangan yang realistis.

Dataset dibagi menjadi beberapa subset untuk memastikan bahwa model dapat dilatih secara efektif tanpa mengalami *overfitting*. Pembagian data dilakukan sebagai berikut:

- a. **Training Set (60%)**: Digunakan untuk melatih model agar dapat mengenali pola-pola dasar dari gambar cabai. Proses ini mencakup penyesuaian parameter model untuk memaksimalkan akurasi prediksi.
- b. **Validation Set (20%)**: Berfungsi untuk menguji performa model selama proses pelatihan, memastikan bahwa model tidak hanya bekerja baik pada data latih tetapi juga mampu generalisasi pada data yang tidak dikenal.
- c. **Testing Set (20%)**: Digunakan untuk mengukur performa akhir model pada data baru yang tidak pernah dilihat selama pelatihan, memberikan gambaran tentang kemampuan model untuk melakukan prediksi di lapangan.

Distribusi data yang digunakan dalam proses pelatihan dan pengujian model ditunjukkan dalam tabel 5.

Tabel 5 Pembagian Dataset Untuk Pelatihan dan Pengujian

Class Name	Count	Training	Testing
Buah cabai 2	300	200	100
Buah cabai 3	300	200	100
Buah cabai 6	300	200	100

Sesuai data pada tabel 5 dijelaskan bahwa, setiap kelas (Buah Cabai 2, Buah Cabai 3, Buah Cabai 6) masing-masing memiliki 300 gambar, yang masing-masing dibagi menjadi 200 gambar untuk dijadikan dataset pelatihan dan 100 gambar lainnya untuk pengujian. Pembagian data ini dilakukan untuk memastikan bahwa model memiliki data yang cukup untuk belajar mengenali pola, serta data yang terpisah untuk menguji kemampuan generalisasi model.

Pengumpulan data dengan variasi yang luas ini sangat penting dalam konteks sistem agrivoltaik, di mana perubahan intensitas cahaya akibat bayangan panel surya dapat memengaruhi tampilan visual cabai. Selain itu, kondisi lingkungan yang berbeda di bawah panel surya dapat menyebabkan variasi dalam pertumbuhan cabai, seperti perubahan suhu dan kelembapan. Oleh karena itu, data yang dikumpulkan mencerminkan variasi yang mungkin dihadapi oleh sistem pertanian agrivoltaik di lapangan.

Model yang dilatih dengan dataset ini diharapkan dapat memberikan prediksi yang akurat mengenai jumlah buah cabai yang ada dalam setiap gambar, bahkan dalam kondisi lingkungan yang tidak selalu optimal. Hal ini mendukung tujuan akhir dari penelitian,


yaitu menciptakan sistem prediksi yang adaptif dan akurat untuk mendukung keberlanjutan sistem agrivoltaik secara keseluruhan.

6.2.2 Arsitektur Model

118

Penelitian ini menggunakan 3 model *Convolutional Neural Network* (CNN), yaitu EfficientNetV2M, EfficientNetV2L dan ResNet50. Masing-masing model ini digunakan untuk mengoptimalkan kemampuan prediksi pada dataset cabai. Model EfficientNetV dipilih karena efisiensinya dalam memproses data dengan berbagai ukuran tanpa mengorbankan akurasi. Sementara itu, RestNet50 digunakan karena kekuatannya dalam menangani struktur data visual yang lebih kompleks,

Sebelum dilatih pada dataset buah cabai, model EfficientNetV2M, EfficientNetV2L dan ResNet50 telah dilatih menggunakan dataset ImageNet. Hasil pre-training ini memberikan kemampuan awal untuk mengenali struktur gambar secara umum, seperti tekstur dan pola bentuk. Dengan demikian, saat diterapkan pada dataset cabai, model sudah memiliki pondasi awal yang baik, memungkinkan untuk adaptasi yang lebih cepat terhadap ciri-ciri spesifik dari gambar cabai. Pengumpulan data dan tahap pre-training ditunjukkan dalam gambar 6.3 berikut ini.



Gambar 44 Alur Pre-training dan Transfer Learning Model CNN

Gambar 43 ini memberikan ilustrasi bagaimana model EfficientNetV2M, EfficientNetV2L dan ResNet50 dilatih terlebih dahulu menggunakan dataset ImageNet untuk mendapatkan parameter dasar pengenalan fitur gambar secara umum. Parameter hasil pre-training tersebut kemudian digunakan dalam proses transfer learning pada dataset cabai. Melalui proses ini, model dilatih lebih lanjut pada data citra cabai untuk memprediksi jumlah buah cabai dalam gambar dengan akurasi yang lebih tinggi.

Model-model ini tidak dilatih dari awal menggunakan dataset cabai. Sebaliknya, parameter dari model pre-trained ini diadaptasi lebih lanjut pada gambar cabai melalui proses transfer learning. Hal ini dilakukan agar model dapat memanfaatkan pengetahuan yang sudah diperoleh dari dataset besar sebelumnya, sehingga fokus pelatihan lebih terarah pada pengenalan karakteristik spesifik dari buah cabai, seperti bentuk buah, variasi warna, dan kondisi pencahayaan yang ada di lapangan agrivoltaik.

6.3 Training Model *Transfer Learning* CNN

Setelah pelatihan awal (pre-training) menggunakan ImageNet, model dilanjutkan dengan proses transfer learning pada dataset buah cabai. Tahap ini melibatkan:

- a. Fine-tuning Parameter: Proses penyesuaian parameter model dilakukan pada lapisan-lapisan terakhir. Penyesuaian ini dilakukan untuk memaksimalkan sensitivitas model terhadap fitur unik dari dataset cabai. Fine-tuning dilakukan dengan mempertahankan parameter awal pada lapisan-lapisan dasar yang sudah dilatih, sementara lapisan atas dilatih ulang untuk menyesuaikan karakteristik dataset baru.
- b. Adaptasi Lapisan Klasifikasi: Lapisan terakhir model diadaptasi untuk mengenali tiga kategori jumlah buah cabai, yaitu Buah Cabai 2, Buah Cabai 3, dan Buah Cabai 6. Adaptasi ini dilakukan dengan mengganti lapisan klasifikasi agar sesuai dengan jumlah kelas pada dataset cabai, sehingga model dapat menghasilkan prediksi yang lebih spesifik sesuai kebutuhan penelitian.

