

PENERAPAN PEMBELAJARAN MESIN (*MACHINE LEARNING*) DAN PEMBELAJARAN DALAM (*DEEP LEARNING*) BERKINERJA TINGGI UNTUK Mendukung SEKTOR PERTANIAN DI INDONESIA

**ORASI PENGUKUHAN PROFESOR RISET
BIDANG PENGOLAHAN SINYAL
MULTIMEDIA DAN KECERDASAN ARTIFISIAL**



OLEH:

HILMAN FERDINANDUS PARDEDE

BADAN RISET DAN INOVASI NASIONAL

**PENERAPAN PEMBELAJARAN MESIN
(*MACHINE LEARNING*) DAN PEMBELAJARAN
DALAM (*DEEP LEARNING*) BERKINERJA
TINGGI UNTUK Mendukung Sektor
PERTANIAN DI INDONESIA**

Buku ini tidak diperjualbelikan.

Diterbitkan pertama pada 2023 oleh Penerbit BRIN

Tersedia untuk diunduh secara gratis: penerbit.brin.go.id



Buku ini di bawah lisensi Creative Commons Attribution Non-commercial Share Alike 4.0 International license (CC BY-NC-SA 4.0).

Lisensi ini mengizinkan Anda untuk berbagi, mengopi, mendistribusikan, dan mentransmisi karya untuk penggunaan personal dan bukan tujuan komersial, dengan memberikan atribusi sesuai ketentuan. Karya turunan dan modifikasi harus menggunakan lisensi yang sama.

Informasi detail terkait lisensi CC-BY-NC-SA 4.0 tersedia melalui tautan: <https://creativecommons.org/licenses/by-nc-sa/4.0/>



**PENERAPAN PEMBELAJARAN MESIN
(*MACHINE LEARNING*) DAN PEMBELAJARAN
DALAM (*DEEP LEARNING*) BERKINERJA
TINGGI UNTUK Mendukung Sektor
Pertanian di Indonesia**

**ORASI PENGUKUHAN PROFESOR RISET
BIDANG PENGOLAHAN SINYAL
MULTIMEDIA DAN KECERDASAN ARTIFISIAL**

OLEH:
HILMAN FERDINANDUS PARDEDE

Penerbit BRIN

Buku ini tidak diperjualbelikan.

© 2023 Badan Riset dan Inovasi Nasional (BRIN)

Katalog dalam Terbitan (KDT)

Penerapan Pembelajaran Mesin (*Machine Learning*) dan Pembelajaran Dalam (*Deep Learning*) Berkinerja Tinggi untuk Mendukung Sektor Pertanian di Indonesia/Hilman Ferdinandus Pardede–Jakarta: Penerbit BRIN, 2023.

ix + 93 hlm.; 14,8 x 21 cm

ISBN 978-623-8372-06-5 (cetak)
978-623-8372-05-8 (*e-book*)




- | | |
|----------------------------------|---|
| 1. Kecerdasan Buatan | 5. Pengenalan Kualitas Pangan |
| 2. Pembelajaran Mesin | 6. <i>Unsupervised Feature Learning</i> |
| 3. Pembelajaran Dalam | 7. Statistika <i>Non-extensive</i> |
| 4. Identifikasi Penyakit Tanaman | |

006.3

Copy editor : Anton Winarko
Proofreader : Sarah Fairuz & Rahma Hilma Taslima
Penata Isi : Meita Safitri
Desainer Sampul : Meita Safitri

Cetakan : September 2023



Diterbitkan oleh:
Penerbit BRIN, Anggota Ikapi
Direktorat Repositori, Multimedia, dan Penerbitan Ilmiah
Gedung B.J. Habibie Lt. 8, Jl. M.H. Thamrin No.8,
Kb. Sirih, Kec. Menteng, Kota Jakarta Pusat,
Daerah Khusus Ibukota Jakarta 10340
Whatsapp: +62 811-1064-6770
E-mail: penerbit@brin.go.id
Website: penerbit.brin.go.id
 PenerbitBRIN
 Penerbit_BRIN
 penerbit.brin

Buku ini tidak diperjualbelikan.

DAFTAR ISI

DAFTAR GAMBAR.....	vii
DAFTAR TABEL.....	ix
BIODATA RINGKAS	1
PRAKATA PENGUKUHAN	3
I. PENDAHULUAN.....	5
II. KECERDASAN ARTIFISIAL, PEMBELAJARAN MESIN, DAN PEMBELAJARAN DALAM DI BIDANG PERTANIAN: PERKEMBANGAN SAAT INI DAN TANTANGAN DI MASA DEPAN.....	11
A. Kecerdasan Artifisial, Pembelajaran Mesin, dan Pembelajaran Dalam	11
B. Perkembangan Teknologi Kecerdasan Artifisial di Bidang Pertanian.....	14
C. Tantangan Penerapan Algoritma Pembelajaran Mesin dan Pembelajaran Dalam	18
III. IMPLEMENTASI PEMBELAJARAN MESIN DAN PEMBELAJARAN DALAM UNTUK DETEKSI PENYAKIT TANAMAN DAN PENGENALAN KUALITAS PERTANIAN PANGAN	23
A. Dataset Pertanian Indonesia	24
B. Implementasi Pembelajaran Mesin dan Pembelajaran Dalam di Bidang Pertanian.....	26
C. Model Pembelajaran Dalam Ringkas, Tahan, dan Berkinerja Tinggi.....	38

IV. RELEVANSI, IMPLIKASI, DAN REKOMENDASI PENERAPAN PEMBELAJARAN MESIN DAN PEMBELAJARAN DALAM PADA SEKTOR PERTANIAN.....	49
A. Pengembangan Platform Informasi	49
B. Kolaborasi Riset	50
C. Rekomendasi	51
V. KESIMPULAN.....	53
VI. PENUTUP.....	55
VII. UCAPAN TERIMA KASIH	57
DAFTAR PUSTAKA.....	61
DAFTAR PUBLIKASI ILMIAH.....	73
DAFTAR RIWAYAT HIDUP.....	85

Buku ini tidak diperjualbelikan.

DAFTAR GAMBAR

Gambar 2.1	Struktur Sebuah <i>Deep Convolutional Neural Networks</i> (DCNN).....	15
Gambar 2.2	Jumlah Publikasi Terindeks Scopus untuk <i>Query</i> [<i>“Machine Learning”</i> or <i>“Deep Learning”</i> and <i>Agriculture</i>].....	16
Gambar 2.3	Jumlah publikasi terindeks Scopus terkait metode pembelajaran mesin dan pembelajaran dalam yang diterapkan pada bidang pertanian.....	16
Gambar 2.4	Pengaruh kapasitas model dengan kemampuan generalisasi algoritma pembelajaran mesin dan pembelajaran dalam.	19
Gambar 3.1	Perbandingan <i>Autoencoder</i> dan <i>Denoising Autoencoder</i>	29
Gambar 3.2	Sampel Contoh Data Hasil dari GAN dan DCGAN	33
Gambar 3.3	Skema Proses <i>Multicondition Training</i> untuk Pembelajaran Dalam	34
Gambar 3.4	Arsitektur <i>Variational Autoencoder</i> yang Diusulkan untuk Identifikasi Pengenalan Klon	37
Gambar 3.5	Perbandingan Arsitektur	40
Gambar 3.6	Skematika Lengkap Arsitektur CompactNet.....	40
Gambar 3.7	Visualisasi Citra dari Hasil <i>Variational Autoencoder</i> yang Terlihat Buram	42
Gambar 3.8	Skematika Arsitektur EGAN untuk <i>Feature Learning</i>	44
Gambar 3.9	Fungsi q -log yang Menjadi Fondasi Statistika Tsallis untuk Berbagai Variasi Nilai q	45
Gambar 3.10	Fungsi <i>loss</i> untuk Pembelajaran Mesin	46

DAFTAR TABEL

Tabel 3.1	Distribusi Data Penyakit pada Teh untuk Setiap Kelas Penyakit dan Sehat	24
Tabel 3.2	Distribusi Data Klon pada Teh untuk Setiap Kelas Jenis Klon	25
Tabel 3.3	Perbandingan Kinerja DCNN untuk Deteksi Penyakit pada Tanaman Jagung (dari Dataset Plantvillage)	26
Tabel 3.4	Performa <i>denoising autoencoder</i> ketika data uji dikotori dengan berbagai jenis derau menggunakan data Plantvillage.	26
Tabel 3.5	Kinerja Berbagai Arsitektur DCNN untuk Pengenalan Penyakit pada Teh	28
Tabel 3.6	Kinerja Fitur Hibrida Warna (RGB) dan Tekstur (<i>Linear Binary Pattern</i>) untuk Sistem Pengenalan Penyakit pada Teh	30
Tabel 3.7	Perbandingan Kinerja Penerapan <i>Transfer Learning</i> dan <i>Fine Tuning</i> pada Sistem Identifikasi Penyakit Teh	31
Tabel 3.8	Perbandingan Kinerja GAN dan DCGAN sebagai Teknik Augmentasi	32
Tabel 3.9	Perbandingan kinerja <i>multicondition training</i> pada dua arsitektur DCNN: AlexNet dan GoogleNet.	34
Tabel 3.10	Perbandingan Performa DCNN pada pengenalan klon teh untuk 6 jenis klon teh	36
Tabel 3.11	Performa <i>Variational Autoencoder</i> dibandingkan VGGNet terhadap beberapa kondisi data uji.	38
Tabel 3.12	Perbandingan ComNet dengan Arsitektur DCNN Lainnya	39
Tabel 3.13	Perbandingan performa EGAN dan metode <i>feature learning</i> lain dan fitur warna.	44
Tabel 3.14	Performa Q-Sigmoid dibandingkan dengan sigmoid <i>loss</i>	48

BIODATA RINGKAS



Hilman Ferdinandus Pardede lahir di Lubuk Pakam, pada tanggal 25 Juni 1982 adalah anak ke-empat dari Bapak Kitaman Pardede dan Ibu Sinta Siahaan. Menikah dengan Mariska Margaret Pitoi, S.Si., M.Sc. dan dikaruniai 3 orang anak, yaitu Gabe Ezekiel Pardede, Posma Eliezer Pardede, dan Hannah Elisha Pardede.

Berdasarkan Keputusan Presiden Republik Indonesia Nomor 51/M Tahun 2021, tanggal 9 November 2021 yang bersangkutan diangkat sebagai Peneliti Ahli Utama terhitung mulai 1 Desember 2021.

Berdasarkan Keputusan Kepala Badan Riset dan Inovasi Nasional No. 248/I/HK/2023 Tanggal 14 Agustus 2023 tentang Pembentukan Majelis Pengukuhan Profesor Riset, yang bersangkutan dapat melakukan pidato pengukuhan Profesor Riset.

Menamatkan Sekolah Dasar HKBP Lubuk Pakam, tahun 1994, Sekolah Menengah Pertama Negeri 1 Lubuk Pakam, tahun 1997, dan Sekolah Menengah Atas Negeri 1 Lubuk Pakam, tahun 2000. Memperoleh gelar Sarjana Teknik dari Universitas Indonesia tahun 2004, gelar Magister Master of Engineering in Information and Communication Technology (MEICT) dari The University of Western Australia tahun 2009, dan gelar Doktor bidang Ilmu Komputer dari Tokyo Institute of Technology tahun 2013. Setelah memperoleh gelar Doktor, melanjutkan Postdoctoral Research Fellow di Fondazione Bruno Kessler di Italia (2013–2015).

Mengikuti beberapa pelatihan yang terkait dengan bidang kompetensinya, antara lain Pelatihan Data Communication, Internet Technologies, and Multimedia Systems di Bandung (2005), Pelatihan The Course on Security: Principles, Techniques and Verification di Bandung (2005), Diklat Fungsional Peneliti Tingkat Pertama di Cibinong (2006), Pelatihan Predeparture Training Course for Postgraduate studies in Australia di Jakarta (2007), Pelatihan Introductory Academic Skills Program di Perth (2007), Diklat Peneliti Tingkat Lanjut di Cibinong (2016), Pelatihan ProGRANT: Proposal Writing for Research Grants di Jakarta (2016), Pelatihan Reviewer dan Tata Cara Penilaian Proposal Penelitian di Jakarta (2019).

Jabatan fungsional peneliti diawali sebagai Peneliti Ahli Pertama golongan III/a tahun 2007, Peneliti Ahli Muda golongan III/c tahun 2014, Peneliti Ahli Madya golongan IV/a tahun 2019, dan memperoleh jabatan Peneliti Ahli Utama golongan IV/d bidang Pengolahan Sinyal Multimedia dan Kecerdasan Artifisial tahun 2021.

Menghasilkan 77 karya tulis ilmiah (KTI), baik yang ditulis sendiri maupun bersama penulis lain dalam bentuk buku, jurnal, dan prosiding. Sebanyak 65 KTI ditulis dalam bahasa Inggris.

Ikut serta dalam pembinaan kader ilmiah, yaitu sebagai pembimbing jabatan fungsional peneliti pada Badan Riset dan Inovasi Nasional, pembimbing skripsi (S-1) pada Institut Teknologi Harapan Bangsa dan Universitas Negeri Jakarta, serta pembimbing tesis (S-2) pada STMIK Nusa Mandiri/Universitas Nusa Mandiri.

Menerima tanda penghargaan Satyalancana Karya Satya 10 Tahun (tahun 2015), dari Presiden RI.

PRAKATA PENGUKUHAN

Salam sejahtera untuk kita semua.

Majelis Pengukuhan Profesor Riset, Kepala Badan Riset dan Inovasi Nasional yang mulia dan hadirin yang saya hormati.

Pertama-tama marilah kita panjatkan puji dan syukur ke hadirat Tuhan Yang Maha Esa, atas segala rahmat, nikmat, dan karunia-Nya sehingga dalam kesempatan ini kita dapat berkumpul dan bersama-sama hadir pada acara orasi ilmiah pengukuhan Profesor Riset di Badan Riset dan Inovasi Nasional

Pada kesempatan yang berbahagia ini, dengan segala kerendahan hati, izinkan saya pada tanggal 12 September 2023 menyampaikan orasi ilmiah dengan judul:

“PENERAPAN PEMBELAJARAN MESIN
(*MACHINE LEARNING*) DAN PEMBELAJARAN
DALAM (*DEEP LEARNING*) BERKINERJA
TINGGI UNTUK Mendukung Sektor
PERTANIAN DI INDONESIA”

Buku ini tidak diperjualbelikan.

I. PENDAHULUAN

Sektor pertanian di Indonesia adalah sektor yang sangat strategis. Indonesia merupakan negara agraris yang memiliki sumber daya hasil pertanian dan perkebunan yang cukup besar. Menurut data BPS, sektor pertanian menyumbang 13,28% PDB tahun 2021 (Biro Pusat Statistik, 2021). Ini menunjukkan bahwa sektor ini masih sangat besar perannya dalam perekonomian nasional.

Salah satu aspek penting dalam pembangunan di bidang pertanian adalah ketahanan pangan. Bertambahnya populasi manusia, tantangan untuk mencapai ketahanan pangan akan makin besar. Penerapan teknologi informatika pada sektor pertanian menjadi salah satu cara untuk mendukung mengatasi tantangan ini. Saat ini, teknologi informatika, seperti kecerdasan artifisial atau *artificial intelligence* (AI) (Benos dkk., 2021; Meshram dkk., 2021), *internet of things* (IoT) (Kour & Arora, 2020), dan *big data* (Lioutas & Charatsari, 2020) dapat digunakan untuk mengolah data-data di bidang pertanian dan menghasilkan informasi yang dapat digunakan untuk meningkatkan produksi ataupun kualitas pangan. Teknologi *smart farming* (Wolfert dkk., 2017) dan *precision agriculture* (Cisternas dkk., 2020) dapat digunakan untuk melakukan pemantauan, pemeliharaan lahan pemanenan, hingga penyimpanan menggunakan teknologi kecerdasan artifisial, IoT, dan data analisis. Tren saat ini menunjukkan teknologi informatika di bidang pertanian makin meningkat. Akan tetapi, penerapannya di Indonesia relatif masih sangat rendah. Oleh karena itu, diperlukan penelitian intensif terkait penerapan teknologi informatika, khususnya terkait kecerdasan artifisial di bidang pertanian.

Pembelajaran mesin atau *machine learning* dan pembelajaran dalam atau *deep learning* adalah dua terminologi bidang informatika yang sangat populer saat ini. Kedua terminologi ini adalah salah satu teknologi kunci dan dominan pada bidang kecerdasan artifisial. Pembelajaran mesin adalah bidang ilmu yang bertujuan agar sistem komputer mampu belajar dari data dan mengekstrak pola yang bermanfaat dari data sehingga sistem tersebut dapat belajar tanpa harus diprogram secara spesifik (Bishop & Nasrabadi, 2006). Kemudian, pola yang diperoleh tersebut dapat digunakan untuk melakukan prediksi kejadian di masa depan, evaluasi data, dan analisis data. Pembelajaran dalam adalah bagian dari pembelajaran mesin. Pembelajaran mesin dapat dibagi menjadi dua, yaitu pembelajaran mesin dangkal dan pembelajaran dalam. Pembelajaran mesin dangkal adalah algoritma pembelajaran mesin yang dibangun berdasarkan struktur dangkal sehingga memiliki kapasitas rendah. Contohnya adalah *support vector machines*, regresi linier, dan regresi logistik. Pembelajaran dalam adalah algoritma pembelajaran mesin yang memiliki kapasitas sangat besar untuk memodelkan relasi nonlinier dari data. Ini yang membedakan dengan pembelajaran mesin dangkal, yang memiliki keterbatasan dalam memodelkan nonlinieritas. Hal ini menyebabkan algoritma pembelajaran dalam umumnya akan lebih baik ketika diterapkan kepada data dengan kompleksitas nonlinieritas yang tinggi misalnya pada data citra, teks, video, maupun audio (Goodfellow dkk., 2016).

Meningkatnya pertumbuhan data saat ini menyebabkan pembelajaran mesin dan pembelajaran dalam telah diterapkan di berbagai bidang, antara lain kesehatan, keuangan dan perbankan, keamanan data, biometrik, pengolahan bahasa alami, bahkan

hingga sektor pertanian. Implementasi di sektor pertanian makin populer belakangan ini melihat besarnya potensi pemanfaatannya di sektor tersebut. Namun, penerapannya di Indonesia masih sangat sedikit. Oleh karena itu, penelitian, pengkajian, penerapan pembelajaran mesin dan pembelajaran dalam untuk mendukung pertanian di Indonesia harus terus ditingkatkan.

Pada naskah orasi ini, akan dijabarkan berbagai penelitian terkait peningkatan peran teknologi pembelajaran mesin dan pembelajaran dalam untuk mendukung pertanian di Indonesia. Untuk mencapai hal tersebut, diperlukan solusi yang mampu mengatasi dua permasalahan yang ditemukan dalam pengembangan riset pembelajaran mesin dan pembelajaran dalam di bidang pertanian di Indonesia. Permasalahan pertama adalah terkait ketersediaan data. Data harus dimiliki dalam pengembangan pembelajaran mesin dan pembelajaran dalam. Oleh karena itu, diperlukan membangun dataset terkait pertanian khas Indonesia (Ramdan dkk., 2021a, 2021b). Akan tetapi, membangun dataset adalah proses yang mahal dan panjang. Oleh karena itu, perlu dicari solusi untuk mengatasi permasalahan keterbatasan data. *Transfer learning* (Ramdan, Heryana, dkk., 2020) dan augmentasi data (Yuwana dkk., 2020) dapat digunakan sebagai solusinya. Kedua, algoritma pembelajaran mesin dangkal membutuhkan fitur *hand-designed* untuk menghasilkan akurasi yang tinggi. Berbagai fitur *hand-designed* telah diuji pada penelitian terdahulu (Kusumo dkk., 2019; Ramdan, Sugiarto, dkk., 2019).

Untuk pembelajaran dalam, arsitektur *deep convolutional neural networks* (DCNN) adalah yang paling dominan digunakan. Arsitektur DCNN memiliki kelebihan dalam memodelkan

korelasi spasial pada data sehingga sangat efektif jika diterapkan pada data citra. Pada penelitian terdahulu, berbagai arsitektur DCNN telah digunakan (Krisnandi dkk., 2019; Kusumo dkk., 2020; Ramdan, Suryawati, dkk., 2019; Ramdan, Zilvan, dkk., 2020; Suryawati, Sustika, dkk., 2019) baik untuk deteksi penyakit tanaman maupun pengenalan kualitas pangan. Aplikasi berbasis Android dan komputer pribadi juga telah dikembangkan untuk sistem deteksi penyakit tanaman dan kualitas pangan (Ramdan, Heryana, dkk., 2019a, 2019b). Selain itu, model prediksi yang ringkas diusulkan pada (Pardede, Suryawati, Zilvan, dkk., 2020) untuk memungkinkan implementasi pada sistem tertanam.

