

PEMANFAATAN MODEL NEURAL NETWORK DALAM GENERASI BARU PERTANIAN PRESISI DI PERKEBUNAN KELAPA SAWIT

Muhdan Syarovy¹, Andri Prima Nugroho¹, dan Lilik Sutiarto¹

Abstrak - Era revolusi industri 4.0 dengan penggunaan *Internet of Thing*, *big data*, dan *Artificial Intelligence* mendorong pertanian presisi ke tingkat yang lebih lanjut (*next generation precision farming*). Teknologi yang dapat mengklasifikasi (*clasification*), mengelompokkan (*clustering*), mengestimasi (*estimation*), dan memprediksi (*forecating*) merupakan salah satu fokus dalam penerapan pertanian presisi. Teknologi pintar tersebut dapat dikembangkan dengan memanfaatkan model matematika yang dikenal dengan model *Neural Network* (NN). Model ini menggunakan algoritma pembelajaran yang terinspirasi oleh cara otak manusia untuk menyimpan informasi. Saat ini, istilah *Machine Learning* dan *Deep Learning* sering digunakan dalam pemodelan menggunakan NN. Penelitian terkait pemanfaatan model NN di perkebunan kelapa sawit telah dilakukan namun masih terdapat banyak ruang yang dapat di eksplorasi dalam penggunaan model ini. Terlebih lagi, saat ini banyak perkebunan yang sudah melakukan proses digitalisasi pada seluruh aktivitasnya. Pemanfaatan model NN diharapkan dapat membantu pengembangan mesin pengambilan keputusan cerdas dalam budidaya kelapa sawit untuk mendukung generasi baru pertanian presisi.

Kata kunci: *Artificial intelligence*, *deep learning*, generasi baru pertanian presisi, kelapa sawit, *machine learning*, *neural network*

PENDAHULUAN

Kelapa sawit merupakan salah satu komoditas perkebunan terbesar di Indonesia. Tanaman ini tumbuh pada berbagai kondisi iklim dan tanah di Indonesia. Pulau Sumatera dan Kalimantan memiliki jumlah sentra perkebunan terbesar di Indonesia (Direktorat Jenderal Perkebunan, 2020). Kelapa sawit juga merupakan tanaman penghasil minyak nabati terbesar di dunia, melampaui kedelai, *rapseed*, dan bunga matahari (Purba, 2019). Produksi minyak sawit pada luas yang sama dapat mencapai sembilan kali lipat lebih tinggi dari kedelai, *rapeseed*, dan bunga matahari sehingga harga jualnya menjadi jauh lebih murah (Suwarno, 2019).

Penulis yang tidak disertai dengan catatan kaki instansi adalah peneliti pada Pusat Penelitian Kelapa Sawit

Muhdan Syarovy* (✉)
Pusat Penelitian Kelapa Sawit
Jl. Brigjen Katamso No. 51 Medan 20158, Indonesia

Email: muhdansyarovy@iopri.co.id

¹ Smart Agriculture Research, Department of Agricultural and Biosystems Engineering, Faculty of Agricultural Technology, Universitas Gadjah Mada. Jln. Flora No.1 Bulaksumur, Yogyakarta 55281

Diperkirakan konsumsi minyak nabati dunia pada tahun 2050 akan terus meningkat menjadi 180 juta ton. Kebutuhan minyak nabati tersebut terutama berasal dari kelapa sawit (Purba, 2019). Indonesia sebagai produsen minyak sawit terbesar dunia juga harus meningkatkan produksi. Saat ini, upaya mayoritas peningkatan produksi kelapa sawit di Indonesia adalah dengan perluasan lahan atau ekstensifikasi. Hal ini terlihat dari data luas areal kelapa sawit yang meningkat cukup pesat dari tahun 2011 hingga 2019, yaitu dari 9,1 juta menjadi 14,7 juta ha atau meningkat 62% (Badan Pusat Statistik 2019). Saat ini, peningkatan produksi melalui ekspansi menjadi semakin sulit karena peraturan pemerintah, seperti moratorium ekspansi kelapa sawit, peraturan sertifikasi minyak sawit yang semakin ketat, dan kendala lainnya.

GENERASI TERBARU PERTANIAN PRESISI

Pertanian presisi secara luas didefinisikan sebagai sistem manajemen pertanian berbasis informasi dan teknologi dalam mengidentifikasi, menganalisis, dan mengelola lahan berdasarkan variabel spasial dan temporal untuk produktivitas dan profitabilitas yang optimal dengan meminimalkan biaya produksi dan

keberlanjutan (Hakkim, Joseph, Gokul, & Mufeedha, 2016). Pertanian presisi menggunakan pendekatan yang menggunakan jumlah *input* yang tepat untuk memperoleh hasil yang lebih tinggi dibandingkan dengan teknik pertanian konvensional. Terdapat beberapa area fokus dalam penerapan pertanian presisi, antara lain: 1) Penerapan teknologi deteksi, pemantauan, analisis, dan prediksi untuk mencatat informasi spesifik spasial dan temporal; 2) Penggunaan dan integrasi berbagai teknologi berorientasi aplikasi; 3) Mengurangi dampak negatif lingkungan dengan memaksimalkan sumber daya yang tersedia (Nanda, 2022). Beberapa contoh aplikasi pertanian presisi adalah pemantauan iklim dengan pemantauan irigasi cerdas untuk meningkatkan efisiensi air, pemantauan kondisi tanah, prakiraan produksi tanaman, dan peramalan pembiayaan (Bwambale, Abagale, & Anornu, 2022; Math & Dharwadkar, 2018; Pooja, Uday, Nagesh, & Talekar, 2017; Rajković et al., 2022; Singh, Sobti, Jain, Malik, & Le, 2022; Wijaya & Susandi, 2018). Aplikasi pertanian presisi di perkebunan kelapa sawit memanfaatkan teknologi global positioning system (GPS), sistem informasi geografi (SIG), teknologi penginderaan jauh, dan aplikasi variable rate, termasuk teknologi sensor dan mesin pertanian (Ginting & Wiratmoko, 2021).

