



- Hak Cipta Dilindungi Undang-undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
 - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
 2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

LAPORAN DISERTASI

MULTIMODAL SPATIO-TEMPORAL DOMAIN ADAPTATION **UNTUK KLASIFIKASI FASE FENOLOGI PADI PADA** **PERTANIAN VERTIKAL**

RIKI RULI AFFANDI SIREGAR



PROGRAM STUDI DOKTOR ILMU KOMPUTER
SEKOLAH SAINS DATA, MATEMATIKA DAN INFORMATIKA
INSTITUT PERTANIAN BOGOR
BOGOR
2026



PERNYATAAN MENGENAI DISERTASI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa disertasi dengan judul “*Multimodal Spatio-Temporal Domain Adaptation* untuk Klasifikasi Fase Fenologi Padi pada Pertanian Vertikal” adalah karya saya dengan arahan dari dosen pembimbing dan belum diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka di bagian akhir disertasi ini.

Dengan ini saya melimpahkan hak cipta dari karya tulis saya kepada Institut Pertanian Bogor.

Bogor, Juni 2026

Riki Ruli Affandi Siregar
G6601202010



RINGKASAN

RIKI RULI AFFANDI SIREGAR. *Multimodal Spatio-Temporal Domain Adaptation* untuk Klasifikasi Fase Fenologi Padi pada Pertanian Vertikal. Dibimbing oleh KUDANG BORO SEMINAR, SRI WAHJUNI dan EDI SANTOSA.

Penelitian ini dilatarbelakangi oleh semakin terbatasnya lahan pertanian produktif untuk budidaya padi, yang disebabkan oleh alih fungsi lahan, urbanisasi, serta perubahan iklim. Kondisi ini mendorong kebutuhan akan inovasi sistem budidaya alternatif yang mampu menjamin keberlanjutan produksi pangan, salah satunya melalui pendekatan *vertical farming*. Meskipun sistem ini telah banyak diterapkan pada komoditas hortikultura, implementasinya pada tanaman padi masih menghadapi berbagai tantangan, khususnya dalam pemantauan fase pertumbuhan secara akurat akibat kompleksitas interaksi antara morfologi tanaman dan dinamika lingkungan mikro. Tantangan ini menjadi semakin penting pada pengembangan padi fungsional (*functional rice*) atau padi dengan karakteristik khusus (misalnya tinggi nutrisi atau adaptif terhadap kondisi tertentu), yang membutuhkan kontrol lingkungan secara presisi. Permasalahan ini menjadi semakin penting pada pengembangan padi fungsional yang membutuhkan pengendalian lingkungan secara presisi dan berbasis data.

Penelitian ini bertujuan mengembangkan model klasifikasi fase pertumbuhan tanaman padi berbasis *multimodal deep learning* yang mampu mengintegrasikan data citra tanaman dan data sensor lingkungan, sekaligus memiliki kemampuan adaptasi terhadap perbedaan distribusi data antara lahan sawah konvensional dan lingkungan *vertical farming*. Model yang diusulkan menggunakan pendekatan *Multimodal Spatio-Temporal Domain Adaptation* (MST-DA) dengan menggabungkan fitur spasial dari citra tanaman menggunakan CNN dan fitur temporal dari data sensor menggunakan LSTM. Beberapa *backbone* CNN yang digunakan meliputi ResNet50, MobileNet, VGG19, dan Xception. Model melakukan klasifikasi terhadap delapan kelas fase fenologi tanaman padi, yaitu persemaian, vegetatif awal, anakan maksimum, inisiasi malai, bunting, pengisian gabah, pematangan, dan Pra-Panen. Proses klasifikasi memanfaatkan fitur spasial yang diekstraksi dari citra tanaman, meliputi karakteristik morfologi, warna daun, tekstur, bentuk tajuk, serta kerapatan vegetasi. Selain itu, model juga memanfaatkan fitur temporal yang berasal dari data sensor lingkungan, meliputi suhu udara, kelembapan udara, intensitas cahaya, kelembapan tanah, pH air, pH tanah yang direkam secara berkala selama proses pertumbuhan tanaman.

Untuk meningkatkan kualitas integrasi *multimodal*, penelitian ini mengimplementasikan mekanisme *Cross-Modal Attention* yang memungkinkan model memberikan bobot perhatian adaptif terhadap fitur sensor yang relevan dengan fitur citra. Mekanisme ini terbukti mampu memperkuat hubungan antara perubahan morfologi tanaman dan variasi parameter lingkungan, sehingga menghasilkan representasi fitur yang lebih informatif dan diskriminatif. Selain itu, pendekatan MST-DA diterapkan melalui penggunaan *Gradient Reversal Layer* (GRL) dan *Maximum Mean Discrepancy* (MMD) untuk meminimalkan *domain shift* antara domain sumber dan target.

Hasil eksperimen menunjukkan bahwa model MST-DA mampu mengatasi perbedaan distribusi data antara domain sumber dan domain target secara efektif. Pada konfigurasi optimal $\lambda_{MMD} = 0,1$ dan $\alpha = 20$, model mencapai *accuracy* sebesar 91,48%, *F1-score* sebesar 83,74%, dan *Mean Intersection over Union (Mean IoU)* sebesar 73,77%. Selama proses pelatihan, nilai *loss* menurun secara konsisten yang menunjukkan konvergensi model yang baik, sementara *domain accuracy* pada domain sumber dan domain target menurun hingga mendekati distribusi acak ($\approx 0,10-0,15$), mengindikasikan bahwa model berhasil mempelajari representasi fitur yang semakin *domain-invariant*. Hasil tersebut menunjukkan bahwa pendekatan MST-DA mampu meningkatkan kemampuan generalisasi model dalam melakukan klasifikasi fase fenologi padi pada lingkungan *vertical farming*.

Temuan utama dari penelitian ini menunjukkan bahwa integrasi antara *Cross-Modal Attention* dan *domain adaptation* mampu meningkatkan kualitas representasi fitur serta memperkuat kemampuan model dalam menghadapi heterogenitas data pertanian lintas domain. Kebaruan penelitian ini terletak pada pengembangan arsitektur MST-DA yang mengintegrasikan pembelajaran spasial-temporal, mekanisme perhatian lintas modalitas, dan *domain adaptation* dalam satu kerangka terpadu untuk klasifikasi fase pertumbuhan padi berbasis IoT *vertical farming*.