Tantangan berikutnya terkait reliabilitas dan ketahanan model prediksi ketika diterapkan di kondisi tidak ideal. Berbagai eksplorasi teknik, seperti *multi-condition training* (Yuwana, Suryawati, Zilvan, dkk., 2019) dan penerapan pembelajaran tidak tersupervisi (Pardede, Suryawati, dkk., 2019; Suryawati dkk., 2021; Suryawati, Zilvan, dkk., 2019; Zilvan dkk., 2019, 2022) telah diusulkan untuk mengatasi hal tersebut. Selain itu, penerapan *framework* baru, yaitu statistika *non-extensive* untuk pembelajaran mesin dan pembelajaran dalam juga telah dilakukan.

Naskah orasi ini dibagi ke dalam enam bab. Bab pertama adalah pendahuluan ini. Bab kedua akan menjabarkan tentang teknologi kecerdasan artifisial, pembelajaran mesin, dan pembelajaran dalam, serta *state of the art* teknologi pembelajaran mesin dan pembelajaran dalam saat ini. Bab ketiga membahas kontribusi penelitian yang dilakukan untuk menerapkan pembelajaran mesin dan pembelajaran dalam pada bidang pertanian berupa sistem deteksi penyakit tanaman dan kualitas pangan,

serta kontribusi metodologi berupa model ringan DCNN yang disebut dengan CompactNet (ComNet), teknik *feature learning* yang baru disebut EGAN, dan eksplorasi statistika *non-extensive* di bidang pembelajaran mesin dan pembelajaran dalam. Bab keempat membahas relevansi, implikasi, rekomendasi terkait perkembangan teknologi pembelajaran mesin dan pembelajaran dalam, dan pentingnya penguasaan teknologi pembelajaran mesin dan pembelajaran dalam. Bab kelima akan menyoroti hasil-hasil penelitian dan bab keenam sebagai penutup.

Buku ini tidak diperjualbelikan.

II. KECERDASAN ARTIFISIAL, PEMBELAJARAN MESIN, DAN PEMBELAJARAN DALAM DI BIDANG PERTANIAN: PERKEMBANGAN SAAT INI DAN TANTANGAN DI MASA DEPAN

Penerapan teknologi informasi dan telekomunikasi pada bidang pertanian adalah salah satu solusi intensifikasi pertanian menuju ketahanan pangan. Teknologi kecerdasan artifisial, *big data*, dan IoT makin banyak dimanfaatkan pada berbagai sektor pertanian. Kecerdasan artifisial saat ini makin memegang peranan penting terutama untuk melakukan otomatisasi ataupun sebagai sistem pendukung analisis data dan rekomendasi. Pada bab ini, dijelaskan terkait perkembangan teknologi kecerdasan artifisial, khususnya pembelajaran mesin dan pembelajaran dalam pada bidang pertanian.

A. Kecerdasan Artifisial, Pembelajaran Mesin, dan Pembelajaran Dalam

Teknologi kecerdasan artifisial bertujuan untuk menghasilkan sistem komputer yang mampu menunjukkan suatu tingkat inteligensia untuk mampu melakukan suatu pekerjaan yang biasanya oleh dilakukan manusia (Kahn & Winters, 2021). Pendekatan kecerdasan artifisial dapat dikategorikan menjadi dua. Kategori pertama disebut *hard AI* yang bertujuan akhir menghasilkan sistem komputer yang memiliki kesadaran sehingga satu sistem mampu melakukan aktivitas manusia secara holistik. Kategori kedua disebut dengan *soft AI*, yaitu sistem kecerdasan artifisial yang bertujuan untuk melakukan hanya satu pekerjaan tertentu saja. Namun, pada perkembangannya, *hard AI* belum dapat di-

capai hingga saat ini sehingga teknologi kecerdasan artifisial saat ini berupa *soft AI*.

Saat ini, teknologi pembelajaran mesin adalah teknologi dominan sebagai solusi kecerdasan artifisial (Haenlein & Kaplan, 2019). Pembelajaran mesin bertujuan untuk mencari pola dari suatu data dan menggunakan pola tersebut untuk memperoleh inferensi (Bishop & Nasrabadi, 2006). Didorong terjadinya peristiwa yang disebut sebagai *AI winter* di periode tahun 1970-an (Floridi, 2020), pembelajaran mesin dan pembelajaran dalam dianggap sebagai salah satu solusi kecerdasan artifisial yang paling memungkinkan dikembangkan untuk *soft AI*. Dengan pembelajaran mesin, yakni pola yang dibangun berdasarkan observasi terhadap data dan target yang telah ditentukan, algoritma melakukan optimasi parameternya untuk menghasilkan model yang meminimalkan galat antara target dan prediksi yang dihasilkan. Dengan kata lain, dengan menggunakan pembelajaran mesin, model data yang dihasilkan dijadikan sebagai basis dari model “kecerdasan”.

Perkembangan pembelajaran mesin untuk kecerdasan artifisial makin pesat dengan diperkenalkannya teknologi pembelajaran dalam (Goodfellow dkk., 2016). Melalui pembelajaran dalam, berbagai teknologi pengolahan bahasa alami, pengenalan sinyal ucapan, dan pengenalan objek menghasilkan kinerja yang sangat baik. Ini yang mendorong teknologi pembelajaran dalam menjadi teknologi dominan untuk kecerdasan artifisial. Hampir semua penerapan kecerdasan artifisial yang ada saat ini berbasis pembelajaran mesin atau pembelajaran dalam.

Pembelajaran dalam pada prinsipnya adalah sebuah jaringan saraf tiruan (JST). JST adalah sebuah model yang mengadopsi

model sistem saraf manusia. Pada prinsipnya, sebuah JST, terdiri dari tiga lapisan (*layer*), yaitu lapisan *input*, lapisan *hidden*, dan lapisan *output*. Lapisan *input* adalah *perceptron* yang menerima data *input*, lapisan *output* adalah *perceptron* yang menghasilkan target atau kelas, sedangkan lapisan *hidden* adalah *perceptron* yang posisinya di antara lapisan *input* dan *output*. JST konvensional umumnya memiliki jumlah lapisan *hidden* sebanyak dua atau tiga lapisan. Pada pembelajaran dalam, jumlah lapisan *hidden* lebih dari tiga. Saat ini, jumlah lapisan *hidden* bahkan bisa mencapai ratusan. Hal ini bertujuan untuk menambah kapasitas algoritma. Penambahan kapasitas ini diperlukan untuk memodelkan kompleksitas data. Secara teori, dengan jumlah lapisan *hidden* yang cukup, pembelajaran dalam mampu mendekati fungsi apa saja sehingga disebut sebagai *universal function approximator* (Nielsen, 2015). Kemampuan ini membuat pembelajaran dalam banyak digunakan untuk memodelkan data nonlinier dan relasi kompleks, seperti pada data teks, data citra, video, dan audio.

Aplikasi pembelajaran mesin dan pembelajaran dalam telah banyak digunakan dalam kehidupan sehari-hari. Misalnya Google menerapkannya untuk melakukan pemeringkatan hasil pencarian, melakukan translasi, mengubah suara menjadi teks, dan pengenalan objek. Pembelajaran mesin dan pembelajaran dalam telah diterapkan, antara lain untuk pengenalan sinyal ucapan (Pardede dkk., 2013a, 2018; Pardede, Yuliani, dkk., 2019), prediksi opini (Kurniawati & Pardede, 2018; Pardede, 2021), *part of speech tagging* (memprediksi kelas sebuah kata) (Yuwana dkk., 2018; Yuwana, Suryawati, & Pardede, 2019), identifikasi spesies burung (Jakaria & Pardede, 2022), *spectrum sensing* (Subekti dkk., 2018), deteksi penipuan asuransi (Nugraha

dkk., 2022), pengenalan emosi (Kurniasih dkk., 2022), deteksi berita bohong (Pardamean & Pardede, 2021), prediksi umur baterai listrik (Yuliani dkk., 2021), prediksi kesetiaan pelanggan telekomunikasi (Nalatisifa & Pardede, 2021), dan prediksi kepribadian (Maulidah & Pardede, 2021).


B. Perkembangan Teknologi Kecerdasan Artifisial di Bidang Pertanian

Makin berkembangnya teknologi kecerdasan artifisial, penerapannya pada bidang pertanian juga makin besar. Salah satu implementasinya adalah teknologi *smart farming* dan *precision agriculture* (Cisternas dkk., 2020; Wolfert dkk., 2017). Teknologi kecerdasan artifisial dipadukan dengan teknologi *big data*, IoT dan pengindraan jauh dapat digunakan untuk proses pemilihan benih (Zhang dkk., 2021), identifikasi penyakit (Pardede, Suryawati, Krisnandi, dkk., 2020), pemupukan (Swaminathan dkk., 2022), pemantauan lahan (Cisternas dkk., 2020), proses pemanenan (Meshram dkk., 2021), identifikasi kualitas pangan (Mahendra dkk., 2019), hingga distribusi hasil panen (Kantasa-Ard dkk., 2021).

1. Deep Convolutional Neural Networks

Data citra menjadi salah satu jenis data utama dalam pengembangan algoritma pembelajaran mesin dan pembelajaran di bidang pertanian. Oleh karena itu, arsitektur *deep convolutional neural networks* (DCNN) dan variannya adalah arsitektur yang paling sering digunakan. DCNN sangat baik untuk data citra karena DCNN efektif dalam mencari korelasi spasial pada data. Ada beragam arsitektur DCNN di literatur yang banyak digunakan untuk visi komputer dan pengenalan objek, antara lain AlexNet (Krizhevsky dkk., 2017), GoogleNet (Szegedy dkk., 2015),

VGGNet (Simonyan & Zisserman, 2014), Inception (Szegedy dkk., 2016), Xception (Chollet, 2017), dan DenseNet (Huang dkk., 2017).

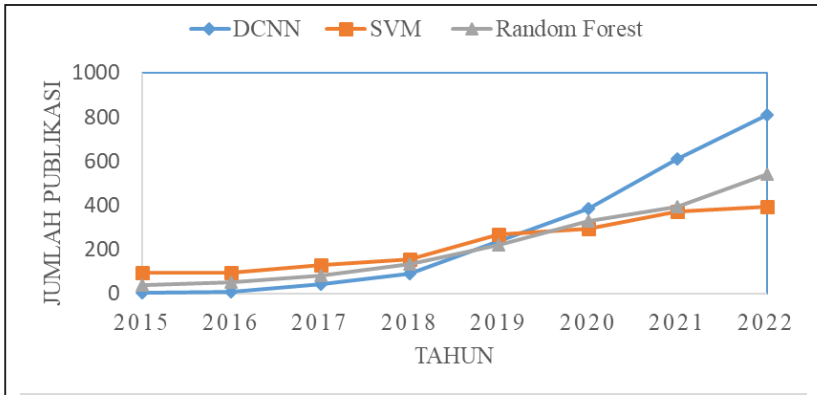


Sumber: Suryawati dkk. (2021)

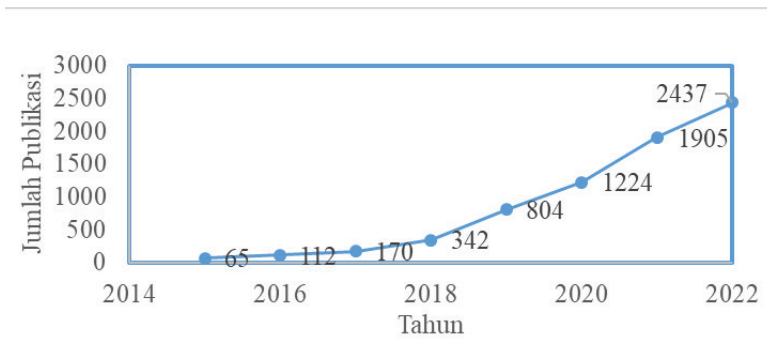
Gambar 2.1 Struktur Sebuah *Deep Convolutional Neural Networks* (DCNN)

Gambar 2.1 adalah struktur dasar dari sebuah DCNN. Sebuah DCNN terdiri dari beberapa lapisan konvolusi (*convolutional layers*), *pooling*, dan *fully connected* yang merupakan sebuah JST biasa. Jadi, yang membedakan dengan JST adalah lapisan konvolusi dan *pooling*. Pada lapisan konvolusi, operasi konvolusi terhadap data input dan sebuah fungsi kernel dilakukan. Hal ini bertujuan mencari korelasi spasial antardata yang saling berdekatan. Beberapa lapisan konvolusi dibangun dengan tujuan agar model DCNN belajar representasi lokal sebelum belajar representasi global dari data. Dengan demikian, diharapkan setiap lapisan konvolusi dari model DCNN akan belajar abstraksi berbeda dari data tersebut. Sementara itu, lapisan *pooling* berguna untuk mengurangi dimensi data. Setelah beberapa *layer* konvolusi dan *pooling*, lapisan *fully connected* digunakan untuk memetakan antara representasi abstraksi dari lapisan konvolusi dengan target kelas dari objek.

Buku ini tidak diperjualbelikan.



Gambar 2.3 Jumlah publikasi terindeks Scopus terkait metode pembelajaran mesin dan pembelajaran dalam yang diterapkan pada bidang pertanian.



Gambar 2.2 Jumlah Publikasi Terindeks Scopus untuk *Query* ["Machine Learning" or "Deep Learning" and Agriculture]

Saat ini DCNN adalah teknologi inti dari berbagai implementasi pembelajaran dalam di bidang pertanian. DCNN telah diterapkan pada sistem prediksi penyakit tanaman (Hughes & Salathé, 2015; Suryawati, Sustika, dkk., 2019; Zilvan dkk., 2019), pengenalan kualitas pangan (Ramdan, Suryawati, dkk., 2019;

Suryawati, Zilvan, dkk., 2019; Zilvan dkk., 2022), teknologi *smart farming* dan *precision agriculture* (Cisternas dkk., 2020; Wolfert dkk., 2017). Pencarian pada *database* Scopus ketika memasukkan *query* [“*Machine learning*” OR “*Deep learning*” AND “*Agriculture*”] memperlihatkan hasil DCNN, SVM, dan *random forest* adalah tiga metode utama dalam pengembangan algoritma pembelajaran mesin dan pembelajaran dalam di bidang pertanian (Gambar 2.2). SVM adalah algoritma pembelajaran mesin yang berbasis klasifikasi linier dengan memaksimalkan nilai margin, sementara *random forest* adalah teknik berbasis grup pohon keputusan yang dibangun secara paralel berbasis sampel data dan fitur dari data latih. Namun, jika melihat tren per tahun, tidaklah mengejutkan DCNN akan menjadi teknologi yang dominan (Gambar 2.3).

2. *Feature Learning*


Proses pembelajaran pada pembelajaran mesin dapat dibagi menjadi dua. Pertama adalah pembelajaran tersupervisi. Pada pembelajaran tersupervisi, data telah diberi label target. Tujuan utama algoritma pembelajaran mesin adalah mencari dan mengoptimasi fungsi yang dapat memetakan data ke target tersebut dengan baik. Contoh algoritma tersupervisi adalah *decision tree*, *naive Bayes*, *support vector machine* (SVM), dan *random forest*. Kategori kedua adalah pembelajaran tanpa supervisi. Pada pembelajaran ini, tujuan algoritma pembelajaran mesin adalah untuk menemukan karakteristik “menarik” dari data. Beberapa contoh algoritma tanpa supervisi adalah *k-means clustering*, *principal component analysis*, *independent component analysis*, dan *Gaussian mixtures*.

Pembelajaran dalam pada awalnya digunakan untuk pembelajaran tersupervisi. Model pembelajaran dalam belajar relasi data input dengan kelas target dari data dan optimasi model dilakukan menggunakan data latih. Namun, saat ini minat pada penerapan pembelajaran dalam untuk pembelajaran tanpa supervisi makin meningkat. Pembelajaran ini disebut dengan *feature learning*. *Feature learning* adalah proses pembelajaran secara tidak tersupervisi dari pembelajaran dalam dengan tujuan mengekstrak fitur dari data secara otomatis. Dengan demikian, kebutuhan untuk mendesain fitur (*hand-designed*) menjadi tidak diperlukan. Hal ini memudahkan implementasi pembelajaran dalam karena umumnya, fitur mentah seperti fitur warna langsung digunakan sebagai masukan ke dalam sistem. *Autoencoder* (AE) (Huang dkk., 2017), *variational autoencoder* (Cemgil dkk., 2020), dan *generative adversarial networks* (GAN) (Goodfellow dkk., 2020) adalah metode yang dapat digunakan untuk teknik *feature learning*. *Feature learning* juga telah diterapkan pada penelitian-penelitian terdahulu, baik untuk pengenalan penyakit pada tanaman (Pardede, Suryawati, dkk., 2019; Zilvan dkk., 2019) maupun pengenalan kualitas hasil pangan (Zilvan dkk., 2022).

C. Tantangan Penerapan Algoritma Pembelajaran Mesin dan Pembelajaran Dalam

Tantangan utama pada pembelajaran mesin adalah yang disebut tentang kemampuan generalisasi model. Model yang baik adalah model yang juga menghasilkan akurasi baik ketika diuji pada data yang memiliki karakteristik berbeda dengan data latih. Pada titik kapasitas tertentu, kemampuan generalisasi sebuah model pembelajaran mesin makin menurun dengan makin besarnya

kapasitas data seperti diilustrasikan pada Gambar 2.4. Kondisi ketika kapasitas model yang digunakan terlalu rendah disebut *underfitting*, sedangkan ketika kapasitas terlalu besar disebut *overfitting*. *Overfitting* menjadi masalah yang lebih rumit karena jika tidak berhati-hati, suatu algoritma pembelajaran mesin dapat menghasilkan kinerja baik pada data latih, tetapi ketika diuji dengan data yang berbeda kondisi dengan data latih, kinerja sistem turun secara drastis.



Sumber: Goodfellow dkk. (2016)

Gambar 2.4 Pengaruh kapasitas model dengan kemampuan generalisasi algoritma pembelajaran mesin dan pembelajaran dalam.

Dengan kata lain, sebuah algoritma pembelajaran mesin dan pembelajaran dalam harus mampu mengatasi variasi yang mungkin ada pada data. Hal ini diperlukan karena umumnya model pembelajaran mesin dilatih dengan data yang terbatas sehingga tidak mungkin mencakup semua variasi data yang mungkin ada. Oleh karena itu, ketika diimplementasikan, model pembelajaran mesin akan dihadapkan pada data yang berbeda

dengan data latih. Jika kapasitas terlalu besar dibandingkan kompleksitas data, model akan *overfit* terhadap data latih. Akibatnya, jika digunakan dengan data yang karakteristiknya berbeda, sistem tersebut lebih rentan terhadap kesalahan prediksi.

Variasi data bisa datang dari *intra-variability*, *inter-variability*, dan derau dari lingkungan. *Intra-variability* terjadi ketika data dari sebuah entitas memang memiliki karakteristik yang mudah berubah. Misalnya pada identifikasi menggunakan wajah (*face recognition*), perubahan emosi dan penambahan umur adalah variasi yang mungkin ada. *Inter-variability* terjadi jika ada kemiripan antara satu objek dan yang lain yang memungkinkan terjadinya kesalahan identifikasi. Derau dari lingkungan juga bisa berupa perbedaan cahaya, sudut, objek penghalang, dan gangguan transmisi yang dapat mengubah karakteristik dari data tersebut.