Revolusi Industri 4.0 dengan *Internet of Things* (IoT) dan kecerdasan buatan (*Artificial Intelligence/AI*) membawa pertanian presisi ke tingkat berikutnya (generasi baru). Pertanian presisi pertama kali diperkenalkan pada akhir 1980-an melalui integrasi mekanisasi, GPS, SIG dan teknologi penginderaan jauh. Selama tiga dekade terakhir, teknik pertanian presisi telah berkembang menjadi strategi untuk pengambilan keputusan spesifik lokasi, terutama berdasarkan citra satelit. Pada 2010-an, dengan perkembangan internet dan teknologi seluler (*smartphone*), pertanian presisi mulai menawarkan layanan melalui berbagai aplikasi web dan *smartphone* dengan mengintegrasikan berbagai sensor nirkabel. Saat ini, teknologi seperti kendaraan udara tak berawak (*unmanned aerial vehicles/UAV*), *big data*, AI, dan otomatisasi sedang dikembangkan untuk mengatasi permasalahan sosial, manufaktur, dan pertanian. Dalam dekade berikutnya, generasi baru pertanian presisi akan ditandai dengan komputasi awan (cloud) performa tinggi, analitik *big data*, AI tingkat lanjut, otomatisasi dan kontrol secara *real time* (Serraj & Pingali, 2019).

BIG DATA DAN ARTIFICIAL INTELLIGENCE

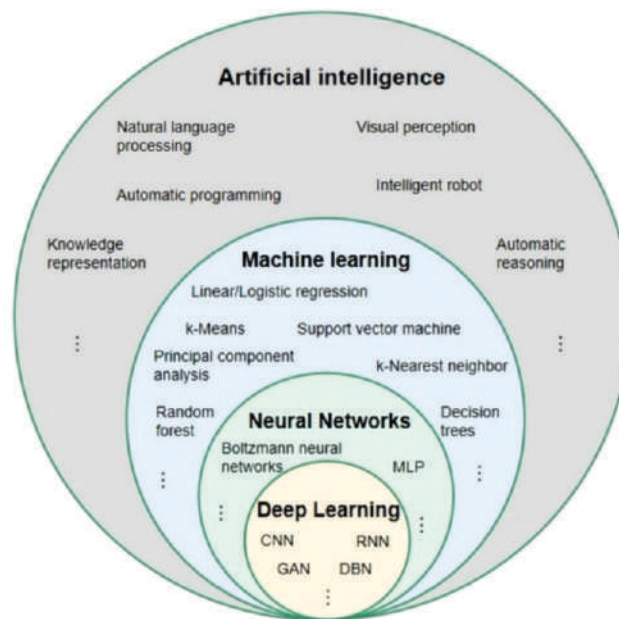
Perkembangan teknologi internet dan telepon seluler selama beberapa dekade terakhir telah menghasilkan sejumlah besar data. Setiap hari data yang dibuat hingga disimpan sebesar 2,5 *terabyte* (Zicari, 2013). Dari tahun 2010 – 2020, data-data yang dihasilkan dari internet mencapai 62,2 *zettabyte* (Statista, 2022). Saat ini, data berperan sebagai “minyak baru” karena potensinya sebagai aset yang bernilai dan memiliki banyak manfaat bagi bisnis dan industri. Data dapat digunakan untuk memahami pasar, membuat keputusan yang lebih baik, dan meningkatkan efisiensi operasional. Beberapa industri, seperti industri teknologi informasi dan media, bahkan bergantung pada data sebagai sumber utama pendapatan mereka. Beberapa perusahaan teknologi seperti Apple, Google, dan Microsoft memiliki nilai perusahaan yang lebih tinggi daripada raksasa minyak seperti PetroChina, Exxon, dan General Electric Marcin, 2021.

Manajemen *big data* dihadapkan dengan beberapa tantangan, antara lain: 1) Volume data, pertumbuhan pesat jumlah data yang dihasilkan; 2) Keragaman dan integrasi ke dalam kumpulan data, karena 80% informasi yang dikumpulkan dalam *big data* masih belum terstruktur; 3) *Velocity*, mengubah data menjadi untuk informasi yang dibutuhkan dengan cepat; 4) Kebenaran, kualitas data dan ketersediaan data. Kualitas data yang buruk menyebabkan keputusan yang buruk; 5) Penemuan data, cara menemukan data berkualitas tinggi dari kumpulan data besar di Internet; 6) Skalabilitas, seberapa besar kumpulan data dapat memecahkan masalah skala besar (Gil & Song, 2016; Zicari, 2013). Beberapa aplikasi dari *big data* di bidang pertanian antara lain prakiraan iklim, rekomendasi waktu tanam, rekomendasi kondisi tanah, rekomendasi benih dan pupuk, prakiraan produksi, dan *e-commerce* di bidang pertanian (Bendre, Thool, & Thool, 2015; Pushparani, Sagaya, & Ravan, 2018; Wijayanto, Purnamasari, Ristiana, Saputra, & Regar, 2022).

Sebagian besar model bisnis perkebunan di Indonesia masih menerapkan metode tradisional termasuk dalam hal pengumpulan data. Namun, sekarang banyak perkebunan di Indonesia mulai melakukan digitalisasi dengan menerapkan IoT ke model bisnis perkebunannya, sehingga nantinya data yang dikumpulkan tersimpan secara terpusat dan

menjadi kumpulan *big data*. Banyak hal yang dapat dilakukan dengan *big data*, salah satunya adalah untuk menganalisis dan membuat model prediktif agar menghasilkan keputusan yang tepat untuk usaha perkebunan. Pemanfaatan model berbasis AI untuk menganalisis dan membuat model prediktif kumpulan data yang besar menjadi hal yang menarik belakangan ini. Terlebih lagi, model tersebut dapat diintegrasikan pada berbagai produk digital untuk menghasilkan sistem keputusan cerdas. AI mengacu

pada membuat mesin secerdas otak manusia (Shinde & Shah, 2018). AI memiliki beberapa sub kelompok, beberapa di antaranya adalah *machine learning* (ML) dan *deep learning* (DL). *Neural Network* (NN) merupakan model yang sangat penting untuk pengembangan model ML maupun DL sehingga peneliti selanjutnya menempatkan NN dalam sub kelompok terpisah. Pembagian masing-masing sub kelompok AI dapat dilihat pada Gambar 1.



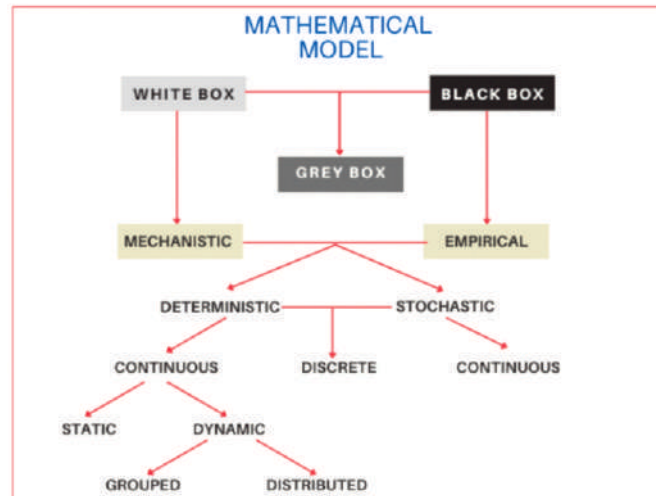
Gambar 1. Hubungan *Artificial intelligence*, *machine learning*, *neural network* dan *deep learning* (S. Li, Deng, Zhu, Hua, & Tao, 2021).