Dari sisi ilmiah, penelitian ini memperluas penerapan *domain adaptation* pada bidang pertanian cerdas, khususnya pada data *multimodal* yang bersifat dinamis dan heterogen. Dari sisi implementasi, model yang dikembangkan berpotensi diterapkan pada sistem *smart farming* berbasis IoT untuk mendukung pemantauan pertumbuhan tanaman secara otomatis, adaptif, dan berbasis data dalam lingkungan *vertical farming*.

Kata kunci: adaptasi *domain*, *cross-modal attention*, *deep learning multimodal*, fase pertumbuhan padi, *vertical farming*



SUMMARY

RIKI RULI AFFANDI SIREGAR. Multimodal Spatio-Temporal Domain Adaptation for Classifying Rice Phenological Stages in Vertical Farming. Supervised by KUDANG BORO SEMINAR, SRI WAHJUNI, and EDI SANTOSA.

This research was motivated by the increasing scarcity of productive agricultural land for rice cultivation due to land-use conversion, urbanization, and climate change. These challenges have created an urgent need for innovative alternative cultivation systems capable of ensuring sustainable food production, one of which is vertical farming. Although this cultivation system has been widely implemented for horticultural crops, its application to rice cultivation remains challenging, particularly in accurately monitoring rice growth stages because of the complex interactions between plant morphology and microenvironmental dynamics. These challenges become even more critical in the development of functional rice, which requires precise and data-driven environmental control throughout the cultivation process.

This study aims to develop a multimodal deep learning model for rice growth stage classification by integrating plant image data and environmental sensor data while adapting to distribution discrepancies between conventional paddy fields and vertical farming environments. The proposed Multimodal Spatio-Temporal Domain Adaptation (MST-DA) framework combines spatial feature extraction from plant images using Convolutional Neural Networks (CNNs) with temporal feature learning from environmental sensor data using Long Short-Term Memory (LSTM) networks. Four CNN backbone architectures, namely ResNet50, MobileNet, VGG19, and Xception, were employed to evaluate their feature extraction capabilities. The proposed model classifies rice plants into eight phenological stages: seedling, early vegetative, maximum tillering, panicle initiation, booting, grain filling, ripening, and pre-harvest. The classification process utilizes spatial features extracted from plant images, including plant morphology, leaf color, texture, canopy structure, and vegetation density. In addition, temporal features are extracted from environmental sensor data, including air temperature, relative humidity, light intensity, soil moisture, water pH, and soil pH, which are continuously recorded throughout the plant growth cycle.

To enhance multimodal feature integration, this study incorporates a Cross-Modal Attention mechanism that enables the model to assign adaptive attention weights to environmental sensor features according to their relevance to visual features extracted from plant images. This mechanism effectively strengthens the relationship between changes in plant morphology and variations in environmental conditions, thereby producing more informative and discriminative feature representations. Furthermore, the proposed MST-DA framework integrates a Gradient Reversal Layer (GRL) and Maximum Mean Discrepancy (MMD) to minimize domain shift between the source and target domains.

Experimental results demonstrate that the proposed MST-DA model effectively addresses differences in data distribution between the source and target domains. Under the optimal parameter configuration ($\lambda_{\text{MMD}} = 0.1$ and $\alpha = 20$), the model achieved an accuracy of 91.48%, an F1-score of 83.74%, and a Mean



Intersection over Union (Mean IoU) of 73.77%. During the training process, the loss consistently decreased, indicating stable model convergence, while the domain classification accuracy in both the source and target domains decreased to values close to a random distribution ($\approx 0,10-0,15$), demonstrating that the proposed framework successfully learned increasingly domain-invariant feature representations. These results indicate that the MST-DA approach effectively improves the model's generalization capability for rice phenological stage classification in vertical farming environments.

The findings of this study demonstrate that the integration of Cross-Modal Attention and domain adaptation enhances the quality of feature representations and improves the model's robustness in handling heterogeneous agricultural data across different domains. The primary novelty of this research lies in the development of a unified MST-DA framework that integrates spatiotemporal learning, cross-modal attention, and domain adaptation into a single architecture for IoT-based rice phenological stage classification in vertical farming. From a scientific perspective, this study extends the application of domain adaptation in smart agriculture, particularly for dynamic and heterogeneous multimodal data. From a practical perspective, the proposed model has strong potential for implementation in IoT-enabled smart farming systems to support automated, adaptive, and data-driven monitoring of rice growth in vertical farming environments.

Keywords: cross-modal attention, domain adaptation, multimodal deep learning, rice growth stages, vertical farming



Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
 - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

© Hak Cipta milik IPB, tahun 2026
Hak Cipta dilindungi Undang-Undang

Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan atau menyebutkan sumbernya. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik, atau tinjauan suatu masalah, dan pengutipan tersebut tidak merugikan kepentingan IPB.

Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apa pun tanpa izin IPB.

MULTIMODAL SPATIO-TEMPORAL DOMAIN ADAPTATION UNTUK KLASIFIKASI FASE FENOLOGI PADI PADA PERTANIAN VERTIKAL

RIKI RULI AFFANDI SIREGAR

Disertasi
Sebagai salah satu syarat untuk memperoleh gelar
Doktor pada
Program Studi Ilmu Komputer

**PROGRAM STUDI DOKTOR ILMU KOMPUTER
SEKOLAH SAINS DATA, MATEMATIKA DAN INFORMATIKA
INSTITUT PERTANIAN BOGOR
BOGOR
2026**



@Hak cipta milik IPB University

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
 - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

Penguji Luar Komisi Pembimbing pada Ujian Tertutup Disertasi:

- 1 Dr. Eng. Annisa, S.Kom., M.Kom
- 2 Prof. Dr. Ir. Iskandar Lubis, M.S

Promotor Luar Komisi Pembimbing pada Sidang Promosi Terbuka Disertasi:

- 1 Dr. Eng. Annisa, S.Kom., M.Kom
- 2 Dr. Ir. Hoetomo Lembito, MBA, CSLP, CMILT



Judul Disertasi : *Multimodal Spatio-Temporal Domain Adaptation Untuk Klasifikasi Fase Fenologi Padi Pada Pertanian Vertikal*
Nama : Riki Ruli Affandi Siregar
NIM : G6601202010

Disetujui oleh

Pembimbing 1:

Prof. Dr. Ir. Kudang Boro Seminar, M.Sc

Pembimbing 2:

Dr. Ir. Sri Wahjuni, M.T.