Untuk mencapai hasil pelatihan yang optimal, diperlukan penyesuaian hyperparameter yang tepat selama proses transfer learning. Hyperparameter ini berperan penting dalam menentukan kecepatan dan efektivitas pembelajaran model, serta mencegah terjadinya overfitting. Pada penelitian ini, beberapa parameter seperti batch size, learning rate, jumlah epoch, jumlah hidden layer, dan dropout rate disesuaikan agar

model dapat belajar dari dataset cabai dengan baik. Rincian pengaturan hyperparameter yang digunakan selama proses pelatihan disajikan dalam Tabel 6.

Tabel 6 Pengaturan Hiperparameter untuk Pelatihan Model CNN

Batch size	Learning Rate	Epoch	Hidden layer	Dropout
16	0,001	100	256	0.4

Tabel 6 ini menggambarkan konfigurasi hyperparameter yang digunakan selama proses pelatihan model CNN. Batch size sebesar 16 memastikan bahwa model melakukan update parameter setelah memproses 16 gambar, sedangkan learning rate sebesar 0,001 membantu mengatur kecepatan pembelajaran model. Epoch sebanyak 100 digunakan untuk memberikan cukup waktu bagi model untuk belajar dari dataset, dan hidden layer berjumlah 256 menunjukkan kompleksitas jaringan neural yang digunakan. Dropout rate sebesar 0,4 diterapkan untuk mengurangi risiko overfitting dengan menghilangkan 40% neuron secara acak selama pelatihan.

Langkah-langkah untuk memprediksi hasil panen meliputi mengimpor pustaka, memuat model yang sudah dilatih sebelumnya, membekukan lapisan, menambahkan lapisan khusus (fine-tuning), menyusun model, memuat dan memproses dataset, serta melatih model. Data validasi digunakan untuk memantau proses pelatihan dan mencegah overfitting serta mengevaluasi model untuk menilai kinerjanya. Aktivasi yang dipertimbangkan dalam penelitian ini adalah ReLU pada lapisan input dan SoftMax pada lapisan output. Pseudocode pelatihan model dalam penelitian ini adalah sebagai berikut :

a. **EfficientNetV2L**

```

img_shape = (img_size[0],img_size[1] , 3)
num_class = len(classes)
base_model = tf.keras.applications.EfficientNetV2L(include_top = False ,
weights = 'imagenet' ,
input_shape = img_shape, pooling= 'max')
model = Sequential([
    base_model,
    BatchNormalization(axis= -1 , momentum= 0.99 , epsilon= 0.001),
    Dense(512, kernel_regularizer = regularizers.l2(l= 0.016) , activity_regularizer

```

```

    = regularizers.l1(0.006),
      bias_regularizer=regularizers.l1(0.006) , activation = 'relu'),
    Dropout(rate=0.4 , seed = 75),
    Dense(num_class , activation = 'softmax')
  ])

```

b. EfficientNetV2M

```

5 img_shape=(img_size[0],img_size[1],3)
num_class = len(classes)
5 base_model = tf.keras.applications.EfficientNetV2M(include_top = False ,
weights = 'imagenet',
input_shape = img_shape, pooling= 'max')
model = Sequential([
    base_model,
    BatchNormalization(axis= -1 , momentum= 0.99 , epsilon= 0.001),
    Dense(512, kernel_regularizer = regularizers.l2(l= 0.016) , activity_regularizer
= regularizers.l1(0.006),
      bias_regularizer=regularizers.l1(0.006) , activation = 'relu'),
    Dropout(rate=0.4 , seed = 75),
    Dense(num_class , activation = 'softmax')
  ])

```

c. ResNet50

```

5 img_shape=(img_size[0],img_size[1],3)
num_class = len(classes)
5 base_model = tf.keras.applications.ResNet50(include_top = False , weights =
'imagenet' ,
input_shape = img_shape, pooling= 'max')
model = Sequential([
    base_model,
    BatchNormalization(axis= -1 , momentum= 0.99 , epsilon= 0.001),
    Dense(512, kernel_regularizer = regularizers.l2(l= 0.016) , activity_regularizer
= regularizers.l1(0.006),
      bias_regularizer=regularizers.l1(0.006) , activation = 'relu'),

```

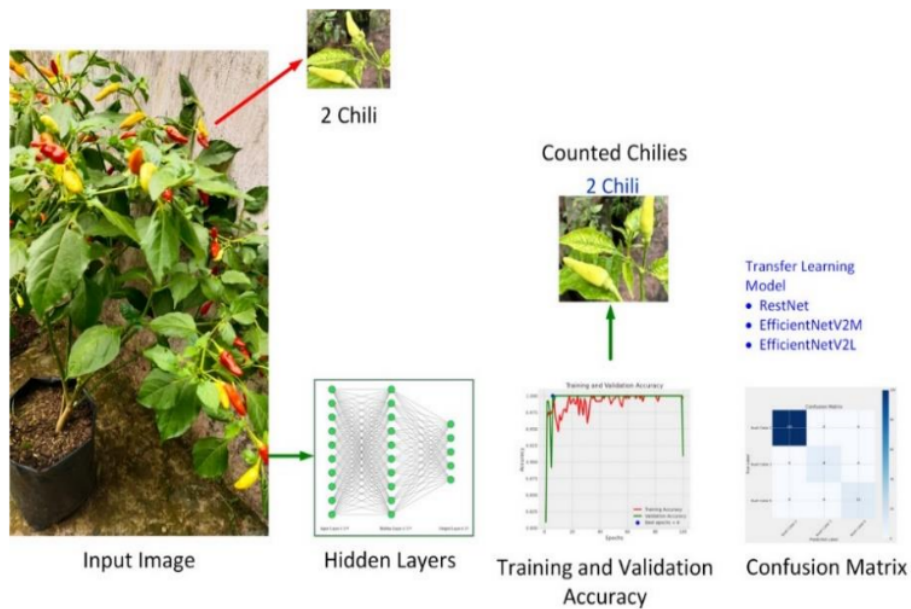
```

Dropout(rate=0.4 , seed = 75),
Dense(num_class , activation = 'softmax')
)

```

6.4 Evaluasi dan Analisa Kinerja Model

Analisa prediksi untuk pertumbuhan dan hasil panen menggunakan tiga model transfer learning yang berbeda—EfficientNetV2L, EfficientNetV2M, dan ResNet50. Dimana evaluasi kinerja dari ketiga model tersebut diukur melalui metrik seperti precision, recall dan F1-score. Pada prediksi pertumbuhan, metrik-metrik ini diterapkan pada setiap kelas yaitu Week 1, Week 2 dan seterusnya. Pada prediksi hasil panen, diterapkan pada setiap kelas, termasuk "Buah Cabai 2," "Buah Cabai 3," dan "Buah Cabai 6."