MODEL NEURAL NETWORK

Pemodelan Matematika dan Neural Network

Pemodelan matematika dapat diklasifikasikan ke dalam model empiris, mekanistik dan gabungannya. Model empiris atau juga biasa disebut model *black box*, merupakan suatu sistem yang dibangun menggunakan persamaan matematika atau statistik tanpa mempertimbangkan batasan dan prinsip-prinsip ilmiah. Model ini biasanya dibangun berdasarkan data eksperimen dan tidak menjelaskan proses mekanisme yang terjadi. Pada saat ini, banyak peneliti menggunakan model empiris untuk memprediksi parameter dengan menggunakan algoritma cerdas seperti *Support Vector Machines* (SVM), *Back-*

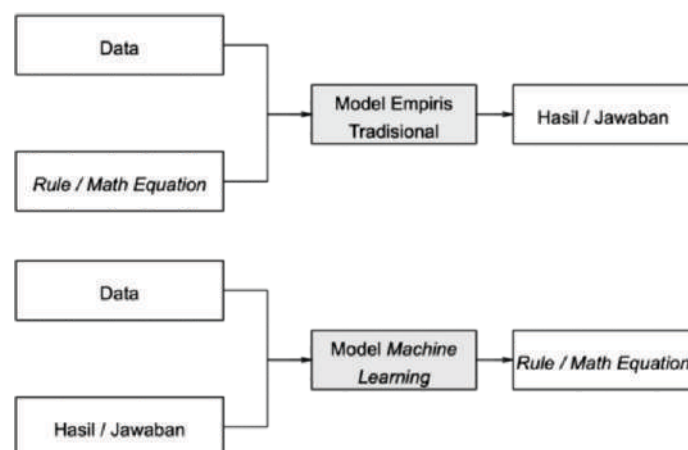
Propagation Neural Network (BPNN), *Artificial Neural Network* (ANN), *Deep Neural Network* (DNN). Namun, model-model berbasis NN juga diklasifikasikan sebagai kombinasi antara model empiris dan mekanistik karena dibutuhkan pemahaman proses fenomena yang terjadi terutama dalam praproses data (Harahap & Lubis, 2018; Syarovy et al., 2022). Sementara itu, model mekanistik atau di sebut juga model *white box* dikembangkan berdasarkan proses mekanis dari suatu fenomena yang terjadi. Pemodelan mekanistik lebih kompleks dan sangat sulit diaplikasikan daripada model-model empiris. Model-model yang mengombinasikan antara model empiris dan mekanistik disebut model *grey box* (García-Rodríguez et al., 2022).



Gambar 2. Klasifikasi model matematika (García-Rodríguez et al., 2022)

Model-model berbasis empiris memiliki akurasi yang rendah jika dibandingkan model mekanistik (Harahap & Lubis, 2018). Namun, saat ini model-model empiris berdasarkan algoritma cerdas ML telah dikembangkan agar memiliki akurasi yang lebih baik. Perbedaan model empiris tradisional dan model berbasis ML adalah model empiris tradisional menggunakan data dan *equation* untuk menghasilkan jawaban atau hasil. Keakuratan prediksi model empiris sangat tergantung pada

pemilihan *equation* yang sesuai dengan pola data. Jika *equation* yang dipilih tidak sesuai dengan pola data, maka prediksi yang dihasilkan akan tidak akurat. Sementara itu, model berbasis *machine learning* menggunakan data dan hasil untuk memperoleh *equation* (Gambar 3). Model ini dapat lebih dinamis terhadap perubahan data-data baru sehingga model dapat belajar melalui error yang terjadi untuk memperoleh hasil prediksi yang lebih akurat (Russell & Norvig, 2021).




Gambar 3. Perbedaan antara model empiris tradisional dengan model *machine learning*

NN adalah teknik pembelajaran mesin yang populer untuk mensimulasikan mekanisme pembelajaran saraf biologis. Sistem saraf manusia

mengandung sel-sel yang disebut neuron. Neuron terhubung satu sama lain oleh akson dan dendrit, koneksi antara area akson dan dendrit disebut

sinapsis. Kekuatan koneksi sinaptik sering berubah sebagai respons terhadap rangsangan eksternal. Perubahan ini merupakan suatu proses pembelajaran berlangsung pada organisme hidup (Gambar 4). NN dapat membaca berbagai jenis pola baik linier maupun non-linier. NN dapat diterapkan

untuk memecahkan berbagai jenis masalah seperti pengklasifikasian, regresi, dan klasifikasi biner. Kelebihan NN dalam memproses pola non-linier menjadikannya pilihan yang baik untuk masalah yang memiliki relasi kompleks antar fitur atau variabel.



Gambar 4. Hubungan sinaptik antar neuron biologi (kiri) dan *artificial* (kanan) (Aggarwal, 2018)

Sejarah dan Perkembangan Model Neural Network


Neural network pertama kali diperkenalkan oleh The McCulloch-Pitts pada tahun 1943. Riset tersebut merupakan pemodelan sederhana tentang cara kerja neuron pada rangkaian listrik sederhana. Pada tahun 1949, Donald Hebb menggunakan dua neuron untuk mengukur proses kompleks di otak. Hal ini merupakan dasar yang diperlukan untuk menerapkan fungsi pembelajaran dan memori. Pada tahun 1957, Frank Rosenblatt menggunakan teori yang dikembangkan sebelumnya untuk membangun fungsi perceptron, yang kemudian dikenal sebagai pembelajaran perceptron. Kemudian, pada tahun 1962, Rosenblatt membuktikan teori konvergensi perceptron. Tiga tahun kemudian, Bernard Widrow memperkenalkan aturan pembelajaran Delta menggunakan pelatihan perceptron (juga dikenal sebagai *The Least Square problem*) yaitu sebuah pengklasifikasian linier yang memungkinkan nilai pada bobot menyesuaikan nilai aktual. Pada tahun 1969 Marvin Minsky mempelajari masalah XOR. Studi tersebut menunjukkan bahwa perceptron tidak dapat dipisahkan secara linier dalam distribusi data. Pada tahun 1970, Seppo Linnainmaa mengusulkan "modus kebalikan dari diferensiasi otomatis", juga dikenal sebagai algoritma *backpropagation* (BP). Paul Werbos kemudian menyempurnakan NNBP dengan penambahan *multi-layer perceptrons* (MLP) pada tahun 1981. Pada tahun 1985, peneliti Rumelhart, Hinton, Williams-Hetch, dan