Pembimbing 3:

Prof. Dr. Edi Santosa S.P., M.Si

Diketahui Oleh

Ketua Program Studi:

Prof. Dr. Imas Sukaesih Sitanggang, S.Si, M.Kom
NIP 19750130 199802 2 001

Dekan Sekolah Sains Data Matematika dan Informatika:

Prof. Dr. Ir. Agus Buono, M.Si, M.Kom
NIP 196607021993011001

Tanggal Ujian:
25 Mei 2026

Tanggal Lulus:



PRAKATA

Puji dan syukur penulis panjatkan kepada Allah subhanahu wa ta'ala atas segala karunia-Nya sehingga karya ilmiah ini berhasil diselesaikan. Tema yang dipilih dalam penelitian yang dilaksanakan sejak bulan Oktober 2022 sampai bulan Desember 2025 ini adalah “*Multimodal Spatio-Temporal Domain Adaptation* untuk Klasifikasi Fase Fenologi Padi pada Pertanian Vertikal”.

Terima kasih penulis ucapkan kepada para pembimbing, Prof. Dr. Ir. Kudang Boro Seminar, M.Sc., Dr. Ir. Sri Wahjuni, M.T., dan Prof. Dr. Edi Santosa, S.P., M.Si., yang telah membimbing dan banyak memberi saran. Ucapan terima kasih juga disampaikan kepada penguji luar komisi pembimbing Prof Anang Kurnia, S.Si., M.Si., Dr. Eng. Annisa, S.Kom., M.Kom., Prof. Dr. Ir. Iskandar Lubis, M.S., Dr. Hendra Rahmawan, S.Kom., M.T. Dr. Ir. Hoetomo Lembito, MBA, CSLP., CMIL., dan Dr. Karlisa Priandana, S.T., M.Eng. Di samping itu, penghargaan penulis sampaikan kepada:

1. Istri tercinta Dyah Kumalasari, serta anak tersayang Fachri Khadhafi Aksara Siregar dan Adzkia Khumairoh Zahrah Siregar yang tak henti-henti mendoakan dan memberikan semangat untuk menyelesaikan disertasi ini, serta selalu sabar dan selalu bertanya “kapan lulus”.
2. Orang tua tersayang, Papa Ruslan Siregar dan Mama Rukiah Harahap, tak henti-henti mendoakan dan memberikan kasih sayangnya. Ibu Mertua Siti Hadidjah serta kedua adik, Ridho Ali Fitrah Siregar dan Rindra Mahendra Sakti Siregar, dan juga Kakak Ipar M. Sholeh dan Erni Kusumawati serta Nuria Wulandari dan Aditya Barly yang tetap memberikan dukungan dalam pelaksanaan studi ini.
3. Rektor IPB, Pimpinan dan staf Sekolah Pasca Sarjana IPB, Dekan dan Wakil Dekan Pimpinan dan Staff Sekolah Sains, Data, Matematika dan Informatika (SSMI) IPB, Ketua Departemen Ilmu Komputer, Kepada Dr. Sony Hartono Wijaya, S.Kom., M.Kom., Ketua Program Studi Doktor Ilmu Komputer, Prof. Dr. Imas Sukaesih Sitanggang, S.Si., M.Kom., Sekretaris Program Doktor Ilmu Komputer, Dr. Hendra Rahmawan, S.Kom., M.T, Ibu Nining Rohaniah dan semua dosen di Departemen Ilmu Komputer IPB University, yang telah banyak membantu studi S3 sampai disertasi ini diselesaikan dengan baik.
4. Rektor Institut Teknologi PLN, Prof. Dr. Ir. Iwa Garniwa, M.T., para Wakil Rektor, Prof. Ir. Syamsir Abduh, PhD. IPU. ASEAN. Eng, Dekan Fakultas Telematika Energi beserta seluruh staf dosen serta tim laboratorium dan seluruh jajarannya yang memberikan dukungan dalam pelaksanaan studi ini.
5. Rekan-rekan seluruh angkatan mahasiswa Program Doktor Ilmu Komputer dan rekan-rekan seperjuangan bimbingan Iriansyah BM Sangadji, Abdul Haris, Dedeng Hirawan, Joko Sarjonoko, Andri, Harry Imanto yang selalu saling membantu dalam pelaksanaan studi dan riset, berbagi pengetahuan dan pengalaman selama studi ini.
6. Tim riset Prof. Dr. Indrianto, Dr. Puji Catur Siswipratini, Dr. Efy Yosrita, Rosida Nur Aziza, Rahma Farah Ningrum, Yozika Arvio, Dine Tiara K, Karina Djunaidi.
7. Bapak Akhmad Fauzi, Direktur PT. Firda Jaya, yang membantu dalam penyusunan dan pencetakan disertasi ini.



8. Pihak-pihak yang tidak bisa disebutkan satu per satu yang mendukung dan membantu dalam proses menyelesaikan studi S3 dan pelaksanaan penelitian ini.

Semoga karya ilmiah ini bermanfaat bagi pihak yang membutuhkan dan bagi kemajuan ilmu pengetahuan.

Bogor, Juni 2026

Riki Ruli Affandi Siregar



DAFTAR ISI

DAFTAR ISI	xvii
DAFTAR TABEL	xix
DAFTAR GAMBAR	xx
DAFTAR LAMPIRAN	xxiii
DAFTAR ISTILAH	xxiv
I PENDAHULUAN	1
1.1 Latar Belakang	2
1.2 Perumusan Masalah	5
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	6
1.5 Ruang Lingkup Penelitian	7
1.6 Kebaruan Penelitian	8
II TINJAUAN PUSTAKA	9
2.1 <i>Deep Learning</i>	9
2.2 <i>Convolutional Neural Networks (CNN)</i>	9
2.3 <i>Visual Geometry Group (VGG)</i>	16
2.4 <i>Residual Networks (ResNet)</i>	16
2.5 <i>MobileNet</i>	17
2.6 <i>Xception (Extreme Inception)</i>	19
2.7 <i>Long Short-Term Memory (LSTM)</i>	20
2.8 <i>Hybrid Deep Learning Data Multimodal</i>	22
2.9 <i>Domain Adaptation</i>	25
2.10 <i>Cross-Modal Attention Mechanism</i>	27
2.12 <i>State of the art Penelitian</i>	30
2.2 Objek Kajian Penelitian	42
III METODE	48
3.1 Kerangka Pemikiran Penelitian	48
3.2 Justifikasi Pemilihan <i>Backbone</i> CNN	49
3.3 Justifikasi Temporal Modeling pada LSTM	51
3.4 Tahapan Penelitian	52
3.5 Waktu dan Tempat Penelitian	54
3.6 Alat dan Bahan	55
3.7 Model Sistem Usulan Lahan Pertanian Vertikal Tanaman Padi	55
3.8 Gambaran Umum Sistem	57
3.9 Desain Skenario Pengujian	59
3.10 Kerangka Kerja <i>Hybrid Deep Learning</i> yang Diusulkan	61
3.11 Akuisisi Data dan Deskripsi Dataset	65
3.12 Akuisisi Data <i>Multimodal</i> Pertanian Sawah dan Vertikal	69
3.13 <i>Data Preprocessing</i> dan Penyelesaian Data	71
3.14 <i>Arsitektur Hybrid Deep Learning Multi-Input</i>	78
3.15 <i>Arsitektur Multimodal Spasial Temporal Domain Adaptation</i>	87
3.16 <i>Adaptasi Adversarial Learning Integrasi Cross-Modal Attention</i>	90