Gambar 45 Ilustrasi Proses Hasil Penghitungan Buah Cabai

Gambar 44 menunjukkan ilustrasi untuk proses hasil penghitungan buah cabai kami, dan hasilnya adalah penghitungan hasil panen seperti yang ditunjukkan pada Gambar 44. Kinerja sistemnya diberikan oleh akurasi pelatihan dan validasi, *training* dan *validation accuracy*, dan matriks konvolusi untuk menunjukkan seberapa efektif metode yang digunakan. Hasil prediksi pertumbuhan tanaman ditunjukkan pada gambar 44.

Gambar 45 menampilkan hasil prediksi jumlah buah cabai menggunakan tiga model transfer learning, yaitu EfficientNetV2M, EfficientNetV2L, dan ResNet50.

Gambar-gambar ini menunjukkan hasil deteksi dan klasifikasi oleh model-model tersebut terhadap berbagai sampel citra cabai yang diambil dari lapangan.

Hasil prediksi penghitungan tanaman dimana metode yang digunakan menghitung jumlah cabai dalam gambar dengan benar, dimana Buah cabai 2 berarti 2 cabai, buah cabai 3 artinya 3 cabai, dan buah cabai 6 adalah 6 cabai.



Gambar 46 Hasil Prediksi Penghitungan Tanaman Dengan 3 Model Pembelajaran Transfer

Gambar 45 menyajikan akurasi pelatihan dan validasi, di mana semua model menunjukkan konvergensi antara pelatihan dan validasi. Konvergensi diperlukan untuk menentukan titik di mana proses pelatihan mencapai keadaan stabil, dan parameter seperti bobot dan bias telah mencapai prediksi akurat untuk data pelatihan. Pembelajaran transfer menciptakan konvergensi yang lebih cepat karena kumpulan data besar yang telah dilatih sebelumnya digunakan sebelumnya. Konvergensi pada Gambar 46 juga menunjukkan bahwa kesalahan pelatihan telah berhenti menurun atau telah mencapai tingkat minimum kesalahan yang dapat diterima. Kesalahan, seperti overfitting, diatasi dengan dropout.




(a) EfisienNet V2L (b) EfisienNetV2M (c) ResNet50

Gambar 47 Hasil Akurasi Pelatihan Dan Validasi 3 Model Pembelajaran Transfer.

Studi ini menerapkan 100 epoch untuk semua model, dan epoch terbaik untuk EfficientNetV2L adalah 4 (Gbr. 46a), EfficientNetV2M adalah 6 (Gbr. 46b), dan RestNet50 adalah 8 (Gbr. 46c), di mana pelatihan dan validasi mulai mencapai konvergensi. Secara keseluruhan, kinerja, konvergensi, dan kemampuan generalisasi dalam metode yang diusulkan terbukti efektif berdasarkan hasil pada Gambar 46.

Gambar 47 menunjukkan hasil *loss validation* dan pelatihan dari tiga model pembelajaran transfer. Epoch terbaik untuk EfficientNetV2L adalah 100% (Gambar 6.8a), EfficientNetV2M adalah 99% (Gambar 6.8b), dan RestNet50 adalah 100% (Gambar 6.8c). Kerugian pelatihan dan validasi adalah nol, yang menunjukkan bahwa model tersebut belajar secara efektif, yang dibuktikan dengan prediksi yang benar pada Gambar 47 dan analisis kinerja total pada tabel 7.



(a) EfisienNetV2L (b) EfisienNet V2M (c) ResNet50

Gambar 48 Hasil pelatihan dan loss validation dari 3 model pembelajaran transfer.

Evaluasi kinerja model total tercantum dalam tabel 7, yang menunjukkan bahwa EfficientNetV2L dan RestNet memiliki akurasi 100%. EfficientNetV2M memiliki akurasi yang lebih rendah karena kinerja kumpulan data yang rendah. Selama menghitung tiga cabai, EfficientNetV2M mengembalikan hasil nol karena ketiga cabai tersebut ditumpuk bersama-sama, dan rona warnanya hijau, yang sangat mirip dengan daun seperti yang ditunjukkan pada Gambar 47, dan ini juga ditunjukkan oleh underfitting dalam akurasi pelatihan dan validasi (Gambar 47.b). Penyetelan mencakup penurunan 0,4, dan benihnya adalah 75.



Gambar 49 Contoh Buah Cabai Yang Menumpuk

Tabel 7 ini menampilkan metrik evaluasi kinerja model dalam memprediksi pertumbuhan tanaman cabai pada berbagai minggu (Week 1 hingga Week 11) menggunakan **precision, recall, dan F1-score** sebagai indikator utama.

Metrik-metrik ini digunakan untuk menilai akurasi prediksi model dalam setiap periode, serta memberikan pemahaman yang lebih mendalam tentang seberapa baik model dalam mengenali dan mengklasifikasikan jumlah cabai pada data uji.

Nilai akurasi sebesar 1.00 untuk setiap minggu menunjukkan bahwa model berhasil mengidentifikasi pertumbuhan tanaman cabai tanpa false positif.