Nielsen berhasil mempresentasikan konsep MLP menggunakan pelatihan BP. Kemudian, pada awal 1980-an, John Hopfield memperkenalkan Hopfield *Network* (model Hopfield) yang merupakan jaringan NN dua *layer* yang terhubung penuh. Pencapaian terbesar dalam NN terjadi pada tahun 1995 ketika Vapnik dan Cortes melakukan studi terkait *Support Vector Machines* (SVM). Penelitian tersebut membagi ML ke dalam dua kelompok yaitu NN dan SVM. Pada tahun 1997, Freund dan Schapire mengembangkan ansambel pengklasifikasi yang lebih baik yang dikenal sebagai AdaBoost. AdaBoost kemudian diselidiki oleh Breiman pada tahun 2001 dan menggabungkan beberapa pohon keputusan, masing-masing dibangun dari subset acak dari *instance* dan setiap node dipilih dari subset fitur acak atau yang disebut *Random Forest* (RF). Seiring dengan semakin canggihnya perkembangan komputer, penelitian NN terus dilakukan dengan mengekstrak fitur dan penggunaan jumlah lapisan tersembunyi yang lebih banyak. Kemudian para ahli memisahkan subset ini dari ML menjadi pembelajaran yang mendalam atau *Deep learning* (DL). Algoritma DL yang umum digunakan termasuk *Deep Neural Network* (DNN), *Convolutional Neural Networks* (CNN), *Recurrent Neural Networks* (RNN), *Generative Adversarial Networks* (GAN), dan *Deep Belief Networks* (DBN) (Alom et al., 2018; Goodfellow, Bengio, & Courville, 2016; Schmidhuber, 2015; Shinde & Shah, 2018).

Matematika dalam Arsitektur MLPBP

Arsitektur *multi layer perceptrons backpropagation* (MLPBP) merupakan arsitektur yang umum digunakan

dalam penelitian NN (Gambar 5). Arsitektur ini juga menjadi dasar dalam pengembangan algoritma DL. Terdapat beberapa tahapan dalam arsitektur *multi layer perceptrons backpropagation*, yaitu:



Gambar 5. Arsitektur neural network backpropagation (Fausett, 1994)

1. Tahap inisiasi

Pada tahap awal, inisiasi dilakukan menggunakan bobot nilai acak yang berukuran kecil. Selama proses ini, tahapan perambatan maju, perambatan mundur, dan pembaruan bobot dan nilai dilakukan secara berulang.

2. Tahap perambatan maju (*feedforward*)

Setiap unit masukan menerima sinyal dari masukan (x_i) dan mengirimnya ke semua unit di lapisan (unit tersembunyi). Setiap unit tersembunyi menambahkan sinyal masukan yang diberi bobot sesuai Persamaan 1. Ada beberapa fungsi aktivasi yang akan digunakan, tergantung dari jenis keluaran yang dihasilkan. Sinyal keluaran dapat dihitung menurut persamaan 2. Sinyal ini dikirim ke semua unit di atasnya (unit keluaran).

$$Z_{inj} = v_o + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

$$Z_{inj} = f(Z_{inj}) \quad (2)$$

Z_{inj} = nilai masukan pada neuron tersembunyi ke-j

v_o = bias pada sinapsis yang menghubungkan neuron bias dan neuron tersembunyi ke-j

ij = indeks neuron masukan dan indeks neuron masukan tersembunyi

n = Jumlah neuron masukan

x_i = nilai neuron masukan ke - i

Setiap unit keluaran menjumlahkan sinyal masukan berbobot menurut Persamaan 3, menerapkan fungsi aktivasi, dan menghitung sinyal keluaran menurut Persamaan 4.

$$y_{ink} = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (3)$$

$$y_k = f(y_{ink}) \quad (4)$$

Keterangan:

- Y_{ink} = nilai masukan pada neuron *hidden* ke -
 W_{ok} = bias pada sinapsis yang menghubungkan neuron bias dan neuron tersembunyi ke - k
 W_{jk} = bobot pada sinapsis yang menghubungkan antara neuron tersembunyi ke - j dan neuron keluaran ke - k
 Y_k = nilai keluaran neuron pada neuron ke - k
 $f(Y_{ink})$ = nilai neuron masukan ke - l

3. Tahap perambatan balik (*backpropagation*)

Setiap unit keluaran menerima pola target yang terkait dengan pola pelatihan data masukan, menghitung informasi galat menurut Persamaan 5, menghitung koreksi bobot menurut Persamaan 6, menghitung koreksi bias menurut Persamaan 7, dan mengirim galat (δ_k) ke unit pada lapisan di bawahnya.

$$\delta_k = (t_k - y_k)(1 - y_k) \quad (5)$$

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (6)$$

Keterangan:

- δ_k = nilai galat pada neuron keluaran ke - k
 t_k = nilai target pada neuron keluaran ke - k
 Δw_{jk} = nilai perubahan bobot pada sinapsis yang menghubungkan neuron tersembunyi ke - j dan neuron keluaran ke - k
 α = laju pembelajaran (*Learning rate*)
 Δw_{ok} = nilai perubahan bias pada sinapsis yang menghubungkan neuron bias dan neuron keluaran ke - k

Setiap unit tersembunyi menjumlahkan galat berbobot menurut Persamaan 8, menghitung galat informasi pada neuron tersembunyi menurut Persamaan 9, menghitung koreksi bobot menurut Persamaan 10, dan menghitung koreksi bias menurut Persamaan 11.

$$\delta_{inj} = \sum_{k=1}^m \delta_k w_{jk} \quad (8)$$

$$\delta_{inj} = \delta_{inj} z_j (1 - z_j) \quad (9)$$

$$\Delta v_{inj} = \alpha \delta_{inj} x_i \quad (10)$$

$$\Delta v_{oj} = \alpha \delta_j \quad (11)$$

Keterangan :

- δ_{inj} = nilai galat masukan pada neuron tersembunyi ke - j
 m = Jumlah neuron keluaran
 δ_j = nilai galat pada neuron tersembunyi ke - j
 Δv_{inj} = nilai perubahan bobot pada sinapsis yang menghubungkan neuron masukan ke - i dan neuron tersembunyi ke - j
 Δv_{oj} = nilai perubahan bias pada sinapsis yang menghubungkan neuron bias dan neuron tersembunyi ke - j

4. Pembaruan bobot dan bias

Setiap unit keluaran dan tersembunyi melakukan pembaruan bias dan bobot unit keluaran ($w_{jk}(new)$) maupun tersembunyi ($w_{jk}(new)$) sesuai Persamaan 12 dan 13.