IV	HASIL DAN PEMBAHASAN	102
4.1	Gambaran Umum Eksperimen	102
4.2	Pengumpulan Dataset	102
4.3	Hasil Tahapan Pra Proses Data <i>Multimodal</i>	106
4.4	Hasil Model <i>Hybrid CNN-LSTM Multimodal</i>	107
4.5	Hasil Model <i>Hybrid Multimodal</i> dengan <i>Domain Adaptation</i>	118
4.5.1	Konfigurasi Pelatihan Model	118
4.5.2	Pendekatan <i>Pseudo-Labeling</i> Berbasis Kepercayaan Model	122
4.5.3	Implementasi <i>Domain-Adversarial Neural Network</i> (DANN)	127
4.5.4	Skenario DANN dengan Mekanisme <i>Cross-Modal Attention</i>	130
4.5.5	Skenario Pengujian dan Evaluasi Parameter Model MST-DA	134
4.5.5.1	Evaluasi dan Pembahasan Parameter $\lambda mmd = 0,01$ dan $grl_alpha_scaling = \{1, 5, 10, 20\}$	135
4.5.5.2	Evaluasi dan Pembahasan Parameter $\lambda mmd = 0,1$ dan $grl_alpha_scaling = \{1, 5, 10, 20\}$	140
4.5.5.3	Evaluasi dan Pembahasan Parameter $\lambda mmd = 0,5$ dan $grl_alpha_scaling = \{1, 5, 10, 20\}$	143
4.5.5.4	Evaluasi dan Pembahasan Parameter $\lambda mmd = 1,0$ dan $grl_alpha_scaling = \{1, 5, 10, 20\}$	145
4.5.5.5	Evaluasi dan Pembahasan Parameter $\lambda mmd = 5,0$ dan $grl_alpha_scaling = \{1, 5, 10, 20\}$	147
4.5.5.6	Evaluasi dan Pembahasan Parameter $\lambda mmd = 10,0$ dan $grl_alpha_scaling = \{1, 5, 10, 20\}$	149
4.5.6	Integrasi Analisis Multi-Visualisasi pada Model MST-DA	161
4.5.6.1	Konsisten pada Performa dari <i>Multimodal CNN-LSTM</i>	161
4.5.6.2	Validasi Kinerja melalui <i>Confusion Matrix</i>	161
4.5.6.3	Analisis Representasi Fitur dan <i>Domain Alignment</i>	162
4.5.6.4	Reduksi <i>Domain Gap</i> sebagai Indikator Keberhasilan Adaptasi	162
4.5.6.5	Analisis <i>Trade-off Domain Invariance</i> dan <i>Discriminability</i>	162
4.5.6.6	Validasi <i>Multi-Objektif Pareto Frontier</i> dan <i>Radar Chart</i>	162
4.5.6.7	<i>Ablation Study</i> dan Mekanisme <i>Dual-Control</i> MST-DA	162
4.5.6.8	Implikasi terhadap Sistem Pertanian Padi Vertikal Berbasis IoT	163
4.5.7	Aplikasi MST-DA pada Lahan <i>Vertikal Farming</i> Berbasis IoT	163
4.5.8	Kontribusi, <i>Novelty</i> dan Penguatan Ilmiah Penelitian MST-DA	166
4.6	Keterbatasan Penelitian	168
V	SIMPULAN DAN SARAN	170
5.1	Simpulan	170
5.2	Saran	171
	DAFTAR PUSTAKA	173
	LAMPIRAN	183
	RIWAYAT HIDUP	221