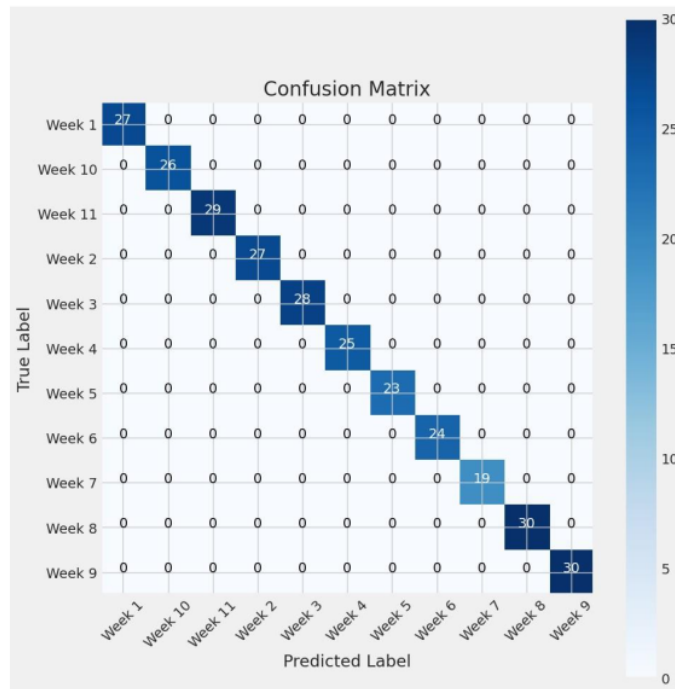
Nilai recall yang juga mencapai 1.00 di setiap minggu menunjukkan bahwa model mampu mengidentifikasi semua sampel yang benar dalam data uji. Hal ini berarti model tidak melewatkan sampel yang seharusnya diklasifikasikan sebagai pertumbuhan tanaman tertentu.

F1-score, yang merupakan harmoni antara precision dan recall, juga mencapai 1.00 di setiap minggu. Ini menunjukkan keseimbangan sempurna antara kemampuan model untuk menghindari kesalahan positif dan mengidentifikasi sampel yang benar.

Tabel 7 Evaluasi Kinerja Pertumbuhan Tanaman

	precision	recall	f1-score	support
Week 1	1.00	1.00	1.00	27
Week 10	1.00	1.00	1.00	26
Week 11	1.00	1.00	1.00	29
Week 2	1.00	1.00	1.00	27
Week 3	1.00	1.00	1.00	28
Week 4	1.00	1.00	1.00	25
Week 5	1.00	1.00	1.00	23
Week 6	1.00	1.00	1.00	24
Week 7	1.00	1.00	1.00	19
Week 8	1.00	1.00	1.00	30
Week 9	1.00	1.00	1.00	30
accuracy			1.00	288
macro avg	1.00	1.00	1.00	288
weighted avg	1.00	1.00	1.00	288

Pada kinerja hasil panen seperti yang ditunjukkan pada tabel 8 EfficientNetV2L dan ResNet50 menunjukkan performa sempurna dalam hal presisi dan recall, mencapai nilai presisi dan recall 1.00 pada semua kategori, yaitu Buah Cabai 2, Buah Cabai 3, dan Buah Cabai 6. Ini berarti kedua model ini tidak hanya mampu mengidentifikasi cabai dengan baik, tetapi juga tidak menghasilkan prediksi positif palsu. EfficientNetV2M menunjukkan nilai presisi dan recall yang lebih rendah pada kelas Buah Cabai 3, di mana cabai cenderung tumpang tindih atau berbaur dengan latar belakang, menghasilkan presisi sebesar 0.92 dan F1-score sebesar 0.96.




Gambar 50 Hasil Confusion Matrix dari 1 model transfer learning

Gambar 49 ini menampilkan *Confusion Matrix* yang menggambarkan kinerja model dalam memprediksi pertumbuhan tanaman cabai untuk setiap minggu selama periode pengujian. Matriks ini memvisualisasikan hubungan antara label sebenarnya (*True Label*) dengan label prediksi (*Predicted Label*) yang dihasilkan oleh model, di mana setiap baris menunjukkan kategori sebenarnya dan setiap kolom menunjukkan kategori yang diprediksi oleh model.

Tabel 8 Evaluasi Kinerja Model

Kelas	Model	Presisi	Recall	F1-Skor	Ketepatan
Buah Cabai 2	EfisienNetV2L	1	1	1	1
	EfisienNetV2M	0,92	1	0,96	0,93
	ResNet50	1	1	1	1
Buah Cabai 3	EfisienNetV2L	1	1	1	1
	EfisienNetV2M	angka 0	angka 0	angka 0	0,93
	ResNet50	1	1	1	1
Buah Cabai 6	EfisienNetV2L	1	1	1	1
	EfisienNetV2M	1	1	1	0,93
	ResNet50	1	1	1	1



(a) EfisienNetV2L

(b) EfisienNet V2M

(c) ResNet50

Catatan: Buah cabai Buah Cabai 1 : 1, Buah Cabai 2 : 2 cabai, dan Buah Cabai 6 sebanyak 6 cabai.

Gambar 51 Hasil Confusion Matrix dari 3 model transfer learning

Gambar 50 menunjukkan *Confusion Matrix* dari tiga model yang digunakan, di mana diagonal menunjukkan jumlah yang diklasifikasikan dengan benar dan diagonal lainnya menunjukkan kesalahan klasifikasi. Matriks confusion terkait dengan tabel 8 dari daftar kinerja model. Kinerja atau akurasi keseluruhan adalah 100%; oleh karena itu, semua label dan prediksi yang benar adalah sama. Skor F1, yang menggabungkan Presisi dan Memory, menunjukkan bahwa skornya adalah 96% untuk EfficientNetV2M, dan model lainnya adalah 100%. Model pembelajaran transfer yang digunakan dalam penelitian ini telah terbukti efektif dalam memprediksi penghitungan tanaman untuk prediksi panen cabai.

6.4. Analisa dan Interpretasi Hasil Prediksi Berdasarkan Prediksi Hyperparameter

Analisis performa model berdasarkan variasi hyperparameter pada Gambar 46 dan 47 menunjukkan bahwa konvergensi yang dicapai oleh ketiga model—EfficientNetV2L, EfficientNetV2M, dan ResNet50—merupakan indikator stabilitas dan efektivitas proses pelatihan. Konvergensi ini menunjukkan bahwa model telah mencapai titik optimal di mana nilai bobot dan bias tidak lagi mengalami perubahan signifikan, dan kesalahan pelatihan (training loss) telah mendekati nilai minimum yang dapat diterima. Capaian ini krusial untuk menjamin bahwa model dapat melakukan generalisasi dengan baik terhadap data baru, sekaligus mengurangi risiko overfitting. Pembelajaran transfer memberikan

keuntungan signifikan dalam akselerasi konvergensi berkat penggunaan data besar yang telah dilatih sebelumnya, yang mempercepat optimasi model.