Untuk mengatasi hal tersebut, ada beberapa cara yang dapat ditempuh. Cara pertama adalah dengan melakukan ekstraksi *hand-designed* fitur. Berbagai operasi diterapkan pada data untuk menghasilkan fitur yang baik dan tahan terhadap variasi data tersebut. Pada penelitian-penelitian sebelumnya, telah dilakukan banyak penelitian untuk menghasilkan fitur pada sinyal suara. Misalnya dengan menerapkan normalisasi fitur (Pardede, 2017; Pardede dkk., 2013a; Pardede, Yuliani, dkk., 2019; Pardede & Shinoda, 2011; Zilvan dkk., 2017, 2021), transformasi fitur (Abka & Pardede, 2015; Pardede, 2016; Yuliani dkk., 2017), dan penambahan metode penghilang derau (Dahlan dkk., 2019; Pardede dkk., 2012, 2013b; Zilvan dkk., 2021). Akan tetapi, usaha penemuan *hand-designed* fitur yang baik adalah proses yang kompleks dan sulit. Dibutuhkan pemahaman karakteristik

data yang baik untuk dapat mendesain fitur yang baik dan sering kali suatu fitur *hand-designed* adalah *task-specific*, yang mengakibatkan tidak dapat diterapkan pada implementasi lainnya. Selain itu, proses desain fitur tersebut rentan akan kehilangan informasi berguna dari data tersebut. Ditambah pula, operasi ketika menerapkan metode ekstraksi fitur memerlukan komputasi yang kompleks dan besar.

Cara kedua adalah dengan melatih algoritma pembelajaran dalam untuk *feature learning* (Bengio dkk., 2013). Kebutuhan untuk mendesain fitur dapat dihindari dengan menerapkan *feature learning*, yaitu sebagian dari arsitektur pembelajaran dalam dapat digunakan sebagai metode untuk secara otomatis mencari informasi yang berguna dari data. Dengan kapasitas yang besar dan kemampuan memodelkan non-linieritas yang kompleks, pembelajaran dalam dapat digunakan untuk melakukan ekstraksi fitur secara otomatis sehingga menghilangkan kebutuhan dalam mendesain fitur. Beberapa studi menunjukkan pembelajaran dalam lebih baik jika menggunakan data mentah (Ranzato dkk., 2007). Beberapa studi penelitian juga menunjukkan efektivitas pembelajaran dalam digunakan untuk *feature learning*, baik untuk klasifikasi maupun peningkatan ketahanan (*robustness*) terhadap variasi data, misalnya untuk telekomunikasi (Subekti dkk., 2018), identifikasi penyakit tanaman (Pardede, Suryawati, dkk., 2019; Zilvan dkk., 2019), dan identifikasi klon¹ teh (Suryawati dkk., 2021; Zilvan dkk., 2022).

¹ *klon teh* yang dimaksud adalah jenis teh yang diperoleh dari perbanyakannya secara vegetatif/aseksual. Menurut KBBI, penulisan yang tepat adalah *klona*. Namun, pada buku ini dituliskan *klon*, menyesuaikan dengan penyebutannya pada beberapa riwayat riset dan publikasi penulis.

Buku ini tidak diperjualbelikan.

III. IMPLEMENTASI PEMBELAJARAN MESIN DAN PEMBELAJARAN DALAM UNTUK DETEKSI PENYAKIT TANAMAN DAN PENGENALAN KUALITAS PERTANIAN PANGAN

Pada bab ini, akan disarikan beberapa hasil riset yang telah dilakukan oleh kandidat dalam penerapan pembelajaran mesin dan pembelajaran dalam pada bidang pertanian di Indonesia. Pertama, beberapa dataset terkait pertanian khas Indonesia yang dapat digunakan untuk pembelajaran mesin dan pembelajaran dalam telah dihasilkan pada studi terdahulu untuk implementasi identifikasi penyakit tanaman (Ramdan dkk., 2021b) dan identifikasi kualitas produk pangan (Mahendra dkk., 2019; Ramdan dkk., 2021a) untuk mengatasi masih sangat minimnya dataset produk pertanian di Indonesia. Kedua, telah dilakukan penerapan algoritma pembelajaran mesin dan pembelajaran untuk berbagai implementasi di bidang pertanian, antara lain untuk identifikasi penyakit tanaman (Krisnandi dkk., 2019; Kusumo dkk., 2019, 2020; Suryawati, Sustika, dkk., 2019) dan deteksi kualitas hasil pangan (Ramdan, Suryawati, dkk., 2019; Sustika dkk., 2018). Ketiga, telah dihasilkan beberapa kontribusi riset antara lain untuk menghasilkan ukuran model yang ringkas sehingga dimungkinkan implementasinya pada sistem tertanam (Pardede, Suryawati, Zilvan, dkk., 2020), model yang tahan terhadap variasi data (Pardede, Suryawati, dkk., 2019; Suryawati dkk., 2021; Zilvan dkk., 2019, 2022), serta kerangka solusi baru untuk pembelajaran mesin yang menghasilkan akurasi yang lebih baik (Pardede dkk., 2022).

A. Dataset Pertanian Indonesia

1. Dataset Teh

Teh adalah salah satu produk ekspor pertanian andalan Indonesia. Penyakit tanaman adalah salah satu faktor yang memengaruhi produksi pangan pertanian termasuk teh. Identifikasi penyakit tanaman otomatis menggunakan pembelajaran mesin dan pembelajaran dalam telah menjadi salah satu bidang riset yang sangat aktif saat ini. Untuk mendukung penelitian kandidat, telah dilakukan pengumpulan data citra daun teh untuk 6 kelas, terdiri dari 5 kelas penyakit dan 1 kelas sehat (Ramdan dkk., 2021b). Data ini dikumpulkan berkolaborasi dengan Pusat Penelitian Teh dan Kina, Gambung di Jawa Barat. Total dataset yang dikumpulkan adalah 19.945 gambar (Tabel 3.1).

Tabel 3.1 Distribusi Data Penyakit pada Teh untuk Setiap Kelas Penyakit dan Sehat

No.	Jenis Penyakit	Jumlah Citra
1.	Sehat	1.448
2.	Blister blight	1.104
3.	<i>Empoasca</i> sp. (leafhoppers)	2.687
4.	<i>Looper caterpillars</i>	1.025
5.	<i>Helopeltis</i>	10.401
6.	<i>Yellowmite</i>	3.280
	Total	19.945

Sumber: Ramdan, Heryana, dkk. (2021b)

Selain dataset penyakit, kolaborasi yang sama juga membangun dataset jenis-jenis klon teh. Telah dikumpulkan sebanyak 28.774 gambar daun teh dari 11 jenis klon teh (Ramdan dkk., 2021a) (Tabel 3.2).

Tabel 3.2 Distribusi Data Klon pada Teh untuk Setiap Kelas Jenis Klon

Tipe Klon	Jumlah Data
GMB 1	2.609
GMB 2	2.449
GMB 3	2.469
GMB 4	2.828
GMB 5	2.579
GMB 6	2.789
GMB 7	2.536
GMB 8	2.691
GMB 9	2.579
GMB 10	2.526
GMB 11	2.719
Total	28.774

Sumber: Ramdan, Heryana, dkk. (2021a)

2. Dataset Stroberi, Pakcoy, dan Manggis

Selain teh, ada beberapa dataset yang juga telah dikumpulkan pada penelitian kandidat. Dataset pertama adalah buah stroberi. Ada 1.870 data citra stroberi yang dikumpulkan secara mandiri (Sustika dkk., 2018). Citra dibagi ke dalam empat tingkatan kualitas yang diidentifikasi dari bentuk dan warna stroberi tersebut.

Dataset kedua adalah tanaman pakcoy (Ramdan, Sugiarto, dkk., 2019). Dataset ini terkait tingkat kesehatan tanaman tersebut. Untuk dataset ini, terkumpul 50 citra yang terdiri dari

Tabel 3.3 Perbandingan Kinerja DCNN untuk Deteksi Penyakit pada Tanaman Jagung (dari Dataset Plantvillage)

Metode DCNN	Akurasi sistem
AlexNet	91,52
GoogleNet	89,68
VGGNet	95,24

Sumber: Ramdan, Heryana, dkk. (2021a)

25 citra tanaman sehat dan 25 citra tanaman sakit. Saat ini juga telah dikumpulkan 7.294 citra buah manggis yang terdiri dari 4 level kualitas buah manggis yang akan diterapkan algoritma pembelajaran mesin dan pembelajaran dalam.

B. Implementasi Pembelajaran Mesin dan Pembelajaran Dalam di Bidang Pertanian

1. Identifikasi Penyakit Tanaman

Penyakit tanaman adalah salah satu penyebab utama kerugian hasil pertanian. Laporan FAO menyebutkan bahwa 20% hingga 40% kehilangan hasil panen akibat penyakit tanaman yang disebabkan bakteri, jamur, serangga, dan sebagainya (FAO, 2021). Identifikasi penyakit tanaman sedini mungkin menjadi

Tabel 3.4 Performa *denoising autoencoder* ketika data uji dikotori dengan berbagai jenis derau menggunakan data Plantvillage.

Tanaman	Jenis data uji				Rata-rata
	Normal	<i>Salt noise</i>	<i>Pepper noise</i>	<i>Salt and pepper noise</i>	
Jagung	86,09	86,32	87,97	87,26	86,91
Kentang	86,77	89,22	88,24	88,24	88,12

Sumber Zilvan dkk. (2019)

salah satu langkah yang sangat krusial untuk penanganan penyakit tanaman. Akan tetapi, institusi-institusi pemerintah sering mengalami kendala dalam identifikasi penyakit secara cepat karena keterbatasan sumber daya manusia yang dapat melakukan identifikasi. Oleh karena itu, dibutuhkan sistem informasi identifikasi otomatis dengan menggunakan teknologi pembelajaran mesin dan pembelajaran dalam. Penerapan pembelajaran dalam pada sistem deteksi penyakit tanaman memiliki keuntungan mampu menghasilkan akurasi yang tinggi (Hughes & Salathé, 2015) jika dibandingkan metode pembelajaran mesin dangkal. Pada penelitian kandidat, telah dilakukan penerapan berbagai algoritma pembelajaran mesin menggunakan fitur *hand-designed* (Mahendra dkk., 2019; Ramdan, Sugiarto, dkk., 2019). Kemudian, berbagai pendekatan pembelajaran dalam baik sebagai teknik supervisi maupun tidak tersupervisi diinvestigasi dan diusulkan (Kusumo dkk., 2020; Pardede, Suryawati, Zilvan, dkk., 2020; Zilvan dkk., 2019).

Pada awal penelitian kandidat, digunakan data publik karena belum adanya dataset yang dibangun sendiri. Salah satu dataset yang populer untuk identifikasi penyakit tanaman adalah Plantvillage (Hughes & Salathé, 2015). Plantvillage adalah data citra daun sebanyak 54.306 sampel yang terdiri dari 38 kelas label dari 14 jenis tanaman pangan, antara lain tomat, apel, jagung, dan stroberi dengan berbagai jenis penyakit yang menyerang. Kelebihan dataset ini adalah ia tersedia secara gratis untuk pemanfaatan riset dan jumlah data dan kelas yang besar. Namun, dataset ini dikumpulkan secara global dari berbagai negara dan daerah. Pada dataset Plantvillage, daun diletakkan pada kondisi “bersih”, terbebas dari objek lain pada latar belakangnya. Hal

Tabel 3.5 Kinerja Berbagai Arsitektur DCNN untuk Pengenalan Penyakit pada Teh

Jumlah kelas penyakit	Arsitektur DCNN	Akurasi
2	GoogleNet	93,30
	Xception	97,61
	Inception-ResnetV2	97,13
3	GoogleNet	80,89
	Xception	82,20
	Inception-ResnetV2	90,05
4	GoogleNet	78,22
	Xception	87,10
	Inception-ResnetV2	87,95

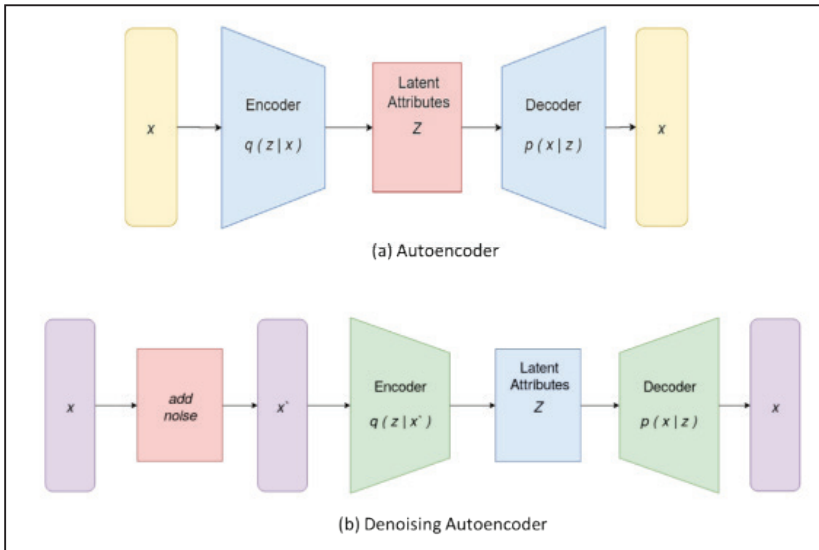
Sumber: Krisnandi dkk. (2019)

yang menyebabkan dataset ini tidak mencerminkan kondisi sebenarnya di lahan pertanian.

Beberapa fitur *hand-designed* pada citra diterapkan pada penelitian terdahulu. Beberapa fitur, seperti *scale invariant feature transform* (SIFT), *histogram oriented gradient* (HOG), *speeded up robust features* (SURF), dan *oriented FAST and rotated BRIEF* (ORB) digunakan pada data jagung (Kusumo dkk., 2019). Kemudian, investigasi penerapan metode pembelajaran dalam dilakukan. Pertama, metode pembelajaran dalam tersupervisi diterapkan pada subset tanaman tomat (Suryawati, Sustika, dkk., 2019). Arsitektur CNN sederhana digunakan sebagai *baseline* dan beberapa arsitektur DCNN, yaitu AlexNet, GoogleNet, dan VGGNet diuji dan dibandingkan. Hasil penelitian menunjukkan penerapan DCNN dapat meningkatkan performa sistem (Tabel 3.3). Secara umum dapat dikatakan, pembelajaran dalam lebih akurat untuk dataset Plantvillage.

Buku ini tidak diperjualbelikan.

Investigasi untuk meningkatkan ketahanan dari sistem dilakukan dengan menerapkan *denoising autoencoder* (Zilvan dkk., 2019) juga dilakukan. Arsitektur *autoencoder* adalah algoritma pembelajaran dalam yang dipilih untuk *feature learning* pada studi ini (Zilvan dkk., 2022). Arsitektur sebuah *autoencoder* dan *denoising autoencoder* dapat dilihat pada Gambar 3.1. Perbedaan utamanya adalah penambahan derau pada data sebelum masuk ke dalam *encoder* data dan dipetakan ke data asli (bersih). Dengan kata lain, sistem belajar membersihkan dirinya sendiri dari derau yang ditambahkan tersebut. Hasil eksperimen menunjukkan bahwa performa yang relatif stabil dapat diperoleh menggunakan *denoising autoencoder* (Tabel 3.4).



Sumber: Zilvan dkk. (2019, 2022)

Gambar 3.1 Perbandingan *Autoencoder* dan *Denoising Autoencoder*

Buku ini tidak diperjualbelikan.

Setelah berhasil membangun dataset teh, sistem identifikasi penyakit tanaman teh berbasis pembelajaran mesin dan pembelajaran dalam dikembangkan. Kandidat telah menerapkan, pertama, penerapan DCNN sebagai model prediksi penyakit. Tiga arsitektur DCNN, yaitu GoogleNet, Xception, dan Inception-Resnet digunakan untuk mendeteksi empat jenis kelas pada data penyakit teh (Krisnandi dkk., 2019). Hasilnya terlihat pada Tabel 3.4 yang menunjukkan akurasi yang tinggi. Kedua, untuk meningkatkan performa sistem, fitur hibrida pada fitur warna RGB dikombinasikan dengan fitur tekstur *linear binary pattern* (LBP) dan digunakan sebagai masukan ke DCNN (Kusumo dkk., 2020). Hasilnya menunjukkan bahwa penggabungan ini dapat meningkatkan performa sistem (Tabel 3.6).

Tabel 3.6 Kinerja Fitur Hibrida Warna (RGB) dan Tekstur (*Linear Binary Pattern*) untuk Sistem Pengenalan Penyakit pada Teh

Fitur	Performa
Warna (RGB)	93,50
<i>Hybrid</i> (RGB +LBP)	96,20

Sumber: Kusumo dkk. (2020)

Pembelajaran dalam adalah model yang membutuhkan data besar untuk melatih. Namun, untuk menghasilkan data besar dibutuhkan biaya besar. Oleh karena itu, dibutuhkan solusi agar model pembelajaran dalam yang dihasilkan dapat tetap efektif ketika dilatih dengan data yang sedikit. Pada rekam jejak peneliti, kandidat telah mengkaji dua teknik sebagai solusi keterbatasan data. Teknik pertama adalah dengan melakukan *transfer learning* dan *fine tuning*, serta teknik kedua dengan menggunakan teknik data augmentasi.

Transfer learning adalah proses melakukan alih model dari domain permasalahan yang sudah dilatih dengan data yang besar ke domain permasalahan lain. Pada studi Ramdan, Heryana, dkk. (2020), dilakukan *transfer learning* dari model yang sudah dilatih dengan data ImageNet. ImageNet merupakan data citra sejumlah 14 juta data untuk pengenalan 22.000 kelas objek. Ada tiga model arsitektur DCNN yang ditransfer, yaitu VGGNet, ResNet, dan Xception. Untuk mengatasi perbedaan domain permasalahan ImageNet ke domain target, diperlukan strategi *fine tuning*. *Fine tuning* adalah strategi melatih ulang model arsitektur pembelajaran dalam dengan menggunakan model transfer sebagai inisialisasinya. *Fine tuning* diperlukan jika domain permasalahan model asal dan model tujuan berbeda. Makin jauh perbedaan domain permasalahan awal dan tujuan maka makin banyak bagian model yang dilakukan *fine tuning*. Untuk menguji apakah *fine tuning* diperlukan, dilakukan variasi *fine tuning* pada penelitian terdahulu. Hasil eksperimen menggunakan *transfer learning* dan *fine tuning* dapat dilihat pada Tabel 3.7.