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk} \quad (12)$$

$$v_{ij}(new) = v_{ij}(old) + \Delta v_{ij} \quad (13)$$

5. Fungsi aktivasi

Menentukan fungsi aktivasi ($\Phi(\cdot)$) merupakan bagian yang sangat penting dari NN. Fungsi aktivasi paling dasar untuk NN adalah aktivasi *identity* atau linier. Fungsi aktivasi *identity* dapat dilihat pada persamaan 14. Fungsi aktivasi lainnya yang umum digunakan adalah Sigmoid, dan *Rectified Linear Unit* (ReLU), Persamaan fungsi aktivasi tersebut masing-masing dapat dilihat pada persamaan 15, 16, 17 dan Gambar 6.

$$\Phi(x) = x \quad (14)$$


$$\Phi(x) = \frac{1}{1 + e^{-x}} \quad (15)$$

$$\Phi(x) = \max\{x, 0\} \quad (16)$$

$$\Phi(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (17)$$

Keterangan :

e = bilangan natural



Gambar 6. Grafik fungsi aktivasi linier, *Rectified Linear Unit* (ReLU), dan Sigmoid

Python untuk Pemodelan Neural Network

Saat ini, arsitektur yang digunakan dalam pemodelan NN sangat kompleks sehingga memerlukan peralatan komputasi yang sangat khusus untuk melakukan proses iterasi dan pelatihan dengan cepat. Perangkat lunak untuk pemrosesan dan komputasi numerik umum, seperti Ms. Excel, dapat digunakan untuk penghitungan NN sederhana, namun tidak untuk digunakan untuk data yang besar dan perhitungan yang kompleks (Thin-Yin & Jonathan, 2020). Perangkat lunak lain seperti MATLAB juga biasa digunakan untuk NN seperti dalam penelitian (Harahap & Lubis, 2018; Hermantoro & Rudyanto, 2018), tetapi MATLAB bukan perangkat lunak *open source*. Beberapa permasalahan apabila program bukan *open source* antara lain kurangnya transparansi terhadap kode yang digunakan, pengguna bergantung kepada vendor untuk perbaikan masalah dan penyediaan dukungan, terdapat biaya yang dibutuhkan untuk pembelian lisensi, dan terbatas dalam kostumisasi kode sesuai kebutuhan pengguna (Ozgur, Colliau, Rogers, Hughes, & Bennie, 2017). Selain itu, kecepatan dalam pengolahan data pada MATLAB sangat bergantung pada spesifikasi komputer. Bahasa pemrograman R juga banyak

digunakan untuk pemodelan NN (Watson-Hernández, Gómez-Calderón, & da Silva, 2022). Namun bahasa pemrograman R memiliki fungsi utama sebagai analisis dan pemodelan statistik, sedangkan model ML memerlukan operasi yang lebih kompleks terlebih lagi jika model tersebut akan digunakan untuk produk digital (Odhiambo, 2020). Bahasa pemrograman lain yang direkomendasikan untuk AI modern adalah Python. Python dapat dengan mudah dikombinasikan dengan bahasa pemrograman lain seperti C/C++. Selain itu terdapat banyak pustaka untuk mendukung keperluan analisis dan ML (Adetiba et al., 2021). Saat ini, 65% peneliti menggunakan Python sebagai tool ML dan DL dibandingkan R yang hanya 25% (Odhiambo, 2020).

Python adalah bahasa pemrograman tingkat tinggi yang digunakan untuk banyak hal, mulai dari membangun berbagai macam aplikasi hingga analisis data dan AI. Python dirancang oleh Guido van Rossum pada tahun 1980 dan dirilis secara resmi pada tahun 1991. Pengembangan ML dan DL dengan Python dapat dilakukan dari awal (tanpa pustaka) atau dengan pustaka. Saat ini sudah banyak pustaka *open source* yang memfasilitasi pengembangan ML dan DL. Beberapa di antaranya dikembangkan oleh

perusahaan teknologi besar seperti Google dengan pustaka Tensorflow dan Meta dengan pustaka Pytorch. Selain itu, ada berbagai *Integrated Development Environment* (IDE) seperti Jupyter Notebook dan PyCharm. Bahkan, Google Colaboratory menyediakan IDE berbasis browser yang terintegrasi dengan *cloud virtual machine*. Hal ini sangat membantu peneliti dalam melatih model pada komputer dengan spesifikasi terbatas.

Ada beberapa pustaka penting untuk mengembangkan model *Neural Network* menggunakan Python, diantaranya:

a. NumPy

NumPy adalah paket dasar untuk melakukan komputasi ilmiah di Python yang menyediakan objek *array* multidimensi dan objek turunan seperti *masked arrays* dan *matrices*. Hal ini juga menawarkan berbagai operasi aljabar, statistik dasar, simulasi acak, matematika, logika, manipulasi bentuk, pengurutan, pemilihan, I/O, transformasi Fourier diskrit, dan lain-lain. (Harris et al., 2020).

b. Pandas

Pandas adalah perpustakaan untuk analisis dan manipulasi data. Pandas dapat membaca data dalam banyak format, termasuk CSV, TSV, Excel, JSON, dan SQL. Secara umum, ada dua struktur yang berguna untuk manipulasi data di Pandas yaitu *Series* dan *DataFrame*. Seri Pandas pada dasarnya adalah struktur satu dimensi, seperti kolom di Excel. Dataframe Pandas adalah struktur dua dimensi yang struktur datanya berupa tabel dengan baris dan kolom (Reback et al., 2022).

c. Matplotlib

Matplotlib adalah pustaka yang digunakan untuk membuat visualisasi statis, animasi, dan interaktif dengan Python. Matplotlib dapat digunakan untuk membuat berbagai visualisasi data seperti diagram batang, *scatter*, *boxplot*, *pie chart*, dan lain sebagainya. Selain itu, Matplotlib digunakan untuk memvisualisasikan data dalam 2D dan 3D dan menghasilkan gambar berkualitas tinggi yang dapat disimpan dalam berbagai format gambar seperti JPEG dan PNG (Hunter, 200).

d. Scikit-learn

Scikit-learn adalah pustaka yang multifungsi yang digunakan untuk berbagai keperluan seperti

melakukan berbagai analisis data dan ML. Aplikasi perpustakaan ini termasuk *supervised learning* (model linier, SVM, *Nearest Neighbors*, *Decision Trees*, *Neural Network* dan lain-lain), reduksi dimensi (PCA, feature selection, dan lain-lain), evaluasi model (korelasi Pearson, *mean square error*, *mean absolute persentage error*, dan lain-lain), praproses data (normalisasi data, imputasi data hilang, pengkodean fitur kategoris dan lain-lain) dan masih banyak fitur lainnya (Pedregosa et al., 2011).