Pada Gambar 46, dapat diamati bahwa konvergensi dicapai pada epoch ke-4 untuk EfficientNetV2L (Gambar 46a), epoch ke-6 untuk EfficientNetV2M (Gambar 46b), dan epoch ke-8 untuk ResNet50 (Gambar 46c). Hal ini mencerminkan perbedaan dalam tingkat kompleksitas dan sensitivitas setiap model terhadap perubahan hyperparameter seperti epoch, learning rate, dan dropout rate. Variasi ini menunjukkan bahwa ResNet50 memerlukan waktu yang sedikit lebih panjang untuk mencapai konvergensi, sedangkan EfficientNetV2L lebih cepat beradaptasi terhadap pola data yang diberikan. Efisiensi ini dapat dikaitkan dengan kemampuan arsitektur EfficientNet dalam melakukan scaling parameter secara efektif melalui pendekatan compound scaling.

Analisis loss pada Gambar 47 mengungkapkan bahwa baik pada tahap pelatihan maupun validasi, ketiga model berhasil mencapai loss yang mendekati nol. Tingkat akurasi yang tinggi ini mengindikasikan kemampuan model dalam menangkap fitur-fitur penting pada dataset. Namun, perbedaan performa menjadi nyata ketika dihadapkan pada tantangan identifikasi yang lebih kompleks seperti pada kelas Buah Cabai 3. Tabel 8 menegaskan bahwa EfficientNetV2M menunjukkan performa lebih rendah pada kategori ini, dengan presisi 0.92 dan F1-score 0.96. Penurunan performa ini disebabkan oleh kemampuan terbatas model dalam mendeteksi objek dengan kemiripan warna dan tekstur dengan latar belakang, seperti yang diilustrasikan pada Gambar 48.

Kelemahan tersebut dapat dikaitkan dengan tingkat dropout yang diterapkan (0.4) serta pemilihan seed pada pelatihan yang mungkin mempengaruhi kestabilan model saat menghadapi variabilitas data. Penelitian ini menyarankan bahwa fine-tuning hyperparameter yang lebih optimal diperlukan untuk memperbaiki masalah underfitting pada EfficientNetV2M. Di sisi lain, EfficientNetV2L dan ResNet50 menunjukkan ketahanan yang baik dalam menghadapi situasi yang kompleks dengan presisi, recall, dan F1-score mencapai 1.00 pada semua kategori.

Confusion Matrix yang ditampilkan pada Gambar 50 mengonfirmasi efektivitas model dalam menangani data uji yang kompleks, dengan seluruh nilai prediksi yang benar berada pada diagonal. Hal ini menunjukkan bahwa metode pembelajaran transfer yang diusulkan dalam penelitian ini telah mencapai performa yang kompetitif, khususnya dalam menangani klasifikasi multi-kelas pada dataset cabai. Keunggulan ini juga

diperkuat oleh nilai akurasi keseluruhan yang mencapai 100% untuk EfficientNetV2L dan ResNet50.

Secara keseluruhan, analisis ini menegaskan bahwa model pembelajaran transfer yang menggunakan arsitektur seperti EfficientNetV2L dan ResNet50 memiliki potensi yang signifikan dalam aplikasi klasifikasi berbasis citra dengan dataset yang kompleks. Efektivitas model ini dalam menangani tantangan klasifikasi cabai membuktikan bahwa pemilihan hyperparameter yang tepat serta optimalisasi lebih lanjut pada konfigurasi dropout dan strategi fine-tuning model dapat meningkatkan kinerja secara signifikan. Analisis ini menawarkan perspektif yang lebih mendalam mengenai keterbatasan model serta memberikan rekomendasi konkret untuk pengembangan model di masa mendatang.

6.5 Publikasi

Hasil penelitian ini telah dipresentasikan dan dipublish pada :

Towards Ecological Sustainability: Harvest Prediction In Agrivoltaic Chili Farming With CNN Transfer Learning yang telah dipublish pada jurnal **Iraqi Journal Of Agricultural Sciences (IJAS)** University of Baghdad. Q1, SJR : 0,64 (2023).

 <https://orcid.org/0000-0002-5774-5906>

BAB VII. PENUTUP

7.1 Kesimpulan

Disertasi ini membahas kemajuan dalam prediksi energi terbarukan dan teknologi pertanian melalui pengembangan model hybrid AI dan praktik pertanian yang berkelanjutan. Salah satu hasil utama dari penelitian ini adalah pengembangan model hybrid LSTM-ANN untuk memprediksi keluaran utama dari sistem fotovoltaik. Menggabungkan keunggulan pembelajaran temporal dari LSTM dan kekuatan pemetaan non-linear dari ANN, model ini berhasil menghasilkan prediksi yang sangat akurat terhadap tegangan dan iradiasi dengan nilai kesalahan rata-rata absolut (MAE) masing-masing sebesar 0,1016 dan 0,0895. Namun, prediksi arus menunjukkan kesalahan tertinggi dengan nilai MAE sebesar 0,1971, yang menandakan adanya ruang untuk perbaikan. Pekerjaan di masa depan disarankan untuk memperluas dataset, memperbaiki parameter model, serta menambahkan variabel cuaca seperti suhu dan kelembapan guna meningkatkan akurasi prediksi daya keluaran. Pendekatan ini bertujuan untuk mengikuti tren berkelanjutan dalam pemanfaatan energi terbarukan.

Selain itu, penelitian ini juga mengkaji implementasi sistem agrivoltaik di wilayah tropis seperti Palembang, Sumatera Selatan, yang memiliki potensi besar sebagai wilayah pertanian digital berbasis energi terbarukan. Pertanian bertenaga surya melalui sistem yang disebut agrivoltaik menawarkan manfaat energi listrik yang stabil untuk wilayah yang belum terjangkau jaringan. Studi ini menyajikan data penyinaran matahari selama satu minggu dengan tingkat penyinaran tertinggi mencapai 1278,8 W/m². Sistem pertanian surya digital yang dikembangkan menggunakan sensor kelembapan untuk memberikan masukan ke pengontrol yang kemudian mengaktifkan pompa irigasi. Implementasi AI diusulkan untuk meningkatkan efektivitas pendekatan ini dalam penerapan sistem baru ini.