Tabel 3.7 Perbandingan Kinerja Penerapan *Transfer Learning* dan *Fine Tuning* pada Sistem Identifikasi Penyakit Teh

Model DCNN	Train from Scratch	Transfer Learning	partial fine tuning	Full fine tuning
ResNet	73,33	19,73	19,73	94,05
VGGNet	84,86	86,04	90,27	91,26
Xception	76,85	56,49	59,19	91,71

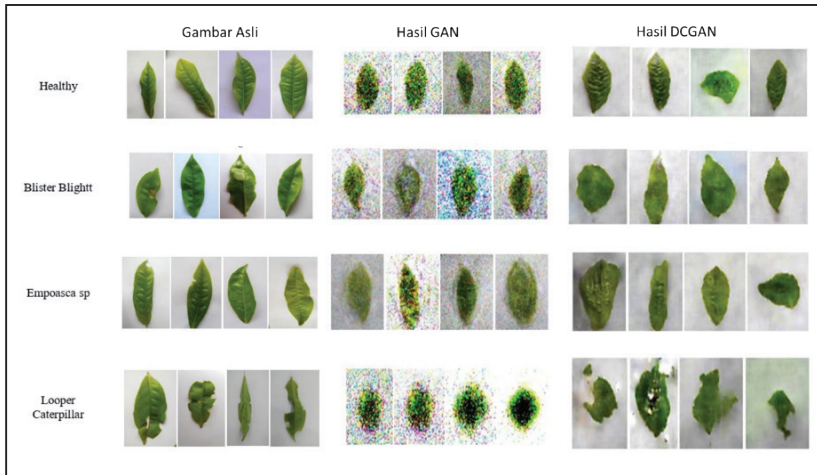
Sumber: Ramdan, Heryana, dkk. (2020)

Cara kedua mengatasi keterbatasan data adalah dengan melakukan augmentasi data. Augmentasi data adalah proses menghasilkan data baru secara artifisial berdasarkan data yang dimiliki. Di penelitian terdahulu, teknologi pembelajaran dalam terbukti dapat digunakan sebagai teknik augmentasi. Kelebihan penerapan pembelajaran dalam untuk augmentasi data adalah data yang dihasilkan merupakan data “baru”, bukan sekadar transformasi dari data yang ada sehingga variasi yang dihasilkan akan cenderung lebih natural. Dua arsitektur, yaitu GAN dan DCGAN digunakan sebagai metode augmentasi (Yuwana dkk., 2020). Hasil augmentasi akan digunakan sebagai data tambahan untuk melatih empat arsitektur DCNN, yaitu AlexNet, DenseNet, ResNet, and Xception. Hasilnya menunjukkan bahwa penerapan GAN dan DCGAN dapat meningkatkan performa sistem seperti yang ditampilkan pada Tabel 3.8. Sampel data gambar hasil DCNN dan perbandingan dengan data asli dapat dilihat pada Gambar 3.2

Tabel 3.8 Perbandingan Kinerja GAN dan DCGAN sebagai Teknik Augmentasi

Model DCNN	Tanpa Data Augmentasi	GAN untuk Augmentasi (1000)	DCGAN untuk Augmentasi (1000)	GAN untuk Augmentasi (2000)	DCGAN untuk Augmentasi (2000)
AlexNet	77,02	80,00	81,89	79,81	81,80
DenseNet	86,30	88,84	88,86	86,66	87,11
ResNet	71,53	72,16	70,63	73,78	73,51
Xception	72,25	73,06	71,98	73,06	64,59

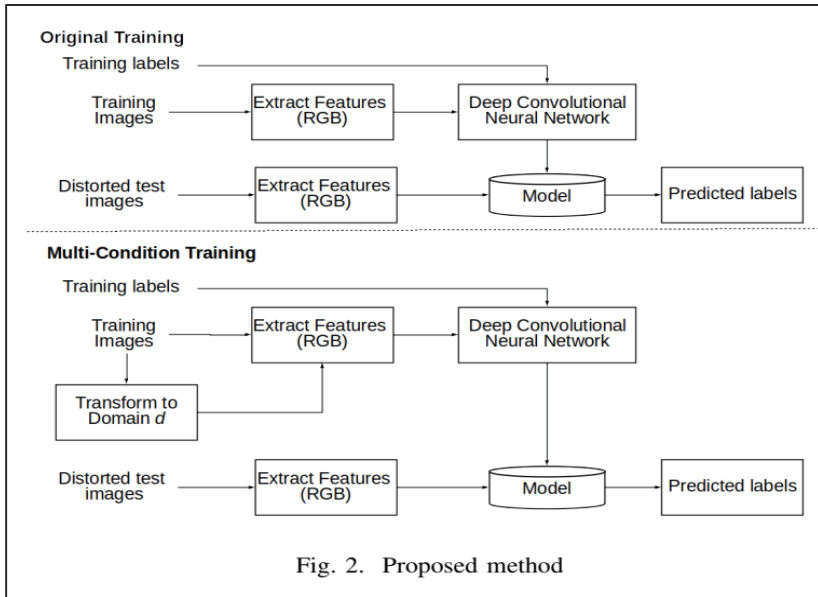
Sumber Yuwana dkk. (2020)



Sumber: Yuwana dkk. (2020)

Gambar 3.2 Sampel Contoh Data Hasil dari GAN dan DCGAN

Investigasi untuk peningkatan ketahanan dari sistem pembelajaran mesin dan pembelajaran dalam untuk identifikasi penyakit tanaman juga telah kandidat lakukan. Untuk ini, *multicondition training* diterapkan (Yuwana, Suryawati, Zilvan, dkk., 2019). Melalui *multicondition training*, data latih diganggu dengan menambah derau yang mungkin muncul ketika diimplementasikan dalam kondisi sebenarnya seperti terlihat pada Gambar 3.3. Hasil eksperimen menunjukkan bahwa tingkat ketahanan sistem dapat ditingkatkan menggunakan *multicondition training* (Tabel 3.9). Selain itu, teknik *smoothed label regularization* juga digunakan pada arsitektur DenseNet (Krisnandi dkk., 2021). Hasilnya menunjukkan peningkatan performa hingga mencapai 2%.



Sumber: Yuwana, Suryawati, Zilvan, dkk. (2019)

Gambar 3.3 Skema Proses *Multicondition Training* untuk Pembelajaran Dalam

Tabel 3.9 Perbandingan kinerja *multicondition training* pada dua arsitektur DCNN: AlexNet dan GoogleNet.

Kondisi data testing	AlexNet		GoogleNet	
	Normal	<i>Multicondition</i>	Normal	<i>Multicondition</i>
Original	81,62	79,20	77,30	71,65
Blur median 3	63,78	77,67	65,05	69,52
Blur median 3	56,31	76,23	59,55	68,68
Blur median 3	55,95	74,62	59,19	68,25
Blur median 3	55,41	74,02	59,55	67,72
Rotasi 10°	79,19	81,80	62,79	70,36
Rotasi 20°	71,08	83,15	59,28	72,07
Rotasi 30°	64,41	83,15	55,50	73,87

Kondisi data testing	AlexNet		GoogleNet	
	Normal	<i>Multicondition</i>	Normal	<i>Multicondition</i>
Rotasi 50°	55,23	82,34	48,47	72,97
Rotasi 60°	52,52	78,74	48,20	68,38
Rotasi 70°	52,88	74,59	47,39	66,40
Rotasi 90°	61,80	66,31	56,13	66,94

Sumber: Yuwana dkk. (2020)

Dari berbagai studi kandidat, dapat disimpulkan bahwa terkait pengembangan algoritma pembelajaran mesin dan pembelajaran dalam untuk pendeteksian penyakit tanaman telah dihasilkan hal-hal sebagai berikut. Pertama adalah adanya data-set citra penyakit tanaman pada teh sejumlah lebih dari 19 ribu citra yang terbagi ke dalam 6 kelas, yaitu 5 jenis penyakit dan 1 kelas sehat. Kedua, dalam algoritma pembelajaran dalam, secara khusus DCNN telah dikembangkan dan menghasilkan akurasi yang lebih baik dibandingkan algoritma pembelajaran mesin dangkal. Namun, studi juga menunjukkan masih ada beberapa masalah riset yang perlu diselesaikan, antara lain menghasilkan model DCNN ringkas yang berakurasi tinggi dan meningkatkan ketahanan sistem terhadap variasi data yang dapat ditemukan ketika diimplementasikan pada kondisi yang sebenarnya.

2. Pengenalan Kualitas Pangan

Dalam rangka memaksimalkan pemanfaatan hasil-hasil pertanian dan perkebunan, diperlukan upaya pengelolaan pascapanen yang baik. Salah satu upaya pengelolaan hasil-hasil pertanian adalah seleksi produk hasil pertanian (seleksi bahan pangan) berupa buah-buahan, sayuran, umbi-umbian, daun-daunan, dan lain-lain. Seleksi ini diperlukan untuk menentukan tingkatan

kualitas dari produk pertanian tersebut, seperti kelayakan untuk dikonsumsi secara langsung (stroberi, tomat, manggis, teh, dan lain-lain) atau tingkat kualitas pangan fungsional yang dihasilkan dari produk pertanian tersebut.

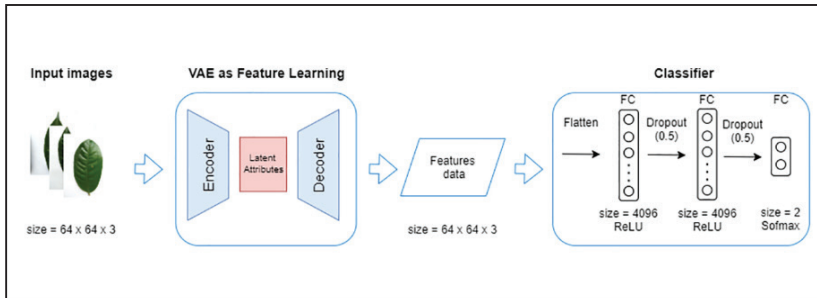
Pada tanaman teh, jenis klon teh dapat digunakan sebagai indikator kualitas dari teh. Citra bahan baku dapat digunakan sebagai indikator kualitas teh selain aroma, rasa, dan kandungan polifenol. Akan tetapi, perkebunan rakyat umumnya terdiri dari berbagai jenis klon. Oleh karena itu, sulit memprediksi kualitas teh yang dihasilkan dari suatu lahan perkebunan. Untuk mengatasinya, dapat dilakukan identifikasi manual secara visual terhadap klon pada setiap area perkebunan. Namun, proses tersebut mahal dan memakan waktu.

Pada penelitian-penelitian kandidat, telah dilakukan pengenalan kualitas beberapa produk pangan, antara lain stroberi (Mahendra dkk., 2019; Sustika dkk., 2018), pakcoy (Ramdan, Sugiarto, dkk., 2019), dan teh (Ramdan, Suryawati, dkk., 2019; Suryawati, Zilvan, dkk., 2019; Zilvan dkk., 2022). Performa yang lebih baik untuk lebih banyak jenis klon diperoleh menggunakan ResNet dan DenseNet. Dalam pengenalan enam jenis klon teh, dapat dihasilkan performa hingga 93,02% seperti terlihat pada Tabel 3.10 (Ramdan, Zilvan, dkk., 2020).

Tabel 3.10 Perbandingan Performa DCNN pada pengenalan klon teh untuk 6 jenis klon teh

Arsitektur	Akurasi
ResNet	82,69
DenseNet	93,02

Sumber: Ramdan, Zilvan, dkk. (2020)



Sumber: Zilvan dkk. (2022)

Gambar 3.4 Arsitektur Variational *Autoencoder* yang Diusulkan untuk Identifikasi Pengenalan Klon

Berikutnya, penerapan *autoencoder* juga dilakukan pada sistem pengenalan klon teh. Kandidat melakukan modifikasi *autoencoder* yang disebut *variational autoencoder* (Zilvan dkk., 2022). Dengan arsitektur ini, *output encoder* dari *autoencoder* dapat dianggap sebagai sebuah model distribusi yang terdiri dari nilai rata-rata dan standar deviasinya sehingga keluaran dari *encoder* dapat disebut sebagai model generatif dari data. Arsitektur dari *autoencoder* yang diusulkan dapat dilihat pada Gambar 3.4. Terlihat bahwa *autoencoder* menghasilkan fitur yang lebih *robust* terhadap data yang buram, meskipun jika dibandingkan VGGNet, performanya lebih rendah pada kondisi *original* (Tabel 3.11).

Tabel 3.11 Performa *Variational Autoencoder* dibandingkan VGGNet terhadap beberapa kondisi data uji.

Kondisi data testing	Arsitektur/Metode	Akurasi
<i>Original</i>	<i>Variational autoencoder</i>	0,83
	<i>VGGNet</i>	0,98
<i>Gaussian Blur</i>	<i>Variational autoencoder</i>	0,75
	<i>VGGNet</i>	0,60
<i>Median Blur</i>	<i>Variational autoencoder</i>	0,78
	<i>VGGNet</i>	0,73

Sumber: Zilvan dkk. (2022)

Dari studi penerapan pembelajaran mesin dan pembelajaran dalam pada identifikasi kualitas pangan, telah dihasilkan hal-hal sebagai berikut. Pertama, telah dikembangkan empat jenis dataset untuk pendeteksian kualitas pangan terhadap tanaman teh, stroberi, pakcoy, dan manggis. Kedua, algoritma pembelajaran dalam—secara khusus DCNN—telah dikembangkan dan menghasilkan akurasi yang tinggi. Permasalahan terkait ukuran model DCNN dan juga peningkatan ketahanan sistem terhadap variasi data masih menjadi tantangan.

C. Model Pembelajaran Dalam Ringkas, Tahan, dan Berkinerja Tinggi

Untuk mengatasi keterbatasan infrastruktur di Indonesia, dibutuhkan model pembelajaran dalam yang ringkas dan tahan terhadap variasi data. Pada penelitian-penelitian kandidat, telah dihasilkan tiga arsitektur baru untuk pembelajaran dalam. Pertama, CompactNet adalah sebuah arsitektur DCNN yang ringkas secara ukuran, tetapi memiliki akurasi tinggi. Kedua, model *feature learning* yang disebut EGAN untuk menghasilkan teknik

Tabel 3.12 Perbandingan ComNet dengan Arsitektur DCNN Lainnya

Arsitektur DCNN	Jumlah Parameter (Juta)	Training Time (s)		Performa	
		PlantVillage	Teh	PlantVillage	Teh
AlexNet	29,78	2,59	3,86	94,44	79,82
VGGNet	39,93	7,00	10,35	93,79	81,31
MobileNet	3,24	3,51	5,43	61,17	37,45
ResNet	23,59	6,85	10,20	93,79	70,37
Xception	20,88	7,79	11,78	92,62	73,22
ComNet	9,66	3,33	4,94	96,61	86,17

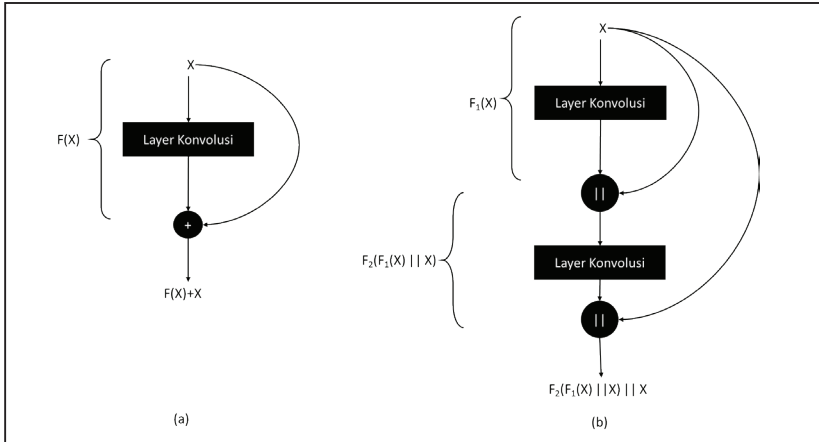
Keterangan: *Training time* adalah waktu latih rata-rata untuk 1 epoch.

Sumber: Zilvan dkk. (2022)

feature learning yang menghasilkan akurasi yang lebih tinggi dari *autoencoder*. Ketiga, fungsi *loss* baru, yaitu *q-Sigmoid* untuk menggantikan fungsi *sigmoid* yang biasa digunakan pada *perceptron*, penyusun dari pembelajaran dalam. Fungsi ini dihasilkan dengan menerapkan statistika *non-extensive* dan menghasilkan performa lebih tinggi.

1. CompactNet: Model Ringkas DCNN

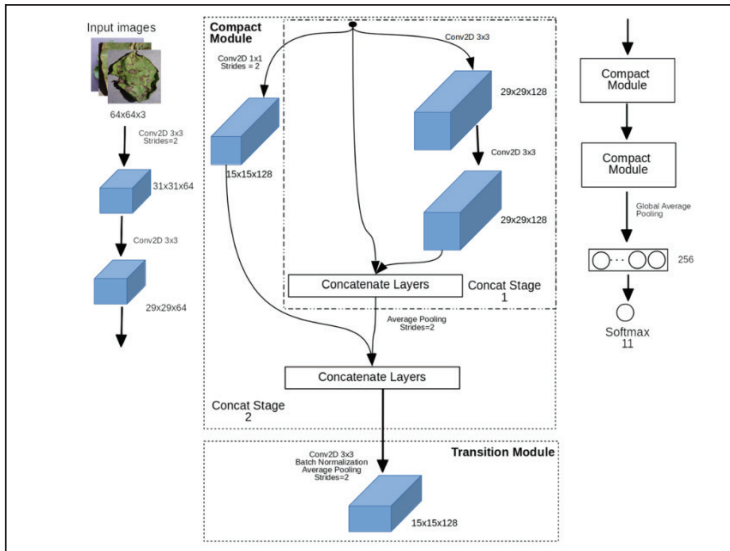
Sebuah arsitektur DCNN ringan dan berkinerja tinggi telah diusulkan kandidat pada penelitian terdahulu (Pardede, Suryawati, Zilvan, dkk., 2020). Arsitektur ini disebut CompactNet (ComNet). ComNet merupakan modifikasi dari ResNet dengan menambah jumlah *skip connection*. Selain itu, penggabungan aliran data dari *layer* konvolusi dan *skip connection* menggunakan penggabungan seperti pada DenseNet, bukan penambahan seperti pada ResNet. Perbedaan antara ResNet dan CompactNet dapat dilihat pada Gambar 3.5 dan arsitektur lengkap CompactNet dapat dilihat pada Gambar 3.6.



Keterangan: (a) Residual Networks dan (b) Compact Networks.

Sumber: Pardede dkk. (2020)

Gambar 3.5 Perbandingan Arsitektur



Sumber: Pardede dkk. (2020)

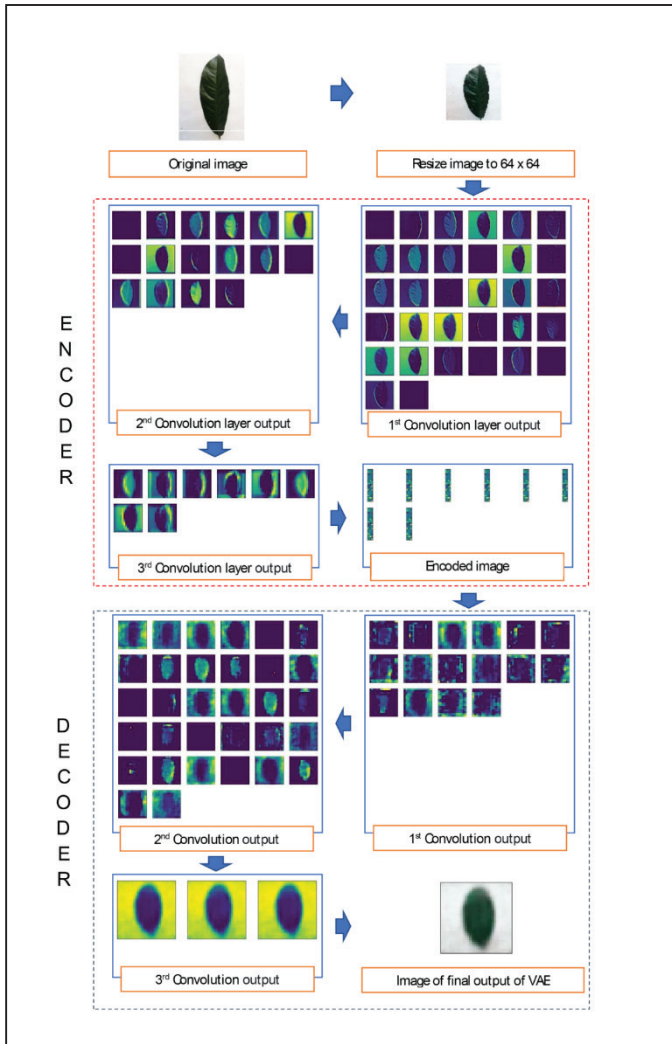
Gambar 3.6 Skematika Lengkap Arsitektur CompactNet

Buku ini tidak diperjualbelikan.

Penerapan ComNet terbukti mengurangi kebutuhan penggunaan *layer* yang sangat dalam seperti pada ResNet dan DenseNet. Terbukti bahwa hanya diperlukan jumlah parameter yang lebih sedikit (Tabel 3.12). Dengan jumlah parameter yang lebih sedikit, dibutuhkan jumlah waktu latih yang lebih sedikit. Model tersebut memiliki ukuran hanya hampir seperempat dari model VGGNet, dengan waktu latih hanya setengahnya. Ini membuat ComNet dapat diterapkan pada sistem tertanam sehingga memungkinkan implementasi sistem tanpa membutuhkan konektivitas internet.

2. EGAN: Encoder-GAN Sebagai Teknik *Feature Learning*

Hasil studi kandidat menunjukkan penerapan *feature learning* menggunakan *autoencoder* meningkatkan ketahanan dari sistem pembelajaran dalam (Pardede, Suryawati, dkk., 2019; Pardede, Zilvan, dkk., 2019; Subekti dkk., 2018; Suryawati dkk., 2021; Suryawati, Zilvan, dkk., 2019; Zilvan dkk., 2022). Namun, performa kondisi normal malah menjadi rendah. Hal ini dikarenakan hasil rekonstruksi citra dari *autoencoder* cenderung menghasilkan gambar yang lebih buram (Gambar 3.7).