e. Keras dan TensorFlow

TensorFlow adalah pustaka *open source* yang dikembangkan oleh Google untuk penelitian *machine learning* dan *deep learning*. TensorFlow memiliki ekosistem, pustaka, dan komunitas yang kaya serta fleksibel yang memungkinkan peneliti merancang, membangun, dan menerapkan aplikasi berbasis machine learning dan deep learning. Keras adalah *Application Programming Interface* (API) yang dikembangkan menggunakan bahasa pemrograman Python dan berjalan di atas platform TensorFlow. Dengan menggunakan perpustakaan Keras, peneliti dapat lebih menyederhanakan *script* TensorFlow dan memberikan solusi yang jelas untuk permasalahan dalam mengembangkan model *deep learning*. Keras banyak digunakan oleh berbagai organisasi ilmiah di seluruh dunia, termasuk CERN, NASA, dan NIH (Abadi et al., 2015; Gulli & Pal, 2017).

Pustaka diatas merupakan pustaka yang populer dalam penelitian NN. Selain pustaka diatas, masih terdapat banyak pustaka *open source* lainnya yang masih bisa di *explore* seperti Pytorch, Theano, Mxnet dan lain sebagainya.

PENGUNAAN MODEL NEURAL NETWORK DI PERKEBUNAN KELAPA SAWIT

Penelitian terkait pemanfaatan model NN untuk perkebunan kelapa sawit telah dilakukan oleh beberapa peneliti (Tabel 1). Namun demikian, masih banyak yang perlu di eksplorasi lebih lanjut dari penelitian tersebut, misalnya dengan memanfaatkan berbagai data yang di *record* selama budidaya perkebunan berlangsung untuk melakukan prediksi produksi, menentukan dosis rekomendasi dan waktu pemupukan yang tepat, memperkirakan ledakan hama dan penyakit, sistem peringatan dini terjadi kekeringan dan antisipasinya dan masih banyak lagi.

Tabel 1. Pemanfaatan model NN di perkebunan kelapa sawit

No.	Peneliti	Hasil penelitian			Evaluasi Model
		Masukan dan Keluaran	Arsitektur	Perangkat Lunak	
1	Harahap & Lubis, 2018	<p>Masukan: Curah hujan dan <i>d-tapped delayed (rainfall lag)</i> (data selama 5 tahun)</p> <p>Keluaran: Prediksi produksi</p>	NARX ANN	MATLAB	R = 0.74 – 0.86
2	Kartika et al., 2016	<p>Masukan: Curah hujan, suhu, kelembaban, intensitas cahaya dan kecepatan angin (data selama 6 tahun)</p> <p>Keluaran: Prediksi produktivitas</p>	ANN MLPBP	MATLAB	MAE = 0.53; MSE = 0.47; RMSE = 0,69
3	Watson-Hernández et al., 2022	<p>Masukan: Tanaman (progeni dan tahun tanam) (<i>lag time</i>: 1 tahun), Satelit (indeks vegetasi dan kelembaban) (data selama 16 tahun).</p> <p>Keluaran: Prediksi produktivitas</p>	ANN	R Studio	MAE = 0.26; RMSE = 0.34; NSE = 0.81, R ² = 0.81
4	Hermantoro & Rudyanto, 2018	<p>Masukan: Tipe tanah, kedalaman tanah, pH, curah hujan, suhu, defisit air, kelembaban, dan radiasi matahari</p> <p>Keluaran: Produktivitas (ton/ha/thn)</p>	ANN MLPBP	MATLAB	R ² = 0.99; RMSE = 0.494

(continued)

No.	Peneliti	Hasil penelitian			Evaluasi Model
		Masukan dan Keluaran	Arsitektur	Perangkat Lunak	
5	Abd Mubin, Nadarajoo, Shafri, & Hamedianfar, 2019	Masukan: Citra resolusi tinggi Keluaran: Klasifikasi tanaman belum menghasilkan (TBM) dan menghasilkan melalui citra (TM)	CNN	Python dengan pustaka Keras	Overall Accuracy (OA) TBM = 95,11%; OA TM = 92,96%
6	Li, Dong, Fu, & Yu, 2019	Masukan: Citra resolusi tinggi Keluaran: Klasifikasi tanaman kelapa sawit	CNN	-	F1-Score 94,99%
7	Jayaselan, Nawi, & Mehdizadeh, 2018	Masukan: Band spektral dari spektroradiometer Keluaran: Hara daun N dan K	ANN MLPBP	MATLAB	Akurasi 85%
8	Ashari, Yanris, & Purnama, 2022	Masukan: Foto tandan kelapa sawit dengan tiga tipe yaitu mentah, matang, dan lewat matang. Keluaran: Deteksi tingkat kematangan melalui foto	CNN	Python dengan pustaka Tensorflow	Akurasi 76%
9	Kwong et al., 2021	Masukan: Citra stomata pada daun di beberapa kelompok umur Keluaran: Deteksi stomata pada daun	CNN	Python dengan pustaka Tensorflow	Akurasi 99,7%

(continued)

No.	Peneliti	Hasil penelitian			
		Masukan dan Keluaran	Arsitektur	Perangkat Lunak	Evaluasi Model
10	Sugiarto & Raisawati, 2021	Masukan: Data produksi tahun 1970 - 2017 Keluaran: Produksi kelapa sawit	LSTM-RNN	-	MAPE 2,99%
11	Syarovy et al., 2022	Masukan: 24 masukan dari data-data yang terdapat diperkebunan selama 11 tahun dengan pengaruh lag komponen curah hujan 1 tahun. Keluaran: Produksi dan produktivitas per tahun	ANN	Python dengan pustaka Keras dan Tensorflow	MAPE 10,52%

PENUTUP

Neural network (NN) merupakan salah satu model yang digunakan dalam AI dan memiliki peran penting dalam mendukung generasi baru pertanian presisi. Model NN juga sangat penting dalam melahirkan beberapa model lainnya seperti *Random Forest* dan *Support Vector Machines*. Seiring semakin pesatnya perkembangan teknologi komputer, para peneliti banyak melakukan penelitian yang mendalam terhadap model NN, baik dengan menambahkan banyak fitur ekstraksi, lapisan tersembunyi, dan algoritma yang lebih kompleks sehingga melahirkan sub kelompok yang lebih spesifik atau lebih dikenal dengan *deep learning* (DL). Saat ini, penerapan model NN sangat mudah karena dukungan berbagai perangkat lunak *open source*, komunitas yang sangat besar dan perangkat komputasi yang canggih.