Lebih jauh, sistem pemantauan cerdas yang diterapkan di rumah kaca menunjukkan potensi besar dalam menjaga stabilitas lingkungan dan mengelola tanaman secara tepat waktu dan akurat. Hal ini mengarah pada peningkatan efisiensi pemanfaatan sumber daya dan pengurangan konsumsi energi di bangunan rumah kaca. Teknologi IoT di rumah kaca memanfaatkan berbagai protokol komunikasi yang dipilih berdasarkan kebutuhan spesifik seperti bandwidth, jangkauan, dan masa pakai baterai. Secara bertahap,

penggunaan protokol komunikasi beralih dari mode kabel ke nirkabel untuk meningkatkan fleksibilitas sistem.

Dalam konteks penggunaan kecerdasan buatan, penerapan pembelajaran mesin dalam sistem pemantauan rumah kaca masih terbatas, tetapi memiliki potensi besar di masa depan. Dengan berkembangnya teknologi 5G, penerapan modul transfer data berbasis 5G menjadi topik penelitian yang signifikan karena mampu meningkatkan kecepatan dan efisiensi transmisi data. Seiring dengan meningkatnya volume data yang terkumpul, pemantauan rumah kaca akan semakin terintegrasi dengan kecerdasan buatan dan pembelajaran mesin, memungkinkan manajemen rumah kaca tanpa awak dan peningkatan efisiensi energi.

Di sisi lain, untuk mengoptimalkan manajemen panen, model transfer learning berbasis CNN—EfficientNetV2L, EfficientNetV2M, dan ResNet 50—diimplementasikan dalam penghitungan tanaman cabai. Model ini menunjukkan akurasi prediksi masing-masing sebesar 100%, 93%, dan 100%, dengan konvergensi yang cepat dalam pelatihan dan validasi, membuktikan pembelajaran yang efektif dan prediksi yang andal. Hasil penelitian ini menekankan bahwa transfer learning sangat cocok untuk penghitungan tanaman dan alokasi sumber daya selama masa panen, memperkuat peran teknologi berbasis AI dalam mendorong efisiensi dan keberlanjutan di berbagai aplikasi energi terbarukan dan agrivoltaik.

Secara keseluruhan, temuan dalam penelitian ini memberikan kontribusi yang signifikan terhadap integrasi AI dan IoT dalam meningkatkan akurasi prediksi, manajemen energi, dan produktivitas pertanian. Melalui pendekatan yang holistik, penelitian ini membuka peluang baru untuk penerapan teknologi terdepan dalam meningkatkan efisiensi dan keberlanjutan di sektor pertanian berbasis energi terbarukan.

7.2 Rekomendasi

Penelitian ini telah menghasilkan sejumlah temuan penting terkait pengembangan teknologi prediksi energi terbarukan dan optimalisasi sistem agrivoltaik berbasis kecerdasan buatan dan IoT. Namun, untuk mencapai potensi maksimal dan memperluas aplikasi sistem ini, beberapa aspek masih memerlukan peningkatan dan penyempurnaan. Oleh karena itu, sub bab ini menguraikan saran serta rekomendasi untuk penelitian lanjutan yang dapat mendukung perkembangan lebih lanjut dalam teknologi agrivoltaik

dan pertanian berkelanjutan. Saran ini diharapkan mampu membuka peluang baru dan meningkatkan efektivitas penerapan solusi yang lebih adaptif dan inovatif di masa mendatang.

1. Transformasi IoT dari Monitoring menjadi Kendali Otomatis:

Sistem IoT yang digunakan berfungsi sebagai alat pemantauan dapat ditingkatkan menjadi sistem kendali otomatis. Dengan menambahkan fungsi kontrol, sistem akan mampu menyesuaikan parameter iklim mikro secara langsung berdasarkan data yang diperoleh, memungkinkan respons yang lebih cepat dan efisien terhadap perubahan kondisi lingkungan.

2. Prediksi Penyakit untuk Mendukung Manajemen Panen:

Meskipun peluang munculnya penyakit pada sistem greenhouse yang terkondisi sangat kecil, penambahan model prediksi penyakit dapat meningkatkan manajemen panen dan menjaga kesehatan tanaman. Model ini dapat mendeteksi potensi awal penyakit, memungkinkan pengelola greenhouse untuk melakukan tindakan pencegahan dini demi mempertahankan kualitas hasil panen yang optimal.

laporan disertasi REVISI 4 turnitin.pdf

ORIGINALITY REPORT

19%

SIMILARITY INDEX

18%

INTERNET SOURCES

8%

PUBLICATIONS

%

STUDENT PAPERS

PRIMARY SOURCES

1	repositori.unsil.ac.id Internet Source	2%
2	repository.its.ac.id Internet Source	2%
3	pdfcoffee.com Internet Source	2%
4	eprints.ubhara.ac.id Internet Source	1%
5	www.cnblogs.com Internet Source	1%
6	123dok.com Internet Source	1%
7	deriota.com Internet Source	1%
8	docplayer.info Internet Source	1%
9	jurnal.ugm.ac.id Internet Source	<1%

10	repository.ub.ac.id Internet Source	<1 %
11	ijape.iaescore.com Internet Source	<1 %
12	lib.unnes.ac.id Internet Source	<1 %
13	repository.pelitabangsa.ac.id:8080 Internet Source	<1 %
14	mardevitaislamiyakti.blogspot.com Internet Source	<1 %
15	Min-Sheng Liao, Shih-Fang Chen, Cheng-Ying Chou, Hsun-Yi Chen, Shih-Hao Yeh, Yu-Chi Chang, Joe-Air Jiang. "On precisely relating the growth of Phalaenopsis leaves to greenhouse environmental factors by using an IoT-based monitoring system", Computers and Electronics in Agriculture, 2017 Publication	<1 %
16	jurnal.ikipmumaumere.ac.id Internet Source	<1 %
17	text-id.123dok.com Internet Source	<1 %
18	journal.isas.or.id Internet Source	<1 %
19	journal.gpp.or.id	