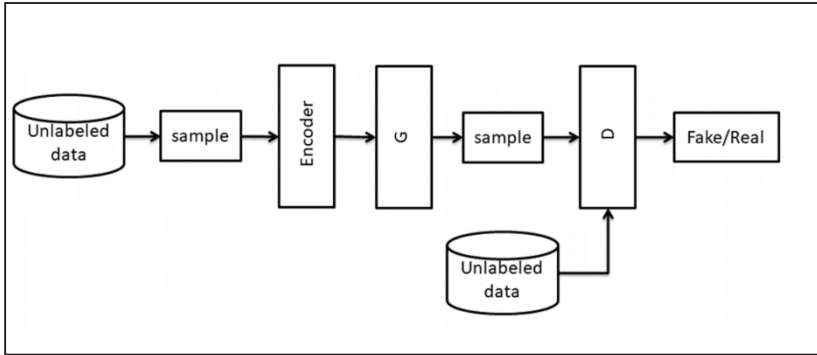
Sumber: Zilvan dkk. (2022)

Gambar 3.7 Visualisasi Citra dari Hasil Variational Autoencoder yang Terlihat Buram

Untuk mengatasi hal tersebut, GAN digunakan untuk *feature learning* (Suryawati dkk., 2021; Suryawati, Zilvan, dkk., 2019). GAN awalnya digunakan untuk menghasilkan data palsu yang mirip dengan data asli. Hal ini membuat GAN lebih sesuai digunakan sebagai teknik augmentasi data (Yuwana dkk., 2020). Penggunaan GAN untuk *feature learning* mengalami kendala karena proyeksi pembelajaran GAN sulit diprediksi. Hal ini dikarenakan *input* dari *generator* pada GAN adalah derau acak dan proses latihnya yang tanpa supervisi menyebabkan hasil pembelajaran tersebut sulit ditebak. Untuk mengatasi hal tersebut, ditambahkan *variational encoder* di atas GAN. Arsitektur ini disebut EGAN. Dengan demikian, inisialisasi GAN adalah hasil pembelajaran dari *encoder* sehingga hasil proyeksinya lebih terarah. Arsitektur EGAN dapat dilihat pada Gambar 3.8. EGAN menghasilkan performa lebih baik dibandingkan teknik *feature learning* lainnya, seperti *autoencoder*, GAN, dan BiGAN (Donahue dkk., 2016) (Tabel 3.13).

3. Q-Sigmoid: Tuneable Surrogate Loss untuk Pembelajaran Mesin

Pada penelitian kandidat dilakukan generalisasi fungsi *sigmoid loss* untuk pembelajaran mesin (Pardede dkk., 2022). Hal ini dilakukan untuk memperoleh sebuah fungsi *loss* baru yang menghasilkan kinerja yang lebih baik. Generalisasi dilakukan menggunakan statistika Tsallis (Tsallis, 1988). Statistika Tsallis sendiri adalah usaha menjelaskan fenomena *non-additive* pada sistem kompleks yang tidak bisa dijelaskan menggunakan entropi Shannon yang berbasis statistika Boltzmann-Gibbs. Pada sistem kompleks, terdapat relasi kompleks di antara data ataupun komponen data yang sulit dimodelkan sehingga secara observasi, entropi sistem tersebut tidak memenuhi penjumlahan entropi komponen penyusunnya.




Sumber: Suryawati dkk., (2021).

Gambar 3.8 Skematika Arsitektur EGAN untuk *Feature Learning*

Tabel 3.13 Perbandingan performa EGAN dan metode *feature learning* lain dan fitur warna.

Dataset	Arsitektur	Ekstraksi Fitur				
		DCNN	RGB	GAN	CNNAE	BiGAN
Klon Teh	AlexNet	90,48	81,85	87,83	78,76	94,02
	DenseNet	80,97	75,22	80,75	82,30	94,46
Jagung	AlexNet	92,46	84,12	92,86	83,73	93,25
	DenseNet	92,46	78,57	90,08	81,74	95,63
Kentang	AlexNet	89,70	83,08	91,91	85,29	97,05
	DenseNet	94,85	80,14	88,97	85,29	98,52
Apel	AlexNet	91,32	76,53	87,76	78,57	93,87
	DenseNet	89,28	69,38	87,76	77,55	95,91
MNIST	AlexNet	96,10	90,96	95,30	90,20	97,70
	DenseNet	97,00	83,63	96,07	87,70	98,83

Sumber: Pardede dkk. (2022)




Sumber: Pardede dkk. (2013a)

Gambar 3.9 Fungsi q -log yang Menjadi Fondasi Statistika Tsallis untuk Berbagai Variasi Nilai q

Statistika Tsallis menggunakan fungsi yang disebut q -logaritma (q -log) yang merupakan generalisasi dari fungsi logaritmik natural ketika nilai parameter $q = 1$ (Gambar 3.9). Fungsi ini memiliki *inverse* yang disebut q -exponensial. Pada penelitian kandidat telah dilakukan beberapa implementasi statistika Tsallis pada pengolahan data untuk pembelajaran mesin, antara lain sebagai berikut. Pertama, sebuah formulasi teknik normalisasi berbasis Tsallis untuk data suara (Pardede dkk., 2013a; Pardede & Shinoda, 2011). Formulasi adaptasi teknik normalisasi tersebut juga telah dilakukan (Pardede, Yuliani, dkk., 2019). Kedua, teknik menghilangkan derau berbasis Tsallis untuk menghilangkan derau pada data suara (Pardede dkk., 2012, 2013b). Metode ini juga telah diterapkan pada sistem komunikasi aman yang mampu meningkatkan kualitas suara hasil enkripsi

pada komunikasi aman (Pardede, Ramli, dkk., 2019). Berbagai fitur *hand-designed* untuk data suara berbasis Tsallis juga telah diusulkan kandidat (Dahlan dkk., 2019; Pardede, 2016, 2017; Yuliani dkk., 2017).



Keterangan: (a) q -Sigmoid dan (b) Turunannya

Sumber: Pardede dkk. (2022)

Gambar 3.10 Fungsi *loss* untuk Pembelajaran Mesin

Pada pembelajaran dalam dan pembelajaran mesin, salah satu elemen penting untuk melakukan optimasi model adalah pemilihan fungsi *loss*. Kondisi ideal adalah menggunakan 0-1 *loss* untuk klasifikasi biner, tetapi fungsi ini tidak memiliki turunan sehingga proses belajar menjadi tidak dapat terunut. Oleh karena itu, penerapan fungsi *loss* pengganti menjadi pilihan. Salah satu fungsi *loss* pengganti yang sering digunakan adalah fungsi *sigmoid*. Dengan statistika Tsallis, fungsi *sigmoid* digeneralisasi dan disebut q -sigmoid. Fungsi q -sigmoid dapat dilihat pada Gambar 3.10.

Penerapan fungsi q -sigmoid pada metode *perceptron*, penyusun pembelajaran dalam, menunjukkan bahwa terdapat hal yang menarik, yaitu terkait *learning rate*. Umumnya, pada optimasi algoritma pembelajaran mesin dan pembelajaran dalam berbasis *gradient descent*, sebuah faktor yang disebut *learning rate* sengaja ditambahkan untuk mengontrol laju pembelajaran. Hal ini untuk memastikan proses belajar akan konvergen. Penambahan faktor ini tidak secara matematis, tetapi lebih ke observasi karena tanpa *learning rate*, kemungkinan proses belajar tidak mencapai konvergen. Dengan q -sigmoid, faktor *learning rate* dapat dijelaskan secara matematis. Ini menjadi kelebihan q -sigmoid. Hasil implementasi q -sigmoid lebih baik dibanding fungsi *sigmoid* pada berbagai data termasuk pada data pengenalan penyakit tanaman Plantvillage dan teh yang diperlihatkan pada Tabel 3.14.

Tabel 3.14 Performa Q-Sigmoid dibandingkan dengan sigmoid *loss*.

Learning Rate	Dataset				
	MNIST	Cifar-10	Cifar-100	Plantvillage	Tea
Baseline ($\alpha=0,01$)	97,40 ± 0,49	79,34 ± 0,96	79,58 ± 3,81	93,16 ± 0,93	83,14 ± 1,14
Baselines ($\alpha=0,1$)	98,27 ± 0,44	9,05 ± 1,26	81,58 ± 3,13	93,25 ± 1,44	84,94 ± 2,47
Proposed ($q=1,20$)	98,30 ± 0,27	79,25 ± 1,72	81,42 ± 2,61	94,13 ± 1,16	85,88 ± 1,11
Proposed ($q=1,22$)	98,32 ± 0,35	78,71 ± 1,65	81,92 ± 2,91	94,22 ± 1,05	82,24 ± 4,78
Proposed ($q=1,30$)	98,42 ± 0,23	80,30 ± 1,16	82,17 ± 3,69	94,09 ± 0,84	81,37 ± 5,12
Proposed ($q=1,40$)	98,33 ± 0,25	79,29 ± 1,69	82,83 ± 3,67	93,78 ± 0,89	82,98 ± 4,94
Proposed (Adaptive)	98,03 ± 0,44	82,50 ± 3,51	82,50 ± 3,51	93,51 ± 1,26	84,19 ± 2,82

Sumber: Pardede dkk. (2022)

IV. RELEVANSI, IMPLIKASI, DAN REKOMENDASI PENERAPAN PEMBELAJARAN MESIN DAN PEMBELAJARAN DALAM PADA SEKTOR PERTANIAN

Penerapan teknologi kecerdasan artifisial pada bidang pertanian menghasilkan berbagai solusi yang dapat dimanfaatkan oleh petani dan berbagai pemangku kepentingan. Salah satunya adalah dengan adanya sebuah platform informasi yang dapat dimanfaatkan oleh berbagai pihak. Pada bab ini akan dijelaskan berbagai bentuk relevansi penerapan kecerdasan artifisial serta implikasi yang dapat timbul. Selain itu, beberapa rekomendasi untuk meningkatkan peran kecerdasan artifisial pada bidang pertanian berdasarkan pengalaman dan pemahaman kandidat akan juga disajikan.

A. Pengembangan Platform Informasi

Selain melakukan riset pengembangan teknologi pembelajaran mesin dan pembelajaran dalam pada bidang pertanian, beberapa platform informasi juga telah dihasilkan. Sistem platform berbasis android dengan nama Leafo (Ramdan, Heryana, dkk., 2019b) untuk deteksi penyakit tanaman pada teh dan Klonti (Ramdan, Heryana, dkk., 2019a) telah dikembangkan dan diberi hak cipta.

Meskipun masih memiliki banyak kekurangan, diharapkan dengan adanya sistem ini dapat menjadi alat yang dapat dengan mudah digunakan oleh petani sehingga identifikasi dapat mudah dilakukan. Petani diharapkan dapat melakukan sendiri identifikasi penyakit tanaman. Apabila diperlukan, hasil identifikasi ini dapat diteruskan ke instansi terkait, seperti Kementerian Pertanian dan

dinas pertanian di tingkat provinsi dan kabupaten/kota sehingga pengguna teknologi ini tidak hanya petani, tetapi juga lembaga dan instansi pemerintah.

B. Kolaborasi Riset

Riset mengenai pengembangan sistem identifikasi penyakit tanaman khususnya pada teh dan sistem identifikasi pengenalan klon teh adalah riset kolaborasi dengan Pusat Penelitian Teh dan Kina. Pusat Penelitian Teh dan Kina adalah sebuah badan di bawah PT Riset Perkebunan Nusantara (RPN) yang merupakan perseroan terbatas yang berada di bawah naungan *holding* Perkebunan Nusantara PTPN III (Persero). Riset ini dilakukan untuk menjawab terbatasnya kebutuhan sumber daya manusia yang mampu melakukan identifikasi penyakit yang menyerang tanaman teh dan jenis klon teh. Hal ini sangat diperlukan mengingat identifikasi penyakit sedini mungkin mampu mengurangi risiko menurunnya hasil panen. Sementara itu, identifikasi jenis klon dapat digunakan sebagai cara memprediksi kualitas teh yang akan dihasilkan dari suatu lahan perkebunan.

Kerja sama ini menghasilkan dua dataset terkait tanaman teh, yaitu dataset penyakit teh (Ramdan dkk., 2021b) dan dataset klon teh (Ramdan dkk., 2021a). Dataset lain seperti stroberi (Mahendra dkk., 2019) dan manggis juga telah dikumpulkan pada penelitian-penelitian terdahulu. Dataset ini merupakan dataset produk pertanian Indonesia sehingga diharapkan dengan adanya dataset ini dapat digunakan oleh komunitas riset di bidang kecerdasan artifisial untuk mendorong makin berkembangnya penerapan pembelajaran mesin dan pembelajaran pada sektor pertanian.

Kolaborasi antara periset kecerdasan artifisial dan industri pertanian seperti ini menjadi sangat penting pada bidang kecerdasan artifisial, pembelajaran mesin, dan pembelajaran dalam. Hal ini dikarenakan periset di bidang kecerdasan artifisial tidak dapat bekerja tanpa adanya data dan pendapat ahli sebagai dasar pembangunan sistem berbasis kecerdasan artifisial. Diharapkan iklim mendorong kerja sama riset antara periset dan industri akan makin terbentuk di masa depan.

C. Rekomendasi

Melihat kemampuan sistem berbasis pembelajaran mesin dan pembelajaran dalam, seyogianya dapat didorong untuk penerapan kecerdasan artifisial yang lebih luas di Indonesia untuk membangun sistem pertanian cerdas dengan menggabungkan kecerdasan artifisial dengan teknologi *big data*, IoT, sistem sensor, dan instrumentasi.

Mengingat perlunya ketersediaan data dalam pengembangan kecerdasan artifisial di bidang pertanian, usaha pembangunan basis data pertanian di Indonesia perlu dilakukan. Indonesia dengan beragam produk pertanian, kondisi dan karakteristik lahan pertanian yang heterogen memerlukan basis data yang lengkap dan dapat diakses berbagai pemangku kepentingan baik periset, pegiat teknologi, pemerintah, maupun swasta.

Peran Kementerian Pertanian perlu didorong untuk pengembangan sistem yang terintegrasi secara nasional dalam rangka mendukung penanggulangan dan pengendalian penyakit tanaman. Selain itu, Kementerian Pertanian dapat mendorong terciptanya regulasi untuk mendukung penerapan kecerdasan artifisial pada sektor pertanian.

Hal lain yang juga perlu mendapat perhatian dalam pengembangan kecerdasan artifisial adalah terkait isu etika khususnya di bidang pertanian (Ryan, 2022). Aturan formal terkait cara agar penerapan teknologi tersebut tidak melanggar hak-hak asasi manusia, membahayakan manusia, privasi data, tanggung jawab, dan lain-lain perlu diatur agar pemanfaatan teknologi kecerdasan artifisial tidak berdampak negatif dan membahayakan bagi manusia.

V. KESIMPULAN

Hasil penelitian kandidat terkait pemanfaatan teknologi pembelajaran mesin dan pembelajaran dalam pada sektor pertanian telah berhasil menemukan model pembelajaran dalam yang ringkas, tahan, dan berakurasi tinggi. Model pembelajaran mesin dan pembelajaran dalam tersebut telah diterapkan pada sistem pengenalan penyakit tanaman, identifikasi jenis klon teh, pengenalan kualitas stroberi, dan identifikasi tingkat kesehatan tanaman pakcoy.

Hasil penelitian kandidat menemukan bahwa penerapan DCNN untuk identifikasi penyakit tanaman, pengenalan klon teh, pengenalan kualitas stroberi dapat menghasilkan akurasi di atas 90%. Namun, studi kandidat juga menemukan bahwa masalah ketahanan sistem terhadap variasi data masih perlu ditingkatkan karena dapat menurunkan kinerja sistem hingga kurang dari 60. Penggunaan *feature learning*, seperti *variational autoencoder* dan EGAN dapat meningkatkan ketahanan sistem.

Hasil penelitian kandidat juga telah menemukan model dengan ukuran ringkas, tetapi tetap berkinerja tinggi. Melalui model tersebut, tingkat ketahanan dapat ditingkatkan. Model tersebut memiliki besar hanya sepertiga dari model DCNN umumnya dan waktu latihnya hanya setengah dari model DCNN umumnya, tetapi mampu menghasilkan akurasi sistem yang lebih baik.

Kandidat juga telah berhasil menurunkan formulasi fungsi *loss* baru yang lebih efektif untuk pengenalan objek termasuk pengenalan penyakit dan identifikasi klon teh. Fungsi ini diturunkan dari statistika Tsallis yang memungkinkan adaptasi fungsi *loss* secara mandiri tanpa perlu dilakukan observasi heuristik terhadap proses latih.

Buku ini tidak diperjualbelikan.

VI. PENUTUP

Sebuah sistem kecerdasan artifisial yang baik diperoleh dari adanya penguasaan teknologi pembelajaran mesin dan pembelajaran dalam. Tidak dapat dimungkiri, tren penerapan pembelajaran mesin dan pembelajaran dalam pada bidang pertanian akan makin populer di masa depan. Hal ini didorong dengan makin tersedianya data terkait bidang pertanian sekarang ini. Oleh karena itu, penguasaan teknologi pembelajaran mesin dan khususnya pembelajaran dalam akan makin penting di masa akan datang.

Makin baiknya kinerja sistem pembelajaran mesin dan pembelajaran dalam membuat dimungkinkannya otomatisasi berbagai aspek kegiatan pertanian, dari tahapan awal pemilihan bibit hingga manajemen distribusi hasil pertanian. Oleh karena itu, kebutuhan akan adanya sistem berbasis kecerdasan artifisial, pembelajaran mesin, dan pembelajaran dalam akan makin besar di masa depan.

Namun, beberapa hal masih menjadi tantangan dalam pengembangan kecerdasan artifisial di Indonesia, antara lain rendahnya kolaborasi periset dan pegiat di bidang kecerdasan artifisial dengan pemangku kepentingan di bidang sektor pertanian baik pemerintah, industri, maupun petani itu sendiri. Hal ini dapat menyulitkan terciptanya sistem tersebut. Periset dan pegiat di bidang kecerdasan artifisial hanya akan bisa bekerja jika ada data riil dan opini ahli, yang dalam hal ini pemangku kepentingan, dalam membangun sistem tersebut. Oleh karena itu, kolaborasi dengan pemangku kepentingan baik dari lembaga riset, akademisi, pemerintah, maupun swasta sangat diperlukan.

Buku ini tidak diperjualbelikan.

Buku ini tidak diperjualbelikan.

VII. UCAPAN TERIMA KASIH

Puji syukur kepada Tuhan Yesus Kristus yang telah memberikan rahmat-Nya sehingga naskah orasi ilmiah ini dapat diselesaikan dengan baik. Semoga dapat memberikan manfaat bagi pengembangan ilmu pengetahuan dalam bidang teknologi informatika dan komunikasi, khususnya pada bidang kecerdasan artifisial.

Dalam kesempatan kali ini, saya mengucapkan terima kasih kepada Presiden Republik Indonesia, Ir. Joko Widodo, atas mandat dan penugasan saya sebagai peneliti utama di BRIN; Kepala Badan Riset dan Inovasi Nasional, Dr. Laksana Tri Handoko, M.Sc., atas dukungannya dalam penyelesaian naskah orasi ilmiah ini; Ketua Majelis Pengukuhan Profesor Riset, Prof. Dr. Ir. Gadis Sri Haryani; Sekretaris Majelis Pengukuhan Profesor Riset, Prof. Ir. Wimpie Agoeng Noegroho Aspar, MSCE., Ph.D.; Tim Penelaah Naskah Orasi Ilmiah, Prof. Dr. Ir. Dony Kushardono, M.Eng., M.Sc.; Prof. Dr. Ana Hadiana M.Eng.Sc., dan Prof. Dr. Ratno Nuryadi, M.Eng.; Plt. Sekretaris Utama BRIN, Nur Tri Aries Suestiningtyas, S.IP., M.A; Kepala Organisasi Riset Elektronika dan Informatika Dr. Eng. Budi Prawara; Kepala Pusat Riset Kecerdasan Artifisial dan Keamanan Siber, Dr. Eng. Anto Satryo Nugroho; panitia pelaksana Pengukuhan Profesor Riset; serta pihak-pihak lain yang berkenaan dengan penyelesaian naskah orasi ilmiah ini.

Terima kasih juga disampaikan kepada Dr. Esa Prakasa M.T. (Kepala Pusat Riset Sains Data dan Informasi), Dr. Didi Rosiyadi (Plt. Kepala Pusat Riset Informatika periode sebelumnya), Kepala Pusat Penelitian Informatika LIPI terdahulu: Drs. Tigor Nauli, Dr. Bogie Soedjatmiko E. Cahyono, Dr. Yan Rianto, Dr.

Buku ini tidak diperjualbelikan.