Model NN sudah digunakan pada berbagai penelitian kelapa sawit. Namun, hasil penelitian tersebut masih belum dapat aplikasikan ke dalam sistem untuk pengambilan keputusan yang tepat. Masih banyak ruang yang dapat di eksplorasi dari

penggunaan model tersebut seperti melakukan prediksi produksi, menentukan dosis rekomendasi dan waktu pemupukan yang tepat, memperkirakan ledakan hama dan penyakit, sistem peringatan dini terjadi kekeringan dan antisipasinya dan masih banyak lagi.

DAFTAR PUSTAKA

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Zheng, X. (2015). TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems. <https://www.tensorflow.org/>, 1–19.
- Abd Mubin, N., Nadarajoo, E., Shafri, H., & Hamedianfar, A. (2019). Young and Mature Oil Palm Tree Detection and Counting Using Convolutional Neural Network Deep Learning Method. *International Journal of Remote Sensing*, 40. <https://doi.org/10.1080/01431161.2019.1569282>
- Adetiba, E., Adeyemi-Kayode, T. M., Akinrinmade, A. A., Moninuola, F. S., Akintade, O. O., Badejo, J.

- A., ... Abayomi, A. (2021). Evolution of Artificial Intelligence Programming Languages—A Systematic Literature Review. *Journal of Computer Science*, 17(11), 1157–1171. <https://doi.org/10.3844/jcssp.2021.1157.1171>
- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A Textbook*. Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-94463-0>
- Agung, D. K., & Gunawan, G. (2020). KEMRUNGSUNG: Intensifikasi Pertanian oleh Petani di Desa Kenalan Kecamatan Pakis Kabupaten Magelang. *Solidarity: Journal of Education, Society and Culture*, 9(2), 1042–1052.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Asari, V. K. (2018). The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches. *CoRR*, abs/1803.01164. Retrieved from <http://arxiv.org/abs/1803.01164>
- Ashari, S., Yanris, G. J., & Purnama, I. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning. *Sinkron: Jurnal Dan Penelitian Teknik Informatika*, 7(2), 649–656. <https://doi.org/10.33395/sinkron.v7i2.11420>
- Badan Pusat Statistik. (2019). Indonesian Oil Palm Statistics 2019. Retrieved September 3, 2022, from <https://www.bps.go.id/>
- Bendre, M. R., Thool, R. C., & Thool, V. R. (2015). Big data in precision agriculture: Weather forecasting for future farming. *2015 1st International Conference on Next Generation Computing Technologies (NGCT)*, 744–750. Dehradun, India: IEEE. <https://doi.org/10.1109/NGCT.2015.7375220>
- Bwambale, E., Abagale, F. K., & Anornu, G. K. (2022). Smart Irrigation Monitoring and Control Strategies for Improving Water Use Efficiency In Precision Agriculture: A Review. *Agricultural Water Management*, 260, 107324. <https://doi.org/10.1016/j.agwat.2021.107324>
- Direktorat Jenderal Perkebunan. (2020). Statistik Perkebunan Unggulan Nasional 2019—2021. *Sekretariat Dirjend Perkebunan Kementerian Pertanian*, 1056 pp.
- Fausett, L. (1994). *Fundamentals of Neural Networks Architectures, Algorithms, and Applications*. Prentice-Hall.
- García-Rodríguez, L. del C., Prado-Olivarez, J., Guzmán-Cruz, R., Rodríguez-Licea, M. A., Barranco-Gutiérrez, A. I., Perez-Pinal, F. J., & Espinosa-Calderon, A. (2022). Mathematical Modeling to Estimate Photosynthesis: A State of the Art. *Applied Sciences*, 12(11), 5537. <https://doi.org/10.3390/app12115537>
- Gil, D., & Song, I.-Y. (2016). Modeling and Management of Big Data: Challenges and Opportunities. *Future Generation Computer Systems*, 63, 96–99. <https://doi.org/10.1016/j.future.2015.07.019>
- Ginting, E. N., & Wiratmoko, D. (2021). Potensi dan Tantangan Penerapan Precision Farming dalam Upaya Membangun Perkebunan Kelapa Sawit yang Berkelanjutan. *WARTA Pusat Penelitian Kelapa Sawit*, 26(2), 12.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press Book. Retrieved from <https://www.deeplearningbook.org>
- Gulli, A., & Pal, S. (2017). *Deep Learning with Keras*. Packt Publishing Ltd.
- Hakkim, V., Joseph, E., Gokul, A., & Mufeedha, K. (2016). Precision Farming: The Future of Indian Agriculture. *Journal of Applied Biology and Biotechnology*, 068–072. <https://doi.org/10.7324/JABB.2016.40609>
- Harahap, I. Y., & Lubis, M. E. S. (2018). Penggunaan Model Jaringan Saraf Tiruan (Artificial Neuron Network) untuk Memprediksi Hasil Tandan Buah Segar (TBS) Kelapa Sawit Berdasar Curah Hujan dan Hasil TBS Sebelumnya. *Jurnal Penelitian Kelapa Sawit*, 26(2), 59–70. <https://doi.org/10.22302/iopri.jur.jpks.v26i2.42>
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Oliphant, T. E. (2020). Array Programming with NumPy. *Nature*, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- Hermantoro & Rudyanto. (2018). Modeling and Simulation of Oil Palm Plantation Productivity Based on Land Quality and Climate Using Artificial Neural Network. *International Journal*