Internet Source

<1 %

20

www.ilmudata.org

Internet Source

<1 %

21

www.atlantispress.com

Internet Source

<1 %

22

repository.pertanian.go.id

Internet Source

<1 %

23

kneks.go.id

Internet Source

<1 %

24

www.researchgate.net

Internet Source

<1 %

25

journal.unpas.ac.id

Internet Source

<1 %

26

repository.um-surabaya.ac.id

Internet Source

<1 %

27

www.e3s-conferences.org

Internet Source

<1 %

28

Gonçalo Hora de Carvalho, Twan Vos. "Deep Reinforcement Learning in High-Dimensional and Stochastic Environments A Short Introductory Literature Survey & Critical Methodological Review", Open Science Framework, 2024

Publication

<1 %

29	protan.studentjournal.ub.ac.id Internet Source	<1 %
30	sunenergy.id Internet Source	<1 %
31	Yurni Oktarina, Zainuddin Nawawi, Bakti Yudho Suprpto, Tresna Dewi. "Digitized Smart Solar Powered Agriculture Implementation in Palembang, South Sumatra", 2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI), 2023 Publication	<1 %
32	jurnal.alimspublishing.co.id Internet Source	<1 %
33	www.mdpi.com Internet Source	<1 %
34	www.jurnal.unsyiah.ac.id Internet Source	<1 %
35	belajarmikrokontroller2022.blogspot.com Internet Source	<1 %
36	repository.uinsu.ac.id Internet Source	<1 %
37	Sayyidina Ali Hidayatullah, Styawati Styawati. "Rancang Bangun Single-Axis Solar Tracker	<1 %

untuk Pembangkit Listrik Tenaga Surya Skala Kecil", Jurnal Pepadun, 2024

Publication

38

repository.ittelkom-pwt.ac.id

Internet Source

<1 %

39

www.walshmedicalmedia.com

Internet Source

<1 %

40

eprints.undip.ac.id

Internet Source

<1 %

41

sista.polindra.ac.id

Internet Source

<1 %

42

rifqimulyawan.com

Internet Source

<1 %

43

www.medicalogy.com

Internet Source

<1 %

44

Anuj Kumar Singh, Sachin Kumar. "Security, Privacy, and Trust in WBANs and E-Healthcare", CRC Press, 2024

Publication

<1 %

45

Muhammad Zuhdi Sasongko, Sucipto Sucipto. "Desain Prototype IoT Menggunakan Bot Telegram Berbasis Text Recognition", RESEARCH : Journal of Computer, Information System & Technology Management, 2021

Publication

<1 %

library.stmikgici.ac.id

46

Internet Source

<1 %

47

repository.teknokrat.ac.id

Internet Source

<1 %

48

www.kompasiana.com

Internet Source

<1 %

49

eprints.umm.ac.id

Internet Source

<1 %

50

etheses.uin-malang.ac.id

Internet Source

<1 %

51

id.123dok.com

Internet Source

<1 %

52

jurnal.umsu.ac.id

Internet Source

<1 %

53

ojs.unud.ac.id

Internet Source

<1 %

54

perpustakaan.poltekkes-malang.ac.id

Internet Source

<1 %

55

simakip.uhamka.ac.id

Internet Source

<1 %

56

id.scribd.com

Internet Source

<1 %

57

Puji Setiyawan, Sukarno Budi Utomo, Agus Adhi Nugroho. "Analisa Optimasi

<1 %

Photovoltaic(PV) 100 W Menggunakan MPPT dengan Alogaritma Perturb dan Observe", Elektrika, 2021

Publication

58

Zeghdoud Sabrina, Teguig Djamel, Tanougast Camel, Mesloub Ammar, Sadoudi Said, Nesraoui Okba. "SDR Implementation of Spectrum Sensing using Deep Learning", International Journal of Sensors, Wireless Communications and Control, 2023

Publication

<1 %

59

repository.upi.edu

Internet Source

<1 %

60

journal.ittelkom-sby.ac.id

Internet Source

<1 %

61

ojs.unikom.ac.id

Internet Source

<1 %

62

eprints.utdi.ac.id

Internet Source

<1 %

63

kledo.com

Internet Source

<1 %

64

prabugomong.wordpress.com

Internet Source

<1 %

65

www.slideshare.net

Internet Source

<1 %

publikasi.mercubuana.ac.id

66

Internet Source

<1 %

67

repository.penerbiteureka.com

Internet Source

<1 %

68

agrifoodmagazine.co.in

Internet Source

<1 %

69

doku.pub

Internet Source

<1 %

70

issuu.com

Internet Source

<1 %

71

pers.pnm.ac.id

Internet Source

<1 %

72

polinema.gitbook.io

Internet Source

<1 %

73

repositori.usu.ac.id

Internet Source

<1 %

74

repository.unj.ac.id

Internet Source

<1 %

75

repository.widyatama.ac.id

Internet Source

<1 %

76

sdgs.telkomuniversity.ac.id

Internet Source

<1 %

77

[Aleksius Madu. "COMPARISON OF TREND PROJECTION METHODS AND](#)

<1 %

BACKPROPAGATION PROJECTIONS METHODS
TREND IN PREDICTING THE NUMBER OF
VICTIMS DIED IN TRAFFIC ACCIDENT IN
TIMOR TENGAH REGENCY, NUSA
TENGGARA", Jurnal Mercumatika : Jurnal
Penelitian Matematika dan Pendidikan
Matematika, 2016

Publication

78

Nur Wakhidah, Prind Triajeng Pungkasanti,
Agusta Praba Ristadi Pinem. "Deteksi Objek
menggunakan Deep Learning untuk
Mengetahui Tingkat Kerumunan Mahasiswa",
Jurnal Edukasi dan Penelitian Informatika
(JEPIN), 2023

Publication

<1 %

79

Rita Magdalena, Sofia Saidah, Nor Kumalasari
Caecar Pratiwi, Akbar Trisnamulya Putra.
"Klasifikasi Tutupan Lahan Melalui Citra Satelit
SPOT-6 dengan Metode Convolutional Neural
Network (CNN)", Jurnal Edukasi dan Penelitian
Informatika (JEPIN), 2021