DAFTAR TABEL

1	Sistematika <i>literature review</i> pertanian vertikal cerdas	31
2	Sistematika <i>literature review</i> AI dengan tanaman padi	32
3	Perbandingan literatur lain dengan usulan penelitian	34
4	Studi penggunaan AI untuk pengembangan pertanian vertikal cerdas	39
5	Aplikasi IoT dalam pertanian vertikal	39
6	<i>Matrix Research Gap</i>	41
7	Kriteria Fase Pertumbuhan Tanaman Padi	44
8	Fase pertumbuhan tanaman padi dan karakteristik morfologis	45
9	Justifikasi Metodologis Pemilihan <i>Backbone</i> CNN	50
10	Desain eksperimen pada model MST-DA mencakup data, arsitektur, metode adaptasi domain, serta strategi evaluasi dan analisis.	61
11	Statistik deskriptif parameter lingkungan direkam oleh sensor IoT dalam sistem budidaya padi <i>vertical farming</i> periode pemantauan.	67
12	Dimensi tensor setiap layer	83
13	Data citra tanaman padi dalam 15 hari	72
14	Data Sensor Lingkungan (Interval 10 Menit)	72
15	Data Sensor Lingkungan (dalam 1 jam)	73
16	Rata-rata fitur sensor (dalam 1 jam)	73
17	Dataset setelah <i>timestamp alignment</i>	73
18	Data <i>Source Domain</i> (Sawah Konvensional)	91
19	Data <i>Target Domain</i> (<i>Vertical Farming</i>)	91
20	Perbedaan data sawah dan data <i>vertical farm</i>	92
21	Perbandingan hasil sebelum dan sesudah <i>domain adaptation</i>	98
22	Dataset citra tanaman padi dari lahan sawah	103
23	<i>Hyperparameter</i> Pelatihan Model CNN dan CNN-LSTM	107
24	Perbandingan <i>precision model</i> pada setiap fase pertumbuhan padi	110
25	Perbandingan <i>recall model</i> pada setiap fase pertumbuhan padi	110
26	Perbandingan <i>F1-score model</i> pada setiap fase pertumbuhan padi	111
27	Perbandingan <i>Intersection over Union</i> (IoU) dari data <i>Precision</i> dan <i>Recall model</i> pada setiap fase pertumbuhan padi	113
28	Hasil ranking model berdasarkan average F1 score dan IoU pada setiap fase pertumbuhan padi	114
29	Model <i>Multimodal</i> CNN-LSTM dengan Mekanisme <i>Domain Adaptation</i> untuk Klasifikasi Fase Fenologi Padi.	119
30	Konfigurasi parameter pelatihan dan pengujian model <i>deep learning</i>	121
31	Skenario eksperimen komparatif antar model	121
32	Konfigurasi skenario metode <i>domain adaptation</i>	121
33	Hasil pelatihan model MST-DA selama 30 <i>epoch</i>	131
34	Skenario Pengujian Parameter MST-DA	134
35	Parameter pengujian <i>grid search</i>	134
36	Hasil Evaluasi <i>Grid Search Hyperparameter</i> pada Model MST-DA untuk variasi λ_{mmd} dan $grl_alpha_scaling$, ditinjau berdasarkan kinerja klasifikasi (<i>Accuracy</i> , <i>F1-score</i> , <i>Mean IoU</i>), dinamika konvergensi (<i>Loss</i>), serta efektivitas <i>domain adaptation</i> (<i>Domain Accuracy</i> dan karakteristik <i>training</i>).	159
37	Kontribusi, Novelty, dan Penguatan Ilmiah Penelitian MST-DA	166

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

DAFTAR GAMBAR

1	Arsitektur <i>Convolutional Neural Network</i>	10
2	<i>Pseudocode CNN</i>	13
3	Transpose 2D menjadi 1D	14
4	Arsitektur CNN berbasis transfer learning untuk klasifikasi kondisi daun padi	15
5	<i>Timeline</i> evolusi CNN <i>backbone</i> yang menjadi dasar pemilihan VGG, ResNet, MobileNet, dan Xception dalam penelitian ini	15
6	Arsitektur VGG 16(A) dan VGG 19(B)	16
7	Arsitektur Resnet50	17
8	Arsitektur MobileNet	18
9	Arsitektur Xception	19
10	Algoritma LSTM	20
11	Arsitektur Hybrid CNN–LSTM untuk Pemodelan Spatio-Temporal Data Sekuensial	24
12	Arsitektur <i>Domain Adaptation</i>	27
13	Tahapan <i>Systematic Literature Review</i> (SLR)	30
14	Kajian literatur dengan empat tahap evaluasi PRISMA	33
15	Distribusi literatur berdasarkan publikasi tahun 2016 hingga 2022	34
16	Distribusi literatur kuartil tahun 2016 hingga 2022	34
17	Jumlah artikel dalam sampel penelitian yang menyebutkan istilah-istilah penelitian tertentu	35
18	Jumlah artikel dengan menyebutkan <i>search keyword</i> pada Tabel 2	36
19	Sebaran artikel pada objek penelitian di bidang pertanian cerdas	37
20	Sebaran artikel pada metode di bidang pertanian cerdas	37
21	Sebaran artikel menggunakan metode <i>machine learning</i> dan <i>deep learning</i>	38
22	Sebaran artikel menggunakan arsitektur <i>deep learning</i>	38
23	Model pertanian vertikal padi Chengdu, Provinsi Sichuan, China	43
24	Tahap pertumbuhan tanaman padi	43
25	Kerangka konseptual dan metodologi penelitian	48
26	Tahapan penelitian	52
27	Usulan desain model lahan pertanian vertikal berbasis IoT	56
28	Diagram Blok Arsitektur Sistem MST-DA untuk Klasifikasi Fase Fenologi Padi dan Pengendalian Lingkungan pada <i>Vertical Farming</i> Berbasis IoT.	58
29	Desain Skenario Eksperimen <i>Multimodal Spatio-Temporal Domain Adaptation</i> (MST-DA)	59
30	Kerangka kerja <i>Hybrid Multimodal Spatio-Temporal Deep Learning</i> untuk klasifikasi fase pertumbuhan padi	62
31	Fase pertumbuhan tanaman padi	67
32	Dataset sensor lingkungan setelah proses pelabelan fase pertumbuhan	74
33	Dataset setelah dilakukan <i>timestamp alignment</i> citra dan sensor	74
34	Arsitektur model <i>hybrid CNN–LSTM</i> yang mengintegrasikan fitur spasial dari citra kanopi tanaman dan fitur temporal dari data sensor lingkungan untuk klasifikasi delapan fase pertumbuhan padi	78

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
- b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