- of Oil Palm, 1(2), 65–70.
- Hunter, J. D. (2007). Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
- Jayaselan, H. A., Nawi, N. M., & Mehdizadeh, S. A. (2018). Application of Artificial Neural Network Classification to Determine Nutrient Content in Oil Palm Leaves Using SPOT7 to Optimize Nitrogen Fertilizer in Oil Palm View project Smart sprayer for weed/plant detection View project. <https://doi.org/10.13031/aea.12403>
- Kartika, N. D., Astika, W., & Santosa, E. (2016). Oil Palm Yield Forecasting Based on Weather Variables Using Artificial Neural Network. *Indonesian Journal of Electrical Engineering and Computer Science*, 3(3), 626–633. <https://doi.org/10.11591/ijeecs.v3.i2.pp626-633>
- Kwong, Q. B., Wong, Y. C., Lee, P. L., Sahaini, M. S., Kon, Y. T., Kulaveerasingam, H., & Appleton, D. R. (2021). Automated stomata detection in oil palm with convolutional neural network. *Scientific Reports*, 11(1), 15210. <https://doi.org/10.1038/s41598-021-94705-4>
- Li, S., Deng, Y.-Q., Zhu, Z.-L., Hua, H.-L., & Tao, Z.-Z. (2021). A Comprehensive Review on Radiomics and Deep Learning for Nasopharyngeal Carcinoma Imaging. *Diagnostics*, 11, 1523. <https://doi.org/10.3390/diagnostics11091523>
- Li, W., Dong, R., Fu, H., & Yu, L. (2019). Large-Scale Oil Palm Tree Detection from High-Resolution Satellite Images Using Two-Stage Convolutional Neural Networks. *Remote Sensing*, 11(1), 11. <https://doi.org/10.3390/rs11010011>
- Marcin, S. (2021). Is Data the New Oil? Retrieved September 3, 2022, from European Parliament website: [https://www.europarl.europa.eu/RegData/etudes/BRIE/2020/646117/EPRS_BRI\(2020\)646117_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2020/646117/EPRS_BRI(2020)646117_EN.pdf)
- Math, R. K. M., & Dharwadkar, N. V. (2018). IoT Based Low-cost Weather Station and Monitoring System for Precision Agriculture in India. *2018 2nd International Conference on 2018 2nd International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)/I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 81–86. <https://doi.org/10.1109/I-SMAC.2018.8653749>
- Nanda, M. A. (2022). Menerapkan Pertanian Presisi pada Kelapa Sawit. Retrieved September 3, 2022, from Detik website: <https://news.detik.com/kolom/d-6029710/menerapkan-pertanian-presisi-pada-kelapa-sawit>
- Odhiambo, J. O. (2020). Which One is The Best for Machine Learning and Deep Learning? https://www.Researchgate.Net/Publication/341419997_An_Analytical_Comparison_Between_Python_Vs_R_Programming_Languages_Which_one_is_the_best_for_Machine_Learning_and_Deep_Learning#fullTextFileContent. Retrieved from https://www.researchgate.net/publication/341419997_An_Analytical_Comparison_Between_Python_Vs_R_Programming_Languages_Which_one_is_the_best_for_Machine_Learning_and_Deep_Learning#fullTextFileContent
- Ozgun, C., Colliau, T., Rogers, G., Hughes, Z., & Bennie, E. (2017). MatLab vs. Python vs. R. *Journal of Data Science: JDS*, 15, 355–372.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830.
- Pooja, S., Uday, D. V., Nagesh, U. B., & Talekar, S. G. (2017). Application of MQTT Protocol for Real Time Weather Monitoring and Precision Farming. *2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)*, 1–6. <https://doi.org/10.1109/ICEECCOT.2017.8284616>
- Purba, J. H. V. (2019). Industri Sawit Indonesia dalam Perspektif Minyak Nabati Global. *Kesatuan Press*, 224.
- Pushparani, M., Sagaya, A., & Ravan, S. (2018). Big Data Analytics using Weight Estimation Algorithm for Oil Palm Plantation Domain. *Int. J.*

- Advance Soft Compu. Appl*, 10(1), 71–89.
- Rajković, D., Jeromela, A. M., Pezo, L., Lončar, B., Zanetti, F., Monti, A., & Špika, A. K. (2022). Yield and Quality Prediction of Winter Rapeseed—Artificial Neural Network and Random Forest Models. *Agronomy*, 12(1). <https://doi.org/10.3390/agronomy12010058>
- Reback, J., jbrockmendel, McKinney, W., Bossche, J. V. den, Roeschke, M., Augspurger, T., ... Li, T. (2022). *pandas-dev/pandas: Pandas 1.4.4*. Zenodo. <https://doi.org/10.5281/zenodo.7037953>
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence A Modern Approach* (Fourth). US: Pearson.
- Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Serraj, R., & Pingali, P. (2019). *Agriculture & Food Systems to 2050: Global Trends, Challenges and Opportunities*. <https://doi.org/10.1142/11212>
- Shinde, P. P., & Shah, S. (2018). A Review of Machine Learning and Deep Learning Applications. 2018 *Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, 1–6. Pune, India: IEEE. <https://doi.org/10.1109/ICCUBEA.2018.8697857>
- Singh, D. K., Sobti, R., Jain, A., Malik, P. K., & Le, D.-N. (2022). LoRa Based Intelligent Soil and Weather Condition Monitoring with Internet of Things for Precision Agriculture in Smart Cities. *IET Communications*, 16(5), 604–618. <https://doi.org/10.1049/cmu2.12352>
- Statista. (2022). Total Data Volume Worldwide 2010-2025. Retrieved August 27, 2022, from Statista website: <https://www.statista.com/statistics/871513/worldwide-data-created/>
- Sugiarto, E., & Raisawati, T. (2021). Kajian Peranan Sertifikasi Benih pada Usaha Penangkaran Benih dalam Mendukung Pembangunan di Bengkulu. *Jurnal Ilmu Tanaman*, 1(2), 99–106.
- Suwarno, W. (2019). Kebijakan Sawit Uni Eropa dan Tantangan bagi Diplomasi Ekonomi Indonesia. *Jurnal Hubungan Internasional*, 8(1). <https://doi.org/10.18196/hi.81150>
- Syarovy, M., Nugroho, A. P., Sutiarsio, L., Suwardi, Muna, M. S., Wiratmoko, A., Pramananda, S. (2022). *Utilization of Big Data in Oil Palm Plantation to Predict Production Using Artificial Neural Network Model*. 492–502. Atlantis Press. https://doi.org/10.2991/978-94-6463-086-2_67
- Thin-Yin, L., & Jonathan, L. Y. (2020). Simpler Machine Learning Using Spreadsheets: Neural Network Predict. *European Journal of Engineering and Formal Sciences*, 4(1), 124. <https://doi.org/10.26417/ejef.v4i1.p124-138>
- Watson-Hernández, F., Gómez-Calderón, N., & da Silva, R. P. (2022). Oil Palm Yield Estimation Based on Vegetation and Humidity Indices Generated from Satellite Images and Machine Learning Techniques. *AgriEngineering*, 4(1), 279–291. <https://doi.org/10.3390/AGRIENGINEERING4010019>
- Wijaya, A. R., & Susandi, A. (2018). Konsep Forecast Based Financing untuk Pertanian Presisi di Indonesia. *Prosiding Semnastek*, (0). Retrieved from <https://jurnal.umj.ac.id/index.php/semnastek/article/view/3534>
- Wijayanto, Y., Purnamasari, I., Ristiana, S., Saputra, T. W., & Regar, A. F. (2022). [Perkembangan Penggunaan Big Data pada Bidang Pertanian di Indonesia]: Review. *Prosiding Seminar Nasional Fakultas Pertanian UNS*, 6(1), 312–320.
- Zicari, R. (2013). Big Data: Challenges and Opportunities. In R. Akerkar (Ed.), *Big Data Computing* (pp. 103–128). Chapman and Hall/CRC. <https://doi.org/10.1201/b16014-5>