Publication

<1 %

80

baskomnews.com

Internet Source

<1 %

81

centralai.id

Internet Source

<1 %

82

ejournal.akprind.ac.id

Internet Source

<1 %

83	jiat.uib.ac.id Internet Source	<1 %
84	jurnal.polibatam.ac.id Internet Source	<1 %
85	kabar-terhangat.blogspot.com Internet Source	<1 %
86	pt.scribd.com Internet Source	<1 %
87	repository.trisakti.ac.id Internet Source	<1 %
88	Ορφανίδης, Ευθύμιος. "Χρήση Μεθόδων Μηχανικής Μάθησης στο Τομέα Της Εφοδιαστικής Αλυσίδας: Πρόβλεψη Backorder", University of Piraeus (Greece), 2024 Publication	<1 %
89	Abdurahman - Abdurahman, Elfirza - Rosiana, Heri - Kusnadi, Toto - Raharjo. "Sistem Monitoring Panel Surya Berbasis Web", Jurnal Sistem dan Teknologi Informasi (JustIN), 2024 Publication	<1 %
90	Ezha Tiara, Ikhwan Ruslianto, Suhardi Suhardi. "Sistem Pemantauan dan Kendali Kelembapan Tanah dan PH pada Tanaman Anggur Berbasis Android (Studi Kasus:	<1 %

Greenhouse FMIPA UNTAN)", Coding Jurnal Komputer dan Aplikasi, 2023

Publication

91 Syahrul Gunawan Ramdhani, Enny Itje Sela. "Implementasi Face Recognition Untuk Sistem Presensi Universitas Menggunakan Convolutional Neural Network", Indonesian Journal of Computer Science, 2023

Publication

92 abaa.uobaghdad.edu.iq <1 %

Internet Source

93 bogordaily.net <1 %

Internet Source

94 core.ac.uk <1 %

Internet Source

95 digilib.unisayogya.ac.id <1 %

Internet Source

96 dokumen.tips <1 %

Internet Source

97 download.garuda.ristekdikti.go.id <1 %

Internet Source

98 e-journal.ivet.ac.id <1 %

Internet Source

99 ejournal.bsi.ac.id <1 %

Internet Source

100	ejurnal.its.ac.id Internet Source	<1 %
101	eprints.umsb.ac.id Internet Source	<1 %
102	es.scribd.com Internet Source	<1 %
103	journal.ipb.ac.id Internet Source	<1 %
104	jurnal.una.ac.id Internet Source	<1 %
105	openresearch-repository.anu.edu.au Internet Source	<1 %
106	paralayangdimalang.blogspot.co.id Internet Source	<1 %
107	pt.slideshare.net Internet Source	<1 %
108	repository.poliupg.ac.id Internet Source	<1 %
109	umpir.ump.edu.my Internet Source	<1 %
110	www.bartleby.com Internet Source	<1 %
111	www.grafiati.com Internet Source	<1 %

112	www.kiostiket.com Internet Source	<1 %
113	www.scribd.com Internet Source	<1 %
114	zh.scribd.com Internet Source	<1 %
115	www.batamnews.co.id Internet Source	<1 %
116	www.sharemaz.com Internet Source	<1 %
117	Dudi Septiadi, Ni Made Wirastika Sari, Ahmad Zainuddin. "Analisis Permintaan Konsumsi Cabai Rawit pada Rumah Tangga di Kota Mataram", AGRIMOR, 2020 Publication	<1 %
118	Sriyani Violina, Niken Rosiana Damayanti, Iwa Ovyawan Herlistiono. "Deteksi Dan Klasifikasi Citra Kanker Darah Menggunakan Metode Convolutional Neural Network (CNN)", INTECOMS: Journal of Information Technology and Computer Science, 2024 Publication	<1 %
119	dspace.uii.ac.id Internet Source	<1 %
120	manajemenelektrounsrat.wordpress.com Internet Source	<1 %

121

ojs.uho.ac.id

Internet Source

<1 %

122

repository.usd.ac.id

Internet Source

<1 %

Exclude quotes Off

Exclude matches Off

Exclude bibliography On

laporan disertasi REVISI 4 turnitin.pdf

PAGE 1

PAGE 2

PAGE 3

PAGE 4

PAGE 5

PAGE 6

PAGE 7

PAGE 8

PAGE 9

PAGE 10

PAGE 11

PAGE 12

PAGE 13

PAGE 14

PAGE 15

PAGE 16

PAGE 17

PAGE 18

PAGE 19

PAGE 20

PAGE 21

PAGE 22

PAGE 23

PAGE 24

PAGE 25

PAGE 26

PAGE 27

PAGE 28

PAGE 29

PAGE 30

PAGE 31

PAGE 32

PAGE 33

PAGE 34

PAGE 35

PAGE 36

PAGE 37

PAGE 38

PAGE 39

PAGE 40

PAGE 41

PAGE 42

PAGE 43

PAGE 44

PAGE 45

PAGE 46

PAGE 47

PAGE 48

PAGE 49

PAGE 50

PAGE 51

PAGE 52

PAGE 53

PAGE 54

PAGE 55

PAGE 56

PAGE 57

PAGE 58

PAGE 59

PAGE 60

PAGE 61

PAGE 62

PAGE 63

PAGE 64

PAGE 65

PAGE 66

PAGE 67

PAGE 68

PAGE 69

PAGE 70

PAGE 71

PAGE 72

PAGE 73

PAGE 74

PAGE 75

PAGE 76

PAGE 77

PAGE 78

PAGE 79

PAGE 80

PAGE 81

PAGE 82

PAGE 83

PAGE 84

PAGE 85

PAGE 86

PAGE 87

PAGE 88

PAGE 89

PAGE 90

PAGE 91

PAGE 92

PAGE 93

PAGE 94

PAGE 95

PAGE 96

PAGE 97

PAGE 98

PAGE 99

PAGE 100

PAGE 101

PAGE 102

PAGE 103

PAGE 104

PAGE 105

PAGE 106

PAGE 107

PAGE 108

PAGE 109

PAGE 110

PAGE 111

PAGE 112

PAGE 113

PAGE 114

PAGE 115

PAGE 116

PAGE 117

PAGE 118

PAGE 119

PAGE 120

PAGE 121

PAGE 122

PAGE 123

PAGE 124

PAGE 125

PAGE 126

PAGE 127