35	<i>Pseudocode Algoritma Hybrid Multimodal CNN–LSTM</i>	84
36	Usulan Arsitektur MST-DA pada padi lahan sawah dan vertikal	88
37	Ilustrasi distribusi fitur <i>source domain</i> dan <i>target domain</i> sebelum proses <i>domain adaptation</i> (<i>domain shift</i>)	96
38	Ilustrasi distribusi fitur <i>source domain</i> dan <i>target domain</i> sesudah proses <i>domain adaptation</i>	99
39	Objek lahan vertikal pada tanaman padi	105
40	Hasil pelabelan dataset fase pertumbuhan tanaman padi	106
41	<i>Heatmap</i> nilai <i>F1-score</i> untuk berbagai arsitektur CNN dan hybrid CNN–LSTM pada klasifikasi fase pertumbuhan tanaman padi	112
42	Evaluasi performa model VGG19–LSTM dengan integrasi <i>Environmental Features</i> klasifikasi fase pertumbuhan tanaman padi.	115
43	Evaluasi performa model CNN–Xception–LSTM dengan integrasi <i>Environmental Features</i> klasifikasi fase pertumbuhan tanaman padi.	116
44	Perbandingan nilai <i>Mean Precision Score</i> dari beberapa arsitektur model CNN–LSTM dengan pendekatan Early Fusion	118
45	Data target dikelompokkan ke dalam himpunan data <i>confidence</i>	123
46	<i>Target domain</i> distribusi nilai kepercayaan (<i>confidence score</i>)	124
47	<i>Target Domain Pseudo-Label Distribution</i>	124
48	<i>Confusion matrix</i> dari data <i>domain source</i> MST-DA	126
49	Visualisasi menggunakan metode t-SNE MSTDA	127
50	Proses pelatihan MSTDA dengan 10 <i>epoch</i>	129
51	Proses pelatihan MSTDA dan GRL dengan 10 <i>epoch</i>	130
52	Proses pelatihan MSTDA dan GRL dengan 30 <i>epoch</i>	132
53	Evaluasi komprehensif pengaruh variasi <i>grl_alpha_scaling</i> terhadap konvergensi, performa klasifikasi, dan stabilitas <i>domain adaptation</i> pada model MST-DA dengan $\lambda_{mmd} = 0.01$, selama 30 <i>epoch</i> .	135
54	Perbandingan hasil Adaptasi Domain α ($\lambda = 0,01$) Berdasarkan Validation Accuracy, F1-score, dan IoU	136
55	Evaluasi komprehensif pengaruh variasi <i>grl_alpha_scaling</i> terhadap konvergensi, performa klasifikasi, dan stabilitas <i>domain adaptation</i> pada model MST-DA dengan $\lambda_{mmd} = 0.1$, d selama 30 <i>epoch</i> .	140
56	Perbandingan hasil Adaptasi Domain α ($\lambda = 0,1$) Berdasarkan Validation Accuracy, F1-score, dan IoU	141
57	Evaluasi komprehensif pengaruh variasi <i>grl_alpha_scaling</i> terhadap konvergensi, performa klasifikasi, dan stabilitas domain adaptation pada model MST-DA dengan $\lambda_{mmd} = 0.5$, selama 30 <i>epoch</i> .	143
58	Perbandingan hasil Adaptasi Domain α ($\lambda = 0,5$) Berdasarkan Validation Accuracy, F1-score, dan IoU	144
59	Evaluasi komprehensif pengaruh variasi <i>grl_alpha_scaling</i> terhadap konvergensi, performa klasifikasi, dan stabilitas domain adaptation pada model MST-DA dengan $\lambda_{mmd} = 1.0$, selama 30 <i>epoch</i> .	145
60	Perbandingan hasil Adaptasi Domain α ($\lambda = 1,0$) Berdasarkan Validation Accuracy, F1-score, dan IoU	146
61	Evaluasi komprehensif pengaruh variasi <i>grl_alpha_scaling</i> terhadap konvergensi, performa klasifikasi, dan stabilitas <i>domain adaptation</i> pada model MST-DA dengan $\lambda_{mmd} = 5.0$, selama 30 <i>epoch</i> .	147

62	Perbandingan hasil Adaptasi Domain α ($\lambda = 5,0$) Berdasarkan Validation Accuracy, F1-score, dan IoU	148
63	Evaluasi komprehensif pengaruh variasi <i>grl_alpha_scaling</i> terhadap konvergensi, performa klasifikasi, dan stabilitas <i>domain adaptation</i> pada model MST-DA dengan $\lambda_{mmd} = 10.0$, selama 30 <i>epoch</i> .	149
64	Perbandingan hasil Adaptasi Domain α ($\lambda = 10,0$) Berdasarkan Validation Accuracy, F1-score, dan IoU	150
65	Kinerja pelatihan MST-DA pada seluruh variasi <i>hyperparameter</i> λ dan skala GRL α ditinjau dari <i>loss</i> , akurasi validasi, F1-score, dan IoU	151
66	Kurva <i>Trade-off</i> antara Validation Accuracy dan Domain Accuracy untuk mengevaluasi keseimbangan kinerja klasifikasi dan adaptasi domain pada Model MST-DA	153
67	<i>Pareto Frontier</i> dalam menunjukkan hubungan kinerja klasifikasi dan kesenjangan domain pada Model MST-DA	154
68	<i>Domain Gap Reduction</i> terhadap <i>epoch</i> penyelarasan fitur pada model MST-DA dengan variasi parameter λ dan α .	155
69	<i>Ablation study</i> terhadap hubungan antara nilai λ (<i>lambda MMD/domain adaptation strength</i>) terhadap <i>Average Best F1-score</i> .	156
70	<i>Ablation Study</i> terhadap pengaruh parameter λ (MMD) dengan Representasi Variansi (<i>Mean $\pm$ Std</i>) pada F1-score	157
71	Visualisasi radar multi-metrik untuk analisis <i>trade-off</i> antara <i>classification performance</i> dan <i>domain invariance</i> pada model MST-DA dengan variasi parameter $\lambda_{\{mmd\}}$ dan α (GRL scaling)	158
72	Halaman utama <i>dashboard</i> klasifikasi kondisi lahan	164
73	Halaman <i>source domain</i> klasifikasi kondisi lahan	165
74	Halaman evaluasi dataset dan <i>confusion matrix</i>	165

DAFTAR LAMPIRAN

1	<i>Training Model CNN-LSTM (VGG19 dan Xception)</i>	199
2	<i>Starting Hyperparameter Search MST-DA (Lambda & Alpha)</i>	199



DAFTAR ISTILAH

<i>Accuracy</i>	: Tingkat ketepatan model dalam menghasilkan prediksi yang benar dibandingkan dengan seluruh data pengujian.
<i>Activation Function</i>	: Fungsi <i>non-linear</i> pada neuron untuk mengubah input menjadi <i>output</i> sehingga model mampu mempelajari pola kompleks.
<i>Adam Optimizer</i>	: Algoritma optimasi berbasis <i>adaptive learning</i> <i>rate</i> dan momentum untuk mempercepat konvergensi model <i>deep learning</i> .
<i>Adversarial Learning</i>	: Mekanisme pelatihan kompetitif antara <i>feature extractor</i> dan <i>domain classifier</i> untuk menghasilkan fitur <i>domain-invariant</i> .
<i>Alignment Phase</i>	: Tahap pelatihan domain adaptation terjadi ketika distribusi fitur <i>source</i> dan target mulai menyatu secara stabil.
<i>Artificial Intelligence (AI)</i>	: Cabang ilmu komputer yang mengembangkan sistem agar mampu meniru kecerdasan manusia dalam belajar dan pengambilan keputusan.
<i>Artificial Neural Network (ANN)</i>	: Model komputasi berbasis <i>neuron</i> yang meniru cara kerja jaringan saraf biologis.
<i>Automatic Weather Station (AWS)</i>	: Sistem pengukuran cuaca otomatis yang merekam parameter lingkungan seperti suhu, kelembapan, dan intensitas cahaya.
<i>Backbone Network</i>	: Arsitektur utama ekstraksi fitur pada <i>deep learning</i> , misalnya VGG19 atau ResNet.
<i>Backpropagation</i>	: Proses pembaruan bobot jaringan menggunakan propagasi <i>gradien error</i> dari <i>output</i> ke <i>input</i> .
<i>Bandwidth</i>	: Kapasitas maksimum transfer data dalam jaringan komunikasi per satuan waktu.
<i>Batch Normalization</i>	: Teknik normalisasi aktivasi untuk meningkatkan stabilitas dan kecepatan pelatihan model.
<i>Batch Size</i>	: Jumlah sampel data yang diproses dalam satu iterasi <i>training</i> .
<i>Bias</i>	: Parameter tambahan pada <i>neuron</i> untuk meningkatkan fleksibilitas model dalam mempelajari pola data.
<i>Booting Stage</i>	: Tahap awal pertumbuhan tanaman padi sebelum pembentukan malai secara penuh.