Purwoko Adhi, atas dukungannya selama berada di LIPI. Terima kasih untuk rekan-rekan di Pusat Riset Kecerdasan Artifisial dan Keamanan Siber BRIN untuk bantuan dan interaksi selama ini, khususnya rekan-rekan Kelompok Riset Machine Learning.

Dalam menjalani pendidikan, tak lupa kandidat mengucapkan terima kasih kepada guru-guru SD, SMP, dan SMA yang telah membimbing dalam menempuh pendidikan dasar. Ucapan terima kasih kepada Prof. Dr. Ir. Djoko Hartanto, M.Sc. yang telah membimbing kandidat pada jenjang S-1 di UI; Prof. Roberto Togneri, PhD yang telah membimbing kandidat pada jenjang S-2 di UWA, serta Prof. Koichi Shinoda (Tokyo Institute of Technology) dan A. Prof. Koji Iwano (Tokyo City University) yang telah membimbing kandidat pada jenjang S-3 di Tokyo Institute of Technology. Kandidat juga mengucapkan terima kasih kepada rekan-rekan Shinoda Lab, antara lain Dr. Sangeeta Biswas, Dr. Johan Rohdin, Dr. Yuan Liang, dan Dr. Muhammad Rasyid Aqmar, yang telah banyak membantu dalam penyelesaian disertasi. Terima kasih kepada kolega dari Fondazione Bruno Kessler, antara lain Dr. Maurizio Omologo dan Dr. Marco Matassoni yang banyak memberikan dukungan selama *postdoc*. Terima kasih disampaikan kepada kolaborator riset selama ini dari Pusat Penelitian Teh dan Kina, Universitas Indonesia, Universitas Nusa Mandiri, dan Asia University.

Saya menghaturkan terima kasih kepada kedua orang tua, Almarhum Bapak Kitaman Pardede dan Ibu Sinta Siahaan, yang telah membimbing, mendidik, dan memberikan doa atas pencapaian saya selama ini. Untuk kakak-kakakku—Anita Sriwati, M.K.M, Betman Hidayat Pardede, dan Nancy Elfrida Pardede, S.K.M—terima kasih banyak atas dukungan dan doanya. Untuk

istriku tersayang, Mariska Margaret Pitoi, M.Sc, dan anak-anakku—Gabe Ezekiel Pardede, Posma Eliezer Pardede, dan Hannah Elisha Pardede—terima kasih atas kesabaran, dukungan, dan doanya untuk Papa dalam meniti karier sebagai peneliti. Terakhir, saya mengucapkan terima kasih kepada semua teman-teman yang tidak dapat disebutkan satu per satu.

Buku ini tidak diperjualbelikan.

Buku ini tidak diperjualbelikan.

DAFTAR PUSTAKA

- Abka, A. F., & **Pardede, H. F.** (2015). Speech recognition features: Comparison studies on robustness against environmental distortions. Dalam *Proceeding - 2015 International Conference on Computer, Control, Informatics and Its Applications: Emerging Trends in the Era of Internet of Things, IC3INA 2015* (114–119). IEEE. <https://doi.org/10.1109/IC3INA.2015.7377757>
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798–1828.
- Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine Learning in Agriculture: A Comprehensive Updated Review. *Sensors*, 21(11). <https://doi.org/10.3390/s21113758>
- Biro Pusat Statistik. (2021). *Produk domestik bruto Indonesia triwulanan 2017 - 2021*.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, Issue 4). Springer.
- Cemgil, T., Ghaisas, S., Dvijotham, K., Goyal, S., & Kohli, P. (2020). The autoencoding variational autoencoder. *Advances in Neural Information Processing Systems*, 33, 15077–15087.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. Dalam *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (1251–1258).
- Cisternas, I., Velásquez, I., Caro, A., & Rodríguez, A. (2020). Systematic literature review of implementations of precision agriculture. *Computers and Electronics in Agriculture*, 176, 105626.

- Dahlan, R., Krisnandi, D., Ramdan, A., & **Pardede, H. F.** (2019). Unbiased Noise Estimator for Q-Spectral Subtraction based Speech Enhancement. Dalam *Proceedings - 2019 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications, ICRAMET 2019* (65–68). IEEE. <https://doi.org/10.1109/ICRAMET47453.2019.8980396>
- Donahue, J., Krähenbühl, P., & Darrell, T. (2016). Adversarial feature learning. *ArXiv Preprint ArXiv:1605.09782*.
- FAO. (2021, 2 Juni). *Climate change fans spread of pests and threatens plants and crops, new FAO study*. <https://www.fao.org/news/story/en/item/1402920/icode/>
- Floridi, L. (2020). AI and its new winter: from myths to realities. *Philosophy and Technology*, 33(1), 1–3. <https://doi.org/10.1007/s13347-020-00396-6>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139–144.
- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (4700–4708). IEEE.
- Hughes, D., & Salathé, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics. *ArXiv Preprint ArXiv:1511.08060*.

- Jakaria, A., & **Pardede, H. F.** (2022). Comparison of classification of birds using lightweight deep convolutional neural networks. *Jurnal Elektronika dan Telekomunikasi*, 22(2), 87–94.
- Kahn, K., & Winters, N. (2021). Constructionism and AI: A history and possible futures. *British Journal of Educational Technology*, 52(3), 1130–1142.
- Kantasa-Ard, A., Nouiri, M., Bekrar, A., Ait el Cadi, A., & Sallez, Y. (2021). Machine learning for demand forecasting in the physical internet: A case study of agricultural products in Thailand. *International Journal of Production Research*, 59(24), 7491–7515.
- Kour, V. P., & Arora, S. (2020). Recent developments of the internet of things in agriculture: a survey. *IEEE Access*, 8, 129924–129957.
- Krisnandi, D., Kusumo, R., Yuwana, R. S., Zilvan, V., Heryana, A., Yuliani, A. R., Suryawati, E., & **Pardede, H. F.** (2021). Densely connected networks with smoothed labels regularization for tea diseases detections. Dalam *ACM International Conference Proceeding Series* (40–44). <https://doi.org/10.1145/3489088.3489098>
- Krisnandi, D., **Pardede, H. F.**, Yuwana, R. S., Zilvan, V., Heryana, A., Fauziah, F., & Rahadi, V. P. (2019). Diseases classification for tea plant using concatenated convolution neural network. *CommIT (Communication and Information Technology) Journal*, 13(2), 67–77.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- Kurniasih, A., Santoso, A. K., Wicaksono, B. D., & **Pardede, H. F.** (2022). Evaluations of emotion analysis of tweets using bidirectional long short term memory and conventional machine learning. *Jurnal Teknologi dan Sistem Komputer*.
- Kurniawati, I., & **Pardede, H. F.** (2018). Hybrid method of information gain and particle swarm optimization for selection of features

- of SVM-based sentiment analysis. Dalam *2018 International Conference on Information Technology Systems and Innovation, ICITSI 2018 - Proceedings* (1–5). IEEE. <https://doi.org/10.1109/ICITSI.2018.8695953>
- Kusumo, R., Heryana, A., Krisnandi, D., Yuwana, R. S., Zilvan, V., & **Pardede, H. F.** (2020). Deep convolutional neural networks-based plants diseases detection using hybrid features. *Computer Engineering and Applications*, *9*(3).
- Kusumo, R., Heryana, A., Mahendra, O., & **Pardede, H. F.** (2019). Machine learning-based for automatic detection of corn-plant diseases using image processing. Dalam *2018 International Conference on Computer, Control, Informatics and Its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding* (93–97). IEEE. <https://doi.org/10.1109/IC3INA.2018.8629507>
- Lioutas, E. D., & Charatsari, C. (2020). Big data in agriculture: Does the new oil lead to sustainability? *Geoforum*, *109*, 1–3.
- Mahendra, O., **Pardede, H. F.**, Sustika, R., & Kusumo, R. (2019). Comparison of Features for Strawberry Grading Classification with Novel Dataset. Dalam *2018 International Conference on Computer, Control, Informatics and Its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding* (7–12). IEEE. <https://doi.org/10.1109/IC3INA.2018.8629534>
- Maulidah, M., & **Pardede, H. F.** (2021). Prediction of Myers-Briggs Type Indicator Personality using long short-term memory. *Jurnal Elektronika Dan Telekomunikasi*, *21*(2), 104–111.
- Meshram, V., Patil, K., Meshram, V., Hanchate, D., & Ramkteke, S. D. (2021). Machine learning in agriculture domain: A state-of-art survey. *Artificial Intelligence in the Life Sciences*, *1*, 100010. <https://doi.org/https://doi.org/10.1016/j.ails.2021.100010>

- Nalatissifa, H., & **Pardede, H. F.** (2021). Customer decision prediction using deep neural network on Telco Customer Churn data. *Jurnal Elektronika Dan Telekomunikasi*, 21(2), 122–127.
- Nielsen, M. A. (2015). *Neural networks and deep learning*. Determination press.
- Nugraha, R. A., **Pardede, H. F.**, & Subekti, A. (2022). Oversampling based on generative adversarial networks to overcome imbalance data in predicting fraud insurance claim: 10.48129/kjs. splml. 19119. *Kuwait Journal of Science*.
- Pardamean, A., & **Pardede, H. F.** (2021). Tuned bidirectional encoder representations from transformers for fake news detection. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(3), 1667–1671. <https://doi.org/10.11591/ijeecs.v22.i3.pp1667-1671>
- Pardede, H. F.** (2016). On noise robust feature for speech recognition based on power function family. Dalam *2015 International Symposium on Intelligent Signal Processing and Communication Systems, ISPACS 2015* (386–391). IEEE. <https://doi.org/10.1109/ISPACS.2015.7432801>
- Pardede, H. F.** (2017). On the impact of normalizing power-based features on robustness against noise for speech recognition. Dalam *Proceedings of 2016 8th International Conference on Information Technology and Electrical Engineering: Empowering Technology for Better Future, ICITEE 2016* (1–6). IEEE. <https://doi.org/10.1109/ICITEED.2016.7863308>
- Pardede, H. F.** (2021). Sentiment analysis of Stocktwits data with word vector and gated recurrent unit. *Jurnal Linguistik Komputasional*, 4(2), 47–51.
- Pardede, H. F.**, Adhi, P., Zilvan, V., Yuliani, A. R., & Arisal, A. (2022). A generalization of sigmoid loss function using tsallis statistics for binary classification. *Neural Processing Letters*. 55(4), 5193–5214. <https://doi.org/10.1007/s11063-022-11087-y>

- Pardede, H. F., Iwano, K., & Shinoda, K. (2013a).** Feature normalization based on non-extensive statistics for speech recognition. *Speech Communication*, 55(5), 587–599. <https://doi.org/10.1016/j.specom.2013.02.004>
- Pardede, H. F., Iwano, K., & Shinoda, K. (2013b).** Spectral subtraction based on non-extensive statistics for speech recognition. *IEICE Transactions on Information and Systems*, E96-D(8), 1774–1782. <https://doi.org/10.1587/transinf.E96.D.1774>
- Pardede, H. F., Ramli, K., Suryanto, Y., Hayati, N., & Presekal, A. (2019).** Speech enhancement for secure communication using coupled spectral subtraction and wiener filter. *Electronics (Switzerland)*, 8(8). <https://doi.org/10.3390/electronics8080897>
- Pardede, H. F., & Shinoda, K. (2011).** Generalized-log spectral mean normalization for speech recognition. Dalam *Proceedings of the Annual Conference of the International Speech Communication Association, Interspeech (1645–1648)*.
- Pardede, H. F., Shinoda, K., & Iwano, K. (2012).** Q-Gaussian based spectral subtraction for robust speech recognition. Dalam *13th Annual Conference of the International Speech Communication Association 2012, Interspeech 2012*, 2, (1254–1257).
- Pardede, H. F., Suryawati, E., Krisnandi, D., Yuwana, R. S., & Zilvan, V. (2020).** Machine learning based plant diseases detection: A review. Dalam *Proceeding - 2020 International Conference on Radar, Antenna, Microwave, Electronics and Telecommunications, ICRAMET 2020 (212–217)*. IEEE. <https://doi.org/10.1109/ICRAMET51080.2020.9298619>
- Pardede, H. F., Suryawati, E., Sustika, R., & Zilvan, V. (2019).** Un-supervised convolutional autoencoder-based feature learning for automatic detection of plant diseases. Dalam *2018 International Conference on Computer, Control, Informatics and Its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding (158–162)*. IEEE. <https://doi.org/10.1109/IC3INA.2018.8629518>

- Pardede, H. F.**, Suryawati, E., Zilvan, V., Ramdan, A., Kusumo, R., Heryana, A., Yuwana, R. S., Krisnandi, D., Subekti, A., Fauziah, F., Fauziah, F., & Rahadi, V. P. (2020). Plant diseases detection with low resolution data using nested skip connections. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-020-00332-7>
- Pardede, H. F.**, Yuliani, A. R., & Subekti, A. (2019). On the effect of the implementation of human auditory systems on Q-log-based features for robustness of speech recognition against noise. *Journal of Information Science and Engineering*, 35(1). [https://doi.org/10.6688/JISE.201901_35\(1\).0005](https://doi.org/10.6688/JISE.201901_35(1).0005)
- Pardede, H. F.**, Yuliani, A. R., & Sustika, R. (2018). Convolutional neural network and feature transformation for distant speech recognition. *International Journal of Electrical and Computer Engineering*, 8(6). <https://doi.org/10.11591/ijece.v8i6.pp.5381-5388>
- Pardede, H. F.**, Zilvan, V., Krisnandi, D., Heryana, A., & Kusumo, R. (2019). Generalized filter-bank features for robust speech recognition against reverberation. Dalam *2019 International Conference on Computer, Control, Informatics and Its Applications: Emerging Trends in Big Data and Artificial Intelligence, IC3INA 2019*. IEEE. <https://doi.org/10.1109/IC3INA48034.2019.8949593>
- Ramdan, A., Heryana, A., Arisal, A., Kusumo, R., & **Pardede, H. F.** (2020). Transfer learning and fine-tuning for deep learning-based tea diseases detection on small datasets. Dalam *Proceeding - 2020 International Conference on Radar, Antenna, Microwave, Electronics and Telecommunications, ICRAMET 2020* (206–211). IEEE. <https://doi.org/10.1109/ICRAMET51080.2020.9298575>
- Ramdan, A., Heryana, A., Dahlan, R., Krisnandi, D., Suryawati, E., **Pardede, H. F.**, Mahendra, O., Yuwana, R. S., Kusumo, R., Dahlan, R., Rahadi, V. P., Fauziah, F., Khomaeni, H. S., Rohdia, D., & Zilvan, V. (2019a). *KlonTi - Aplikasi Identifikasi Klon Teh Otomatis* (Nomor Hak Cipta 000171814). Direktorat Jenderal Kekayaan Intelektual. <https://pdki-indonesia.dgip.go.id/detail/>

f6848a099bc67fbfe4aed172994a1b1c14232a459cd8d49f3f75bf-cc7d8a0595%3Fnomor=EC00201990322?type=copyright&keyword=KlonTi+-+Aplikasi+Identifikasi+Klon+Teh+Otomatis

Ramdan, A., Heryana, A., Dahlan, R., Krisnandi, D., Suryawati, E., **Pardede, H. F.**, Mahendra, O., Yuwana, R. S., Kusumo, R., Dahlan, R., Rahadi, V. P., Fauziah, F., Khomaeni, H. S., Rohdia, D., & Zilvan, V. (2019b). *LEAFO - Aplikasi Identifikasi Penyakit Tanaman Otomatis* (Nomor Hak Cipta 000171818). Direktorat Jenderal Kekayaan Intelektual. <https://pdki-indonesia.dgip.go.id/detail/50c8c9060731c19b1a00d46ea55772d43fe58f802e38a6acc7387baf8b9569f%3Fnomor=EC00201990323?type=copyright&keyword=LEAFO+-+Aplikasi+Identifikasi+Penyakit+Tanaman+%E2%80%8EOtomatis>

Ramdan, A., Heryana, A., Krisnandi, D., Suryawati, E., **Pardede, H. F.**, Mahendra, O., Yuwana, R. S., Kusumo, R., Dahlan, R., Rahadi, V. P., Fauziah, F., Khomaeni, H. S., Rohdia, D., & Zilvan, V. (2021a). *Dataset Citra Klon Daun Teh* (Nomor Hak Cipta 000304956). Direktorat Jenderal Kekayaan Intelektual. <https://pdki-indonesia.dgip.go.id/detail/299942c1ff94adc392b12a3412d74dd2f1b390b93d2e23addb30ff6f21ac70aa%3Fnomor=EC00202178029?type=copyright&keyword=Dataset+Citra+Klon+Daun+Teh>

Ramdan, A., Heryana, A., Krisnandi, D., Suryawati, E., **Pardede, H. F.**, Mahendra, O., Yuwana, R. S., Kusumo, R., Dahlan, R., Rahadi, V. P., Fauziah, F., Khomaeni, H. S., Rohdia, D., & Zilvan, V. (2021b). *Dataset Citra Penyakit Daun Teh* (Nomor Hak Cipta 000305043). Direktorat Jenderal Kekayaan Intelektual. <https://pdki-indonesia.dgip.go.id/detail/a01dc204e2ad7b446a62ebeaf74256cc5a39f35284d12fe0d5e1bba02fdde17e%3Fnomor=EC00202178031?type=copyright&keyword=Dataset+Citra+Penyakit+Daun+Teh>

Ramdan, A., Sugiarto, B., Rianto, P. D., Prakasa, E., & **Pardede, H. F.** (2019). Support vector machine-based detection of pak choy leaves conditions using RGB and HIS features. Dalam *2018*

International Conference on Computer, Control, Informatics and Its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding (114–117). IEEE. <https://doi.org/10.1109/IC3INA.2018.8629540>

- Ramdan, A., Suryawati, E., Kusumo, R., **Pardede, H. F.**, Mahendra, O., Dahlan, R., Fauziah, F., & Syahrian, H. (2019). Deep cnnbased detection for tea clone identification. *Jurnal Elektronika dan Telekomunikasi*, 19(2), 45–50.
- Ramdan, A., Zilvan, V., Suryawati, E., **Pardede, H. F.**, & Rahadi, V. P. (2020). Klasifikasi klon teh berbasis deep CNN dengan residual dan densely connections. *Jurnal Teknologi dan Sistem Komputer*, 8(4), 289–296.
- Ranzato, M., Boureau, Y.-L., & Cun, Y. (2007). Sparse feature learning for deep belief networks. *Advances in Neural Information Processing Systems*, 20.
- Ryan, M. (2022). The social and ethical impacts of artificial intelligence in agriculture: mapping the agricultural AI literature. *AI & Society*, 1–13.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *ArXiv Preprint ArXiv:1409.1556*.
- Subekti, A., **Pardede, H. F.**, Sustika, R., & Suyoto. (2018). Spectrum sensing for cognitive radio using deep autoencoder neural network and SVM. Dalam *Proceedings - 2018 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications, ICRAMET 2018* (81–85). IEEE. <https://doi.org/10.1109/ICRAMET.2018.8683930>
- Suryawati, E., **Pardede, H. F.**, Zilvan, V., Ramdan, A., Krisnandi, D., Heryana, A., Yuwana, R. S., Kusumo, R., Arisal, A., & Supianto, A. A. (2021). Unsupervised feature learning-based encoder and adversarial networks. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00508-9>

- Suryawati, E., Sustika, R., Yuwana, R. S., Subekti, A., & **Pardede, H. F.** (2019). Deep structured convolutional neural network for tomato diseases detection. *2018 International Conference on Advanced Computer Science and Information Systems, ICACISIS 2018* (385–390). IEEE. <https://doi.org/10.1109/ICACISIS.2018.8618169>
- Suryawati, E., Zilvan, V., Yuwana, R. S., Heryana, A., Rohdiana, D., & **Pardede, H. F.** (2019). Deep convolutional adversarial network-based feature learning for tea clones identifications. Dalam *ICICOS 2019 - 3rd International Conference on Informatics and Computational Sciences: Accelerating Informatics and Computational Research for Smarter Society in The Era of Industry 4.0, Proceedings*. IEEE. <https://doi.org/10.1109/ICI-CoS48119.2019.8982416>
- Sustika, R., Subekti, A., **Pardede, H. F.**, Suryawati, E., Mahendra, O., & Yuwana, S. (2018). Evaluation of deep convolutional neural network architectures for strawberry quality inspection. *International Journal of Engineering and Technology (UAE)*, 7(4), 75–80. <https://doi.org/10.14419/ijet.v7i4.40.24080>
- Swaminathan, B., Palani, S., Vairavasundaram, S., Kotecha, K., & Kumar, V. (2022). IoT-driven artificial intelligence technique for fertilizer recommendation model. *IEEE Consumer Electronics Magazine*, 12(2), 109–117.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. Dalam *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (1–9).
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. Dalam *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2818–2826).
- Tsallis, C. (1988). Possible generalization of Boltzmann-Gibbs statistics. *Journal of Statistical Physics*, 52, 479–487.

- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming—a review. *Agricultural Systems*, 153, 69–80.
- Yuliani, A. R., Ramdan, A., Zilvan, V., Supianto, A. A., Krisnandi, D., Yuwana, R. S., Prajitno, D., & **Pardede, H.** (2021). Remaining useful life prediction of lithium-ion battery based on LSTM and GRU. Dalam *ACM International Conference Proceeding Series* (21–25). <https://doi.org/10.1145/3489088.3489092>
- Yuliani, A. R., Sustika, R., Yuwana, R. S., & **Pardede, H. F.** (2017). Feature transformations for robust speech recognition in reverberant conditions. Dalam *Proceedings - 2017 International Conference on Computer, Control, Informatics and Its Applications: Emerging Trends In Computational Science and Engineering, IC3INA 2017*. IEEE. <https://doi.org/10.1109/IC3INA.2017.8251740>
- Yuwana, R. S., Fauziah, F., Heryana, A., Krisnandi, D., Kusumo, R., & **Pardede, H. F.** (2020). Data augmentation using adversarial networks for tea diseases detection. *Jurnal Elektronika dan Telekomunikasi*, 20(1), 29–35.
- Yuwana, R. S., Suryawati, E., & **Pardede, H. F.** (2019). On empirical evaluation of deep architectures for Indonesian POS tagging problem. Dalam *2018 International Conference on Computer, Control, Informatics and Its Applications: Recent Challenges in Machine Learning for Computing Applications, IC3INA 2018 - Proceeding* (204–208). IEEE. <https://doi.org/10.1109/IC3INA.2018.8629531>
- Yuwana, R. S., Suryawati, E., Zilvan, V., Ramdan, A., **Pardede, H. F.**, & Fauziah, F. (2019). Multi-condition training on deep convolutional neural networks for robust plant diseases detection. Dalam *2019 International Conference on Computer, Control, Informatics and Its Applications: Emerging Trends in Big Data and Artificial Intelligence, IC3INA 2019* (30–35). IEEE. <https://doi.org/10.1109/IC3INA48034.2019.8949580>

- Yuwana, R. S., Yuliani, A. R., & **Pardede, H. F.** (2018). On part of speech tagger for Indonesian language. *Proceedings - 2017 2nd International Conferences on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2017* (369–372). IEEE. <https://doi.org/10.1109/ICITISEE.2017.8285530>
- Zhang, J., Dai, L., & Cheng, F. (2021). Identification of corn seeds with different freezing damage degree based on hyperspectral reflectance imaging and deep learning method. *Food Analytical Methods*, *14*, 389–400.
- Zilvan, V., Heryana, A., Yuliani, A. R., Krisnandi, D., Yuwana, R. S., & **Pardede, H. F.** (2021). Front-end Based Robust Speech Recognition Methods: A Review. Dalam *ACM International Conference Proceeding Series* (136–140). Association for Computing Machinery. <https://doi.org/10.1145/3489088.3489121>
- Zilvan, V., Ni'mah, I., Yuliani, A. R., & **Pardede, H. F.** (2017). On real time Q-log-based feature normalization for distant speech recognition. Dalam *2016 International Conference on Information Technology Systems and Innovation, ICITSI 2016 - Proceedings*. IEEE. <https://doi.org/10.1109/ICITSI.2016.7858234>
- Zilvan, V., Ramdan, A., Heryana, A., Krisnandi, D., Suryawati, E., Yuwana, R. S., Kusumo, R., & **Pardede, H. F.** (2022). Convolutional variational autoencoder-based feature learning for automatic tea clone recognition. *Journal of King Saud University - Computer and Information Sciences*, *34*(6), 3332–3342. <https://doi.org/10.1016/j.jksuci.2021.01.020>
- Zilvan, V., Ramdan, A., Suryawati, E., Kusumo, R., Krisnandi, D., & **Pardede, H. F.** (2019). Denoising convolutional variational autoencoders-based feature learning for automatic detection of plant diseases. Dalam *ICICOS 2019 - 3rd International Conference on Informatics and Computational Sciences: Accelerating Informatics and Computational Research for Smarter Society in The Era of Industry 4.0, Proceedings*. IEEE. <https://doi.org/10.1109/ICI-CoS48119.2019.8982494>

DAFTAR PUBLIKASI ILMIAH

JURNAL INTERNASIONAL

1. **Pardede, H. F.**, Adhi, P., Zilvan, V., Yuliani, A. R., & Arisal, A. (2023). A generalization of sigmoid loss function using Tsallis statistics for binary classification. *Neural Processing Letters*, 55(4), 5193–5214.
2. Supianto, A. A, Nurdiansyah R., Weng C.W., Zilvan, V., Yuwana, R. S., Arisal, A., **Pardede, H. F.**, Lee, M. M., Huang, C. H., & Ng, K. L. (2023). Cluster-based text mining for extracting drug candidates for the prevention of COVID-19 from the biomedical literature. *Journal of Taibah University Medical Sciences*, 18(4), 787–801.
3. **Pardede, H. F.**, Adhi, P., Zilvan, V., Ramdan, A., & Krisnandi, D. (2023). Deep convolutional neural networks-based features for Indonesian large vocabulary speech recognition. *IAES International Journal of Artificial Intelligence*, 12(2), 610.
4. Pitoi, M. M., Harmoko, H., Tresnawati, A., **Pardede, H. F.**, Ariyani, M., Ridwan, Y. S., & Yusiasih, R. (2022). Pesticide residues in fruits and vegetables in Indonesia: findings of five-year proficiency testing. *Accreditation and Quality Assurance*, 27(4), 181–193.
5. Zilvan, V., Ramdan, A., Heryana, A., Krisnandi, D., Suryawati, E., Yuwana, R. S., Kusumo, R. B. S., & **Pardede, H. F.** (2022). Convolutional variational autoencoder-based feature learning for automatic tea clone recognition. *J King Saud Univ – Comput Inf Sci*, 34(6): 3332–3342.
6. Nugraha R.A., **Pardede, H.F.**, & Subekti, A. (2022). Oversampling based on generative adversarial networks to overcome imbalance data in predicting fraud insurance claim. *Kuwait J Sci*, 49.

7. Suryawati, E., **Pardede, H. F.**, Zilvan, V., Ramdan, A., Krisnandi, D., Heryana, A., Yuwana, R. S., Kusumo, R. B. S., Arisal, A., & Supianto, A. A. (2021). Unsupervised feature learning-based encoder and adversarial networks. *J Big Data*, 8(1).
8. Pardamean, A., & **Pardede, H. F.** (2021). Tuned bidirectional encoder representations from transformers for fake news detection. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(3), 1667–1671.
9. **Pardede, H. F.**, Suryawati, E., Zilvan, V., Ramdan, A., Kusumo, R. B. S., Heryana, A., Yuwana, R. S., Krisnandi, D., Subekti, A., Fauziah, F., & Rahadi, V. P. (2020). Plant diseases detection with low resolution data using nested skip connections. *Journal of Big Data*, 7, 1–21.
10. **Pardede, H. F.**, Ramli, K., Suryanto, Y., Hayati, N., & Presekal, A. (2019). Speech enhancement for secure communication using coupled spectral subtraction and Wiener filter. *Electronics*, 8(8), 897.
11. **Pardede, H. F.**, Yuliani, A. R., & Subekti, A. (2019). On the effect of the implementation of human auditory systems on Q-Log-based features for robustness of speech recognition against noise. *J. Inf. Sci. Eng.*, 35(1), 87–104.
12. **Pardede, H. F.**, Yuliani, A. R., & Sustika, R. (2018). Convolutional neural network and feature transformation for distant speech recognition. *International Journal of Electrical and Computer Engineering (IJECE)*, 8(6), 5381–5388.
13. Sustika, R., Subekti, A., **Pardede, H. F.**, Suryawati, E., Mahendra, O., & Yuwana, S. (2018). Evaluation of deep convolutional neural network architectures for strawberry quality inspection. *Int. J. Eng. Technol.*, 7(4), 75–80.
14. **Pardede, H. F.**, Iwano, K., & Shinoda, K. (2013). Feature normalization based on non-extensive statistics for speech recognition. *Speech Communication*, 55(5), 587–599.

15. **Pardede, H.**, Iwano, K., & Shinoda, K. (2013). Spectral subtraction based on non-extensive statistics for speech recognition. *IEICE Transactions on Information and Systems*, 96(8), 1774–1782.

JURNAL NASIONAL

16. Jakaria, A., & **Pardede, H. F.** (2022). Comparison of classification of birds using lightweight deep convolutional neural networks. *Jurnal Elektronika dan Telekomunikasi*, 22(2), 87–94.
17. Riana, D., Subekti, A., **Pardede, H. F.**, Putra, Z. P., & Aziz, F. (2022). Penyuluhan literasi media untuk bijak di media sosial dan pemanfaatan media digital. *Jurnal Abdimas Prakasa Dakara*, 2(2), 83–91.
18. Setyawan, O., & **Pardede, H. F.** (2022). Sentiment analysis for event-based stock price predictions using bidirectional long short term memory. *JISICOM (Journal of Information System, Informatics and Computing)*, 6(1), 50–58.
19. Suprayogi, D., & **Pardede, H. F.** (2022). Support vector regression dalam prediksi penurunan jumlah kasus penderita Covid-19. *Jointecs (Journal of Information Technology and Computer Science)*, 7(2), 63–70.
20. Kurniasih, A., Santoso, A. K., Wicaksono, B. D., & **Pardede, H. F.** (2022). Evaluations of emotion analysis of tweets using bidirectional long short term memory and conventional machine learning. *Jurnal Teknologi dan Sistem Komputer*.
21. Prasetyo, O., Supianto, A. A., Anam, S., **Pardede, H. F.**, Zilvan, V., & Kusumo, R. B. S. (2022). Peningkatan performa pengelompokan siswa berdasarkan aktivitas belajar pada media pembelajaran digital menggunakan metode adaptive moving self-organizing maps. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(1), 145–154.

22. Izzuddin, M., Supianto, A. A., Tibyani, T., **Pardede, H. F.**, Yuliani, A. R., & Ramdan, A. (2022). Peningkatan performa pengelompokan pola berpikir siswa dalam belajar pada media pembelajaran menggunakan direct batch growing self organizing map. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(1), 137–144.
23. Nalatissifa, H., & **Pardede, H. F.** (2021). Customer decision prediction using deep neural network on Telco Customer Churn data. *Jurnal Elektronika dan Telekomunikasi*, 21(2), 122–127.
24. Maulidah, M., & **Pardede, H. F.** (2021). Prediction of Myers-Briggs type indicator personality using long short-term memory. *Jurnal Elektronika dan Telekomunikasi*, 21(2), 104–111.
25. **Pardede, H.** (2021). Sentiment analysis of Stocktwits data with word vector and gated recurrent unit. *Jurnal Linguistik Komputasional*, 4(2), 47–51.
26. Kriswantara, B., Kurniawati, K., & **Pardede, H. F.** (2021). Prediksi harga mobil bekas dengan machine learning. *Syntax Literate; Jurnal Ilmiah Indonesia*, 6(5), 2100–2110.
27. Azhar, M., & **Pardede, H. F.** (2021). Klasifikasi dialek pengujar Bahasa Inggris menggunakan random forest. *Jurnal Media Informatika Budidarma*, 5(2), 439–446.
28. Putro, N. A., Septian, R., Widiastuti, W., Maulidah, M., & **Pardede, H. F.** (2021). Prediction of hotel booking cancellation using deep neural network and logistic regression algorithm. *Jurnal Techno Nusa Mandiri*, 18(1), 1–8.
29. Sautomo, S., & **Pardede, H. F.** (2021). Prediksi belanja pemerintah Indonesia menggunakan long short-term memory (LSTM). *Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi)*, 5(1), 99–106.
30. Oscar, N. M., Purnamawati, A., Putri, D., & **Pardede, H. F.** (2021). Prediksi tingkat kesuksesan promosi bank dengan algoritma DNN. *Jurnal Informatika*, 21(1), 23–33.

31. Ramdan, A., Zilvan, V., Suryawati, E., **Pardede, H. F.**, & Rahadi, V. P. (2020). Klasifikasi klon teh berbasis deep CNN dengan residual dan densely connections. *Jurnal Teknologi dan Sistem Komputer*, 8(4), 289–296.
32. Ramdan, A., Zilvan, V., Suryawati, E., **Pardede, H. F.**, & Rahadi, V. P. (2020). Tea clone classification using deep CNN with residual and densely connections. *Jurnal Teknologi dan Sistem Komputer*, 8(4), 289–296.
33. Kusumo, B. S., Heryana, A., Krisnandi, D., Yuwana, S., Zilvan, V., & **Pardede, H. F.** (2020). Deep convolutional neural networks-based plants diseases detection using hybrid features. *Computer Engineering and Applications Journal*, 9(3), 215–225.
34. Yuwana, R. S., Fauziah, F., Heryana, A., Krisnandi, D., Kusumo, R. B. S., & **Pardede, H. F.** (2020). Data augmentation using adversarial networks for tea diseases detection. *Jurnal Elektronika dan Telekomunikasi*, 20(1), 29–35.
35. Ramdan, A., Suryawati, E., Kusumo, R. B. S., **Pardede, H. F.**, Mahendra, O., Dahlan, R., Fauziah, F., & Syahrian, H. (2019). Deep cnnbased detection for tea clone identification. *Jurnal Elektronika dan Telekomunikasi*, 19(2), 45–50.
36. Romadloni, N. T., & **Pardede, H. F.** (2019). Seleksi fitur berbasis Pearson correlation untuk optimasi opinion mining review pelanggan. *Jurnal Resti (Rekayasa Sistem dan Teknologi Informasi)*, 3(3), 505–510.
37. Setiyono, A., & **Pardede, H. F.** (2019). Klasifikasi SMS spam menggunakan support vector machine. *Jurnal Pilar Nusa Mandiri*, 15(2), 275–280.
38. **Pardede, H. F.** (2017). Teknik normalisasi fitur secara adaptif untuk sistem pengenalan ucapan tahan terhadap gema. *Inkom Journal*, 10(2), 47–56.

PROSIDING INTERNASIONAL

39. Yuwana, R. S., Andini, R., **Pardede, H. F.**, Sulandari, W., Suryawati, E., Ihsan, C., & Supianto, A. A. (2022). Evaluation of machine learning models for detecting disambiguation on medical abbreviations. Dalam *The 2022 International Conference on Computer, Control, Informatics and Its Applications* (125–129). ACM.
40. Kusumo, B. S., Oktaviana, S., Sulandari, W., Heryana, A., Yuwana, R. S., Suryawati, E., Yuliani, A. R., & **Pardede, H. F.** (2022). Detection of driver drowsiness based on eye and mouth movements using convolutional neural networks. Dalam *The 2022 International Conference on Computer, Control, Informatics and Its Applications* (135–140). ACM.
41. Heryana, A., Krisnandi, D., **Pardede H. F.**, Nugraha Nurkahfi, G., Dinata, M. M., Rozie, A., & Firmansyah R. (2022). Realtime video latency reduction for autonomous vehicle teleoperation using RTMP over UDP protocols. Dalam *The 2022 International Conference on Computer, Control, Informatics and Its Applications* (44–49). ACM.
42. Cantiabela, Z., **Pardede, H. F.**, Zilvan, V., Sulandari, W., Yuwana, R. S., Supianto, A. A., & Krisnandi, D. (2022). Deep learning for robust speech command recognition using convolutional neural networks (CNN). Dalam *The 2022 International Conference on Computer, Control, Informatics and Its Applications* (101–105). ACM.
43. Hafizhahullah, H., Yuliani, A. R., **Pardede H. F.**, Ramdan, A., Zilvan, V., Krisnandi, D., & Kadar, J. (2022). A hybrid CNN-LSTM for battery remaining useful life prediction with charging profiles data. Dalam *The 2022 International Conference on Computer, Control, Informatics and Its Applications* (106–110). ACM.
44. Supianto, A. A., Nurdiansyah, R., Weng, C. W., Windarwati, H. D., Yuwana, R. S., Arisal, A., Zilvan, V., **Pardede, H. F.**, Huang, C.

- H., Heryana, A., & Krisnandi, D. (2022). DCPC: Drug Candidates for the Prevention of COVID-19 database. Dalam *2022 IEEE 22nd International Conference on Bioinformatics and Bioengineering (BIBE)* (124–127). IEEE.
45. Krisnandi, D., Kusumo, R. B., Yuwana, R. S., Zilvan, V., Heryana, A., Yuliani, A. R., Suryawati, E., & **Pardede, H. F.** Densely Connected networks with smoothed labels regularization for tea diseases detections. Dalam *The 2021 International Conference on Computer, Control, Informatics and Its Applications* (40–44). ACM.
 46. Zilvan, V., Heryana, A., Yuliani, A. R., Krisnandi, D., Yuwana, R. S., & **Pardede, H. F.** (2021). Front-end based robust speech recognition methods: A review. Dalam *The 2021 International Conference on Computer, Control, Informatics and Its Applications* (136–140). ACM.
 47. Yuliani A. R., Ramdan, A., Zilvan, V., Supianto, A. A., Krisnandi, D., Yuwana, R. S., Prajitno, D., & **Pardede H. F.** (2021). Remaining useful life prediction of lithium-ion battery based on LSTM and GRU. Dalam *The 2021 International Conference on Computer, Control, Informatics and Its Applications* (21–25). ACM.
 48. Supianto A. A., Prasetya, O., Anam, S., Tibyani, T., **Pardede, H. F.**, Hayashi, Y., & Hirashima, T. (2021). Cluster analysis of student learning process on digital learning media based on visual intuition using adaptive moving self-organizing maps. Dalam *6th International Conference on Sustainable Information Engineering and Technology* (118–124).
 49. Suwarningsih, W., Heryana, A., **Pardede, H. F.**, Adhi, P., Zilvan, V., Rozie, A. F., Kusumo, R. B., Nugraheni, E., Yuwana, R. S., Riswantini, D., & Suryawati, E. (2020). Qu-Antri: Multi-tenant architecture for Bandung public services to reduce the crowd.

Dalam *2020 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)* (135–140). IEEE.

50. Ramdan, A., Heryana, A., Arisal, A., Kusumo, R. B., & **Pardede, H. F.** (2020). Transfer learning and fine-tuning for deep learning-based tea diseases detection on small datasets. Dalam *2020 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)* (206–211). IEEE.
51. **Pardede H. F.**, Suryawati, E., Krisnandi, D., Yuwana, R. S., Zilvan, V. (2020). Machine learning based plant diseases detection: A review. Dalam *2020 International conference on radar, antenna, microwave, electronics, and telecommunications (ICRAMET)* (212–217). IEEE.
52. Damayanti, R., Prakasa, E., Dewi, L. M., Wardoyo, R., Sugiarto, B., **Pardede, H. F.**, Riyanto, Y., Astutiputri, V. F., Panjaitan, G. R., Hadiwidjaja, M. L., & Maulana, Y. H. (2019). LignoIndo: Image database of Indonesian commercial timber. Dalam *IOP Conference Series: Earth and Environmental Science* (Vol. 374, No. 1, p. 012057). IOP Publishing.
53. Dahlan, R., Krisnandi, D., Ramdan, A., & **Pardede, H. F.** (2019). Unbiased noise estimator for Q-spectral subtraction based speech enhancement. Dalam *2019 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)* (65–68). IEEE.
54. Suryawati, E., Zilvan, V., Yuwana, R. S., Heryana, A., Rohdiana, D., & **Pardede, H. F.** Deep convolutional adversarial network-based feature learning for tea clones identifications. Dalam *2019 3rd International Conference on Informatics and Computational Sciences (ICICoS)* (1–5). IEEE.