<i>Classification</i>	: Proses pengelompokan data ke dalam kelas tertentu berdasarkan karakteristik fitur.
<i>Classification Loss</i>	: Nilai kesalahan prediksi pada tugas klasifikasi yang digunakan untuk memperbarui parameter model.
<i>Cluster</i>	: Sekumpulan titik data dengan karakteristik fitur yang saling berdekatan pada ruang representasi.
<i>CNN (Convolutional Neural Network)</i>	: Arsitektur <i>deep learning</i> yang dirancang khusus untuk ekstraksi fitur citra.
<i>Concatenate Layer</i>	: Lapisan yang menggabungkan beberapa vektor fitur menjadi satu representasi gabungan.
<i>Confusion Matrix</i>	: Matriks evaluasi yang menunjukkan hubungan antara label aktual dan prediksi model.
<i>Convergence</i>	: Kondisi ketika proses training mulai stabil dan perubahan loss menjadi kecil antar epoch.
<i>ConvLSTM</i>	: Kombinasi CNN dan LSTM untuk memproses data spasial dan temporal secara simultan.
<i>Cross-Entropy Loss</i>	: Fungsi <i>loss</i> berbasis probabilitas untuk mengukur kesalahan klasifikasi multikelas.
<i>Cross-Modal Attention</i>	: Mekanisme <i>attention</i> untuk mempelajari hubungan antar fitur dari modalitas berbeda, seperti citra dan sensor.
<i>Data Augmentation</i>	: Teknik memperbanyak variasi data <i>training</i> melalui transformasi citra atau sinyal.
<i>Dataset</i>	: Kumpulan data yang digunakan untuk pelatihan, validasi, dan pengujian model.
<i>Deep Learning</i>	: Cabang <i>machine learning</i> berbasis jaringan saraf berlapis untuk mempelajari representasi fitur kompleks.
<i>Dense Layer</i>	: Lapisan <i>fully connected</i> yang menghubungkan seluruh <i>neuron</i> antar layer.
<i>Domain Adaptation</i>	: Teknik adaptasi model agar mampu bekerja pada distribusi data target yang berbeda dengan data sumber.
<i>Domain Classifier</i>	: Komponen model yang bertugas membedakan asal domain suatu fitur, apakah dari <i>source</i> atau target domain.
<i>Domain-Invariant Feature</i>	: Representasi fitur yang memiliki karakteristik serupa antar domain sehingga model lebih <i>generalizable</i> .
<i>Domain Loss</i>	: Nilai kesalahan pada proses klasifikasi domain <i>source</i> dan target dalam <i>domain adaptation</i> .
<i>Dropout</i>	: Teknik regularisasi dengan menonaktifkan sebagian <i>neuron</i> secara acak selama <i>training</i> untuk mengurangi <i>overfitting</i> .

Early Learning Phase

Early Stopping

Epoch

F1-Score

Feature Alignment

Feature Extraction

Feature Fusion

Feature Space

Fine-Tuning

Flatten

Flowering Stage

Fully Connected Layer

Fusion Layer

GAP (Global Average Pooling)

GPU (Graphics Processing Unit)

Gradient

Gradient Descent

Gradient Reversal Layer (GRL)

Hidden Layer

Hidden State

- : Fase awal *training* ketika model mulai mempelajari pola dasar data.
- : Teknik menghentikan *training* lebih awal untuk mencegah *overfitting* ketika performa validasi tidak meningkat lagi.
- : Satu siklus penuh proses pelatihan terhadap seluruh dataset *training*.
- : *Harmonic mean* digunakan untuk mengevaluasi keseimbangan performa klasifikasi antara *precision* dan *recall*.
- : Proses penyelarasan distribusi fitur antara domain sumber dan target.
- : Proses pengambilan representasi fitur penting dari data mentah.
- : Penggabungan fitur dari beberapa sumber data atau modalitas menjadi satu representasi bersama.
- : Ruang representasi matematis adalah tempat fitur data dipetakan.
- : Proses penyesuaian lanjutan model *pretrained* menggunakan dataset spesifik penelitian.
- : Proses mengubah data multidimensi menjadi vektor satu dimensi sebelum masuk ke *dense layer*.
- : Tahap pembungaan tanaman padi adalah ketika malai mulai mengeluarkan bunga.
- : Lapisan jaringan saraf di mana setiap neuron terhubung dengan seluruh neuron pada *layer* sebelumnya.
- : Lapisan penggabungan fitur *multimodal* dari citra dan sensor.
- : Teknik reduksi dimensi fitur dengan menghitung rata-rata global pada *feature map* CNN.
- : Perangkat keras komputasi paralel yang mempercepat proses *training deep learning*.
- : Turunan fungsi *loss* terhadap parameter model yang digunakan dalam optimasi.
- : Metode optimasi iteratif untuk meminimalkan fungsi *loss* model.
- : Layer pada *domain adaptation* yang membalik arah *gradien* untuk menghasilkan fitur *domain-invariant*.
- : Lapisan tersembunyi pada jaringan saraf yang melakukan transformasi fitur.
- : Representasi memori internal pada model LSTM atau RNN.

<i>H-ConvLSTM</i>	:	<i>Hybrid Convolutional LSTM</i> untuk pemodelan data spasial-temporal kompleks.
<i>Hyperparameter</i>	:	Parameter yang ditentukan sebelum proses training, seperti <i>learning rate</i> dan <i>batch size</i> .
<i>Image Preprocessing</i>	:	Tahapan pengolahan awal citra sebelum digunakan sebagai <i>input</i> model.
<i>Inference</i>	:	Proses penggunaan model terlatih untuk melakukan prediksi data baru.
<i>Input Layer</i>	:	Lapisan pertama yang menerima data masukan pada jaringan saraf.
<i>Internet of Things (IoT)</i>	:	Sistem perangkat yang saling terhubung untuk pengumpulan dan pertukaran data otomatis.
<i>Intersection over Union (IoU)</i>	:	Metrik evaluasi mengukur tingkat tumpang tindih antara prediksi dan <i>ground truth</i> .
<i>Kernel (Filter)</i>	:	Matriks kecil pada CNN digunakan untuk mengekstraksi fitur citra.
<i>Late Alignment Phase</i>	:	Tahap akhir <i>domain adaptation</i> ketika distribusi fitur <i>source</i> dan target semakin menyatu.
<i>Learning Rate</i>	:	Besar langkah pembaruan parameter model selama proses optimasi.
<i>Loss Function</i>	:	Fungsi matematis untuk mengukur tingkat kesalahan prediksi model.
<i>Long Short-Term Memory (LSTM)</i>	:	Jenis RNN yang mampu mempelajari dependensi jangka panjang pada data sekuensial.
<i>Machine Learning</i>	:	Cabang AI yang memungkinkan sistem belajar dari data tanpa diprogram secara eksplisit.
<i>Mean Squared Error (MSE)</i>	:	Fungsi <i>error</i> berbasis rata-rata kuadrat selisih antara prediksi dan nilai aktual.
<i>Mid Adaptation Phase</i>	:	Tahap pertengahan <i>training</i> ketika tekanan <i>adversarial</i> mulai meningkat.
<i>Model Generalization</i>	:	Kemampuan model menghasilkan performa yang baik pada data baru yang belum pernah dilatih.
<i>Model Training</i>	:	Proses pembelajaran model menggunakan data <i>training</i> dan optimasi parameter.
<i>Multimodal Learning</i>	:	Pendekatan pembelajaran yang mengintegrasikan beberapa jenis data, seperti citra dan sensor IoT.
<i>MST-DA</i>	:	<i>Multimodal Spatial-Temporal Domain Adaptation</i> adalah model yang menggabungkan data citra dan sensor temporal dengan <i>domain adaptation</i> .
<i>Normalization</i>	:	Proses penyesuaian skala data agar berada pada rentang tertentu.

Overfitting

Paddy Growth Stage

@ Hak cipta milik IPB University

Panicle Initiation

Pooling

Precision

Pretrained Model

Recall

ReLU (Rectified Linear Unit)

Representation Learning

Regression

ResNet

RNN (Recurrent Neural Network)

Sensor Alignment

Sensor Data

Sigmoid

Softmax

Source Domain

Spatial Feature

Smart Farming

Target Domain

Temporal Data

Temporal Feature

- : Kondisi ketika model terlalu menyesuaikan data *training* sehingga performa pada data baru menurun.
- : Tahapan pertumbuhan tanaman padi mulai dari vegetatif hingga pemasakan.
- : Tahap awal pembentukan malai pada tanaman padi.
- : Proses reduksi dimensi *feature map* CNN untuk mempertahankan fitur penting.
- : Tingkat ketepatan prediksi positif yang dihasilkan oleh model.
- : Model yang telah dilatih sebelumnya menggunakan dataset besar dan digunakan kembali melalui *transfer learning*.
- : Kemampuan model dalam menemukan seluruh data positif yang sebenarnya.
- : Fungsi aktivasi non-linear untuk mengatasi masalah *vanishing gradient*.
- : Proses pembelajaran representasi fitur otomatis oleh model *deep learning*.
- : Metode prediksi nilai kontinu berdasarkan hubungan antarvariabel.
- : *Backbone* CNN dengan *residual connection* untuk mengatasi degradasi jaringan dalam arsitektur yang dalam.
- : Arsitektur jaringan saraf untuk memproses data sekuensial atau temporal.
- : Proses sinkronisasi waktu antara data sensor dan data citra.
- : Data hasil pembacaan perangkat IoT seperti suhu, pH, kelembapan, dan cahaya.
- : Fungsi aktivasi *output* rentang 0 hingga 1.
- : Fungsi aktivasi untuk menghasilkan probabilitas pada klasifikasi multikelas.
- : Domain data asal yang memiliki label lengkap dan digunakan sebagai sumber pembelajaran model.
- : Fitur yang merepresentasikan karakteristik spasial atau visual pada citra.
- : Sistem pertanian berbasis teknologi digital dan IoT untuk meningkatkan efisiensi produksi.
- : Domain data tujuan yang memiliki distribusi berbeda dari *source domain*.
- : Data yang memiliki urutan atau ketergantungan waktu.
- : Fitur yang menggambarkan pola perubahan data berdasarkan waktu.

<i>Testing Set</i>	: Dataset yang digunakan untuk evaluasi akhir performa model.
<i>Time-Series</i>	: Data berurutan berdasarkan dimensi waktu.
<i>Transfer Learning</i>	: Teknik memanfaatkan model <i>pretrained</i> untuk tugas baru dengan data lebih sedikit.
<i>t-SNE (t-Distributed Stochastic Neighbor Embedding)</i>	: Metode reduksi dimensi untuk visualisasi distribusi fitur dalam ruang dua dimensi.
<i>Training Set</i>	: Dataset yang digunakan untuk melatih model <i>deep learning</i> .
<i>Validation Set</i>	: Dataset yang digunakan untuk memvalidasi performa model selama <i>training</i> .
VGG19	: Arsitektur CNN <i>pretrained</i> dengan 19 layer yang digunakan sebagai <i>backbone</i> ekstraksi fitur citra.
<i>Vertical Farming</i>	: Sistem pertanian bertingkat pada ruang terbatas dengan kontrol lingkungan terintegrasi.
<i>Vegetative Stage</i>	: Tahap pertumbuhan vegetatif tanaman sebelum pembentukan bunga dan malai.
<i>Yield Prediction</i>	: Prediksi hasil panen tanaman menggunakan model <i>machine learning</i> atau <i>deep learning</i> .