55. Zilvan, V., Ramdan, A., Suryawati, E., Kusumo, R. B., Krisnandi, D., & **Pardede, H. F.** (2019). Denoising convolutional variational autoencoders-based feature learning for automatic detection of plant diseases. Dalam *2019 3rd International Conference on Informatics and Computational Sciences (ICICoS)* (1–6). IEEE.
56. Yuwana, R. S., Suryawati, E., Zilvan, V., Ramdan, A., **Pardede, H. F.**, & Fauziah, F. (2019). Multi-condition training on deep convolutional neural networks for robust plant diseases detection. Dalam *2019 international conference on computer, control, informatics and its applications (IC3INA)* (30–35). IEEE.
57. **Pardede, H. F.**, Zilvan, V., Krisnandi, D., Heryana, A., & Kusumo, R. B. (2019) *Generalized filter-bank features for robust speech recognition against reverberation*. Dalam *2019 International Conference on Computer, Control, Informatics and its Applications (IC3INA)* (19–24). IEEE.
58. **Pardede, H. F.**, Suryawati, E., Sustika, R., & Zilvan, V. (2018). Unsupervised convolutional autoencoder-based feature learning for automatic detection of plant diseases. Dalam *2018 international conference on computer, control, informatics and its applications (IC3INA)* (158–162). IEEE.
59. Kusumo, B. S., Heryana, A., Mahendra, O., & **Pardede, H. F.** (2018). Machine learning-based for automatic detection of corn-plant diseases using image processing. Dalam *2018 International conference on computer, control, informatics and its applications (IC3INA)* (93–97). IEEE.
60. Mahendra, O., **Pardede, H. F.**, Sustika, R., & Kusumo, R. B. (2018). Comparison of features for strawberry grading classification with novel dataset. Dalam *2018 International Conference on Computer, Control, Informatics and its Applications (IC3INA)* (7–12). IEEE.

61. Ramdan, A., Sugiarto, B., Rianto, P. D., Prakasa, E., & **Pardede, H. F.** (2018). Support vector machine-based detection of pak choy leaves conditions using RGB and HIS features. Dalam *2018 International Conference on Computer, Control, Informatics and its Applications (IC3INA)* (114–117). IEEE.
62. Yuwana, R. S., Suryawati, E., & **Pardede, H. F.** (2018). On empirical evaluation of deep architectures for Indonesian POS tagging problem. Dalam *2018 International Conference on Computer, Control, Informatics and Its Applications (IC3INA)* (204–208). IEEE.
63. Suryawati, E., Sustika, R., Yuwana, R. S., Subekti, A., & **Pardede, H. F.** (2018). Deep structured convolutional neural network for tomato diseases detection. Dalam *2018 international conference on advanced computer science and information systems (ICACISIS)* (385–390). IEEE.
64. Kurniawati, I., & **Pardede, H. F.** (2018). Hybrid method of information gain and particle swarm optimization for selection of features of SVM-based sentiment analysis. Dalam *2018 International Conference on Information Technology Systems and Innovation (ICITSI)* (1–5). IEEE.
65. Subekti, A., **Pardede H. F.**, & Sustika, R. (2018). Spectrum sensing for cognitive radio using deep autoencoder neural network and SVM. Dalam *2018 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)* (81–85). IEEE.
66. Sustika, R., Yuliani, A. R., Zaenudin, E., & **Pardede, H. F.** (2017). On comparison of deep learning architectures for distant speech recognition. Dalam *2017 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)* (17–21). IEEE.

67. Sugiarto, B., Prakasa, E., Wardoyo, R., Damayanti, R., Dewi, L. M., **Pardede, H. F.**, & Rianto, Y. (2017). Wood identification based on histogram of oriented gradient (HOG) feature and support vector machine (SVM) classifier. Dalam *2017 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)* (337–341). IEEE.
68. Yuwana, R. S., Yuliani, A. R., & **Pardede, H. F.** (2017). On part of speech tagger for Indonesian language. Dalam *2017 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)* (369–372). IEEE.
69. Yuliani, A. R., Sustika, R., Yuwana, R. S., & **Pardede, H. F.** (2017). Feature transformations for robust speech recognition in reverberant conditions. Dalam *2017 International Conference on Computer, Control, Informatics and its Applications (IC3INA)* (57–62). IEEE.
70. Zaenudin, E., Sustika, R., & **Pardede, H. F.** (2017). Using cluster for fixing kernel transpose to improve parallel of strength pareto evolutionary Algorithm 2 (pSPEA2). Dalam *2017 International Conference on Computer, Control, Informatics and its Applications (IC3INA)* (63–68). IEEE.
71. **Pardede, H. F.** (2016). On the impact of normalizing power-based features on robustness against noise for speech recognition. Dalam *2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE)* (1–6). IEEE.
72. Zilvan, V., Ni'mah, I., Yuliani, A. R., & **Pardede, H. F.** (2016). On real time Q-log-based feature normalization for distant speech recognition. Dalam *2016 International Conference on Information Technology Systems and Innovation (ICITSI)* (1–5). IEEE.
73. **Pardede, H. F.** (2015). On noise robust feature for speech recognition based on power function family. Dalam *2015 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)* (386–390). IEEE.

74. Abka, A. F., & **Pardede, H. F.** (2015). Speech recognition features: Comparison studies on robustness against environmental distortions. Dalam *2015 International Conference on Computer, Control, Informatics and its Applications (IC3INA)* (114–119). IEEE.
75. **Pardede, H. F.**, Shinoda, K., & Iwano, K. (2012). Q-Gaussian based spectral subtraction for robust speech recognition. Dalam *Thirteenth Annual Conference of the International Speech Communication Association 2012*.
76. **Pardede H. F.**, & Shinoda, K. (2011). Generalized-log spectral mean normalization for speech recognition. Dalam *Twelfth Annual Conference of the International Speech Communication Association 2011*. ISCA.
77. **Pardede, H. F.**, & Hartanto, D. (2006). Current and voltage analysis of single-electron transistor with sidewall depletion gates using spice model. Dalam *Innovative ASEAN: Creating ASEAN Competitiveness Through Innovation, Sciences, and Technology: the 7th ASEAN Science and Technology Week, Sub Commitee Conference on Microelectronics and Information Technology* (241). LIPI Press.

DAFTAR RIWAYAT HIDUP

A. Data Pribadi

- Nama : Dr. Eng. Hilman Ferdinandus
Pardede, S.T., M.Eng.
- Tempat, Tanggal Lahir : Lubuk Pakam, 25 Juni 1982
- Anak ke : 4 dari 4 Bersaudara
- Jenis Kelamin : Laki-laki
- Nama Ayah Kandung : Kitaman Pardede
- Nama Ibu Kandung : Sinta Siahaan
- Nama Istri : Mariska Margaret Pitoi, S.Si., M.Sc.
- Jumlah Anak : 3
- Nama Anak : 1. Gabe Ezekiel Pardede
2. Posma Eliezer Pardede
3. Hannah Elisha Pardede
- Nama Instansi : Pusat Riset Kecerdasan Artifisial dan
Keamanan Siber, Badan Riset dan
Inovasi Nasional
- Judul Orasi : Penerapan Pembelajaran Mesin (*Machine Learning*) dan Pembelajaran Dalam (*Deep Learning*) Berkinerja Tinggi untuk Mendukung Sektor Pertanian di Indonesia
- Bidang Keahlian : Pengolahan Sinyal Multimedia dan
Kecerdasan Artifisial
- No. SK
Pangkat Terakhir : 20212370/I/KP/2022,
tanggal 30 Maret 2022
- No. SK
Peneliti Ahli Utama : 51/M Tahun 2021, tanggal 9 November

B. Pendidikan Formal

No.	Jenjang	Nama Sekolah/PT/ Universitas	Tempat/Kota/ Negara	Tahun Lulus
1.	SD	SD HKBP Lubuk Pakam	Lubuk Pakam/ Indonesia	1994
2.	SMP	SMP Negeri 1 Kecamatan Lubuk Pakam	Lubuk Pakam/ Indonesia	1997
3.	SMA	SMA Negeri 1 Kecamatan Lubuk Pakam	Lubuk Pakam/ Indonesia	2000
4.	S-1	Universitas Indonesia	Jakarta/ Indonesia	2004
5.	S-2	The University of Western Australia	Perth/Australia	2009
6.	S-3	Tokyo Institute of Technology	Tokyo/Jepang	2013

C. Pendidikan Nonformal

No.	Nama Pelatihan/Pendidikan	Tempat/Kota/ Negara	Tahun
1.	Workshop Teknik Penulisan Ilmiah Populer Hasil Penelitian IPTEK di Media Massa	LIPI/Bandung/ Indonesia	2005
2.	The Course on Data Communication, Internet Technologies, and Multimedia Systems	UN University/ Bandung/Indonesia	2005
3.	The Course on Security: Principles, Techniques and Verification	UN University/ Bandung/Indonesia	2005
4.	The Course on Introduction to Model Checking Techniques and SPIN Model Checker	UN University/ Bandung/Indonesia	2005

Buku ini tidak diperjualbelikan.

No.	Nama Pelatihan/Pendidikan	Tempat/Kota/ Negara	Tahun
5.	Diklat Prajabatan	LIPI/Cibinong/ Indonesia	2005
6.	Diklat Fungsional Peneliti Tingkat Pertama	Pusbindiklat LIPI/Cibinong/ Indonesia	2006
7.	Introductory Academic Skills Program	UWA/Perth/ Australia	2007
8.	Predeparture Training Course for Postgraduate Studies in Australia	IALF/Jakarta/ Indonesia	2007
9.	ProGRANT: Proposal Writing for Research Grants	DAAD/Jakarta/ Indonesia	2016
10.	Diklat Fungsional Peneliti Tingkat Lanjutan	Pusbindiklat LIPI/ Cibinong/ Indonesia	2016
11.	Pelatihan Reviewer dan Tata Cara Penilaian Proposal Penelitian	Kemenristekdikti/ Jakarta/Indonesia	2019

D. Jabatan Fungsional

No.	Jenjang Jabatan	TMT Jabatan
1.	Peneliti Ahli Pertama	1 Agustus 2007
2.	Peneliti Ahli Muda	1 Januari 2014
3.	Peneliti Ahli Madya	1 April 2019
4.	Peneliti Ahli Utama	1 Desember 2021

E. Penugasan Khusus Nasional/Internasional

No.	Jabatan/Pekerjaan	Pemberi Tugas	Tahun
1.	Dosen dengan NIDK	Universitas Nusa Mandiri	2016–Sekarang
2.	Postdoctoral Research Fellow	Fondazione Bruno Kessler	2013–2015

F. Keikutsertaan dalam Kegiatan Ilmiah

No.	Nama Kegiatan	Peran/Tugas	Penyelenggara (Kota/Negara)	Tahun
1.	Interspeech 2011	Pemakalah	ISCA/Florence/Italy	2011
2.	ISPACS 2015	Pemakalah	ITB/Bali/Indonesia	2015
3.	ICITEE 2016	Pemakalah	UGM/Yogyakarta/Indonesia	2016
4.	IC3INA 2016	Ketua Pelaksana	Serpong/Banten/Indonesia	2016
5.	Expert Sharing Machine Learning dan AI	Pembicara	Telkom/Bandung/Indonesia	2018
6.	Seminar Ilmiah Metrologi, Klimatologi, dan Geofisika	Pembicara	BMKG/Jakarta/Indonesia	2018
7.	Pelatihan Penulisan Publikasi Ilmiah	Narasumber	Universitas Tanri Abeng/Jakarta/Indonesia	2019

No.	Nama Kegiatan	Peran/ Tugas	Penyelenggara (Kota/Negara)	Tahun
8.	ASEAN IVO Forum 2019	Pembicara	NICT/Manila/ Pilipina	2019
9.	ICICoS 2019	Pemakalah	UNDIP/Semarang/ Indonesia	2019
10.	IC3INA 2019	Pemakalah	LIPI/Serpong/ Indonesia	2019
11.	IC3INA 2018	Pemakalah	LIPI/Serpong/ Indonesia	2019
12.	ICRAMET 2020	Pemakalah	LIPI	2020
13.	IC3INA 2021	Pemakalah	BRIN	2021
13.	IC3INA 2022	Pemakalah Kunci	BRIN	2022
14.	NISS 2022	Pemakalah	BRIN-Abdelmalek Essadi University/ Virtual	2022

G. Keterlibatan dalam Pengelolaan Jurnal Ilmiah

No.	Nama Jurnal	Penerbit	Peran/ Tugas	Tahun
1.	Speech Communications	Elsevier	<i>Reviewer</i>	2013–2016
2.	International Journal of Machine Learning and Cybernetics	Springer	<i>Reviewer</i>	2016–2019
3.	IEEE Access	IEEE	<i>Reviewer</i>	2019–2023
4.	IET Signal Processing	IET	<i>Reviewer</i>	2019–2023
5.	Scientific Reports	Springer	<i>Reviewer</i>	2020

Buku ini tidak diperjualbelikan.

No.	Nama Jurnal	Penerbit	Peran/ Tugas	Tahun
6.	Computer and Electrical Engineering	Elsevier	<i>Reviewer</i>	2020–2022
7.	Computers and Electronics in Agriculture	Elsevier	<i>Reviewer</i>	2020–2022
8.	Journal of King Saud University-Computer and Information Sciences	Elsevier	<i>Reviewer</i>	2020–2023
4.	Biomedical Signal Processing and Control	Elsevier	<i>Reviewer</i>	2021–2022
9.	Pattern Recognition	Elsevier	<i>Reviewer</i>	2021–2023
10	Jurnal Elektronika dan Telekomunikasi	BRIN	<i>Section editor</i>	2022–2023
11	Applied Sciences	MDPI	<i>Reviewer</i>	2022–2023

H. Karya Tulis Ilmiah

No.	Kualifikasi Penulis	Jumlah
1.	Penulis Tunggal	4
2.	Bersama Penulis Lainnya	73
	Total	77

No.	Kualifikasi Bahasa	Jumlah
1.	Bahasa Indonesia	12
2.	Bahasa Inggris	65
3.	Bahasa Lainnya	-
	Total	77

Buku ini tidak diperjualbelikan.

I. Pembinaan Kader Ilmiah

Pejabat Fungsional Peneliti

No.	Nama	Instansi	Peran/Tugas	Tahun
1.	Vicky Zilvan	BRIN	Pembimbing	2020–2022
2.	Endang Suryawati	BRIN	Pembimbing	2020–2021
3.	Devi Munandar	BRIN	Pembimbing pendamping	2022

Mahasiswa

No.	Nama	PT/Universitas	Peran/Tugas	Tahun
1.	Maman Firmansyah	STMIK Nusa Mandiri	Pembimbing S-2	2022
2.	Ricko Anugrah Mulya Pratama	STMIK Nusa Mandiri	Pembimbing S-2	2022
3.	Dwi Krisnandis	STMIK Nusa Mandiri	Pembimbing S-2	2022
4.	Aldi Jakaria	STMIK Nusa Mandiri	Pembimbing S-2	2022
5.	Tetra Widiyanto	STMIK Nusa Mandiri	Pembimbing S-2	2022
6.	Delvina Tri Agustin	STMIK Nusa Mandiri	Pembimbing S-2	2022
7.	Amsal Pardamean	STMIK Nusa Mandiri	Pembimbing S-2	2021
8.	Rian Ardianto	STMIK Nusa Mandiri	Pembimbing S-2	2021
9.	Noor Hafidz	STMIK Nusa Mandiri	Pembimbing S-2	2021
10.	Oscar	STMIK Nusa Mandiri	Pembimbing S-2	2021

Buku ini tidak diperjualbelikan.

No.	Nama	PT/Universitas	Peran/Tugas	Tahun
11.	Hiya Nalatissifa	STMIK Nusa Mandiri	Pembimbing S-2	2021
12.	Mawadatul Maulidah	STMIK Nusa Mandiri	Pembimbing S-2	2021
13.	Sabar Sautomo	STMIK Nusa Mandiri	Pembimbing S-2	2020
14.	Muhamad Azhar	STMIK Nusa Mandiri	Pembimbing S-2	2020
15.	Ahmad Rifqy Alfyan	STMIK Nusa Mandiri	Pembimbing S-2	2020
16.	Dodi Suprayogi	STMIK Nusa Mandiri	Pembimbing S-2	2020
17.	Muhammad Ja'far Shidiq	STMIK Nusa Mandiri	Pembimbing S-2	2020
18.	Rasenda	STMIK Nusa Mandiri	Pembimbing S-2	2020
19.	Basri	STMIK Nusa Mandiri	Pembimbing S-2	2020
20.	Fitra Septia Nugraha	STMIK Nusa Mandiri	Pembimbing S-2	2020
21.	Ahmad Fauzi	STMIK Nusa Mandiri	Pembimbing S-2	2019
22.	Nova Tri Romadloni	STMIK Nusa Mandiri	Pembimbing S-2	2019
23.	Ahmad Fauzi	STMIK Nusa Mandiri	Pembimbing S-2	2019
24.	Ilham Kumiawan	STMIK Nusa Mandiri	Pembimbing S-2	2019
25.	Salman Topiq	STMIK Nusa Mandiri	Pembimbing S-2	2018

Buku ini tidak diperjualbelikan.

No.	Nama	PT/Universitas	Peran/Tugas	Tahun
26.	Sari Susanti	STMIK Nusa Mandiri	Pembimbing S-2	2018
27.	Ika Kurniawati	STMIK Nusa Mandiri	Pembimbing S-2	2017
28.	Tri Agus Setiawan	STMIK Nusa Mandiri	Pembimbing S-2	2017
29.	Muhammad Baydhowi	STMIK Nusa Mandiri	Pembimbing S-2	2017

J. Organisasi Profesi Ilmiah

No.	Jabatan	Nama Organisasi	Tahun
1.	Anggota	INAPR	2022–2023
2.	Anggota	PPI	2021–2023
3.	Anggota	IEEE	2009–2015, 2023

K. Tanda Penghargaan

No.	Nama Penghargaan	Pemberi Penghargaan	Tahun
1.	Satyalancana Karya Satya 10 Tahun	Presiden RI	2015

PENERAPAN PEMBELAJARAN MESIN (*MACHINE LEARNING*) DAN PEMBELAJARAN DALAM (*DEEP LEARNING*) BERKINERJA TINGGI UNTUK Mendukung Sektor Pertanian di Indonesia

Sektor pertanian adalah salah satu sektor strategis di Indonesia dan penerapan teknologi pembelajaran mesin dan pembelajaran dalam pada sektor ini dapat menjadi salah satu solusi mencapai ketahanan pangan. Akan tetapi, potensi tersebut belum digali secara optimal akibat kurangnya data dan kondisi geografis Indonesia. Pada naskah orasi ini dijabarkan beberapa penerapan teknologi pembelajaran mesin dan pembelajaran dalam pada sektor untuk mengatasi beberapa kendala tersebut. Pertama, beberapa dataset produk pertanian Indonesia yang dapat digunakan sebagai data latih sistem pembelajaran mesin dan pembelajaran dalam untuk sistem identifikasi penyakit tanaman dan pengenalan kualitas pangan telah dihasilkan. Kedua, teknologi berbasis pembelajaran mesin dan pembelajaran dalam yang ringkas sehingga dapat diterapkan secara luring untuk menjangkau daerah geografis yang belum terjangkau fasilitas internet telah diperkenalkan. Ketiga, solusi model pembelajaran dalam yang tahan terhadap berbagai variasi dan kondisi data telah diusulkan.

Tidak dapat dimungkiri, tren penerapan kecerdasan artifisial, khususnya pembelajaran mesin dan pembelajaran dalam pada bidang pertanian akan makin populer di masa depan. Oleh karena itu, penguasaan teknologi pembelajaran mesin dan pembelajaran dalam akan makin penting di masa akan datang. Kolaborasi periset dan pegiat di bidang kecerdasan artifisial dengan pemangku kepentingan di bidang sektor pertanian seperti pemerintah, industri, dan petani itu sendiri harus terus dibangun.



BRIN
BADAN PENELITIAN
DAN INOVASI NASIONAL

Diterbitkan oleh:

Penerbit BRIN, Anggota Ikapi
Direktorat Repositori, Multimedia, dan Penerbitan Ilmiah
Gedung B. J. Habibie Lt. 8, Jl. M.H. Thamrin No. 8,
Kb. Sirih, Kec. Menteng, Kota Jakarta Pusat,
Daerah Khusus Ibukota Jakarta 10340
Whatsapp: +62 811-1064-6770
E-mail: penerbit@brin.go.id
Website: penerbit.brin.go.id

DOI: 10.55981/brin.872



ISBN 978-623-8372-06-5

