



**Analisa Prediksi Tegangan *Input Sensor Capacitive Soil Moisture* dengan *Random Forest*
untuk Mendukung Pertanian Pintar**

Elsa Nurul Mardiyati¹, Tresna Dewi², Yurni Oktarina³

¹Teknik Elektro, Politeknik Negeri Sriwijaya

elsanurulmardiyatii@gmail.com, tresna_dewi@polsri.ac.id, yurni_oktarina@polsri.ac.id

Abstract

In this era of rapid technological development, agriculture in Indonesia has entered the Generation 4.0 era with the main focus on the transformation, development, and utilization of technology in agriculture. The agricultural sector in Indonesia is currently in the transformation of traditional agriculture towards smart agriculture that utilizes technological advances, such as the Internet of Things (IoT), robotics, and microcontrollers, one of the applications of these technologies is in greenhouses. Greenhouse is a building covered with clear or translucent material that requires monitoring of certain variables, such as temperature, humidity, and light intensity, to maintain the condition of cultivated plants. In the greenhouse Translated with DeepL.com (free version). In the greenhouse, a Capacitive Soil Moisture sensor is used, which when the sensor detects a lack of moisture in the soil, it will give a signal to turn on the pump. This sensor certainly requires input in turning on the pump, where the voltage has a different value for each action in turning on the pump. Therefore, a prediction and proof approach with the help of optimization is needed to predict the sensor input so that it can continue to support the smooth continuity of agriculture in the greenhouse. In predicting the input voltage of the Capacitive Soil Moisture Sensor using random forest. The test results using random forest show an accuracy rate of 100% or 1.00 which is displayed with the ROC graph and Confusion Matrix. In the evaluation model, this random forest model gets macro average and weighted average values with a precision value of 1.00, recall 1.00, f1-score 1.00 and support 45. As well as MSE and RMSE values at 0.0000. Translated with DeepL.com (free version)

Keywords: Smart Farm, Input Prediction, Random Forest

Abstrak

Di era perkembangan teknologi yang sangat pesat ini, pertanian di Indonesia telah memasuki era Generasi 4.0 dengan fokus utama pada transformasi, pengembangan, dan pemanfaatan teknologi di bidang pertanian. Sektor pertanian di Indonesia saat ini sedang berada pada transformasi pertanian tradisional menuju pertanian cerdas yang memanfaatkan kemajuan teknologi, seperti *Internet of Things* (IoT), robotika, dan mikrokontroler, salah satu penerapan teknologi tersebut ada pada *greenhouse*. *Greenhouse* merupakan bangunan yang diselubungi bahan bening atau tembus cahaya yang memerlukan pemantauan variabel tertentu, seperti temperatur, kelembaban udara, dan intensitas cahaya, untuk menjaga kondisi tanaman yang dibudidayakan. Pada *greenhouse* digunakan sensor *Capcitive Soil Moisture*, dimana pada saat sensor tersebut mendeteksi kurangnya kelembapan pada tanah, maka sensor tersebut akan memberikan sinyal untuk menghidupkan pompa. Sensor ini tentu saja memerlukan *input* dalam menghidupkan pompa, dimana tegangan tersebut memiliki nilai yang berbeda-beda disetiap aksinya dalam menghidupkan pompa. Oleh karena itu, diperlukannya pendekatan prediksi dan pembuktian dengan bantuan optimalisasi untuk memprediksi *input* sensor agar dapat terus mendukung kelancaran keberlangsungan pertanian pada *greenhouse*. Dalam memprediksi tegangan *input* sensor *Capcitive Soil Moisture* ini menggunakan *random forest*. Hasil pengujian menggunakan *random forest* menunjukkan angka akurasi 100% atau 1,00 yang di tampilkan dengan grafik ROC dan *Confusion Matrixs*. Pada model evaluasi, model *random forest* ini mendapatkan nilai *macro average* dan *weighted average* dengan nilai *precision* 1.00, *recall* 1.00, *f1-score* 1.00 dan *support* 45. Serta nilai MSE dan RMSE di angka 0,0000.

Kata kunci: Pertanian Pintar, Prediksi *Input*, *Random Forest*

1. Pendahuluan

Indonesia merupakan negara agraris dengan Sumber Daya Alam (SDA) yang melimpah, khususnya sumber daya lahan, menjadikan sektor pertanian sangat vital dalam mendukung tercapainya ketahanan pangan guna mencapai SDG's ke-2 yang menargetkan penghilangan kelaparan, ketahanan pangan dan gizi yang baik, serta meningkatkan pertanian berkelanjutan. Saat ini, pertanian di Indonesia telah memasuki era Generasi 4.0 dengan fokus utama pada transformasi, pengembangan, dan pemanfaatan teknologi di bidang pertanian. Salah satu pemanfaatan teknologi pada bidang pertanian yaitu adalah *greenhouse* [1-2]. Di dalam *greenhouse*, parameter lingkungan yang berpengaruh terhadap pertumbuhan tanaman, yaitu cahaya matahari, suhu udara, kelembaban udara, pasokan nutrisi, kecepatan angin, dan konsentrasi karbondioksida dapat dikendalikan. Penggunaan *greenhouse* memungkinkan dilakukannya modifikasi lingkungan yang tidak sesuai bagi pertumbuhan tanaman menjadi lebih mendekati kondisi optimum bagi pertumbuhan tanaman. [1-2-3]


Saat ini *greenhouse* banyak digunakan dalam proses kendali tanaman mulai dari pembibitan, perawatan dan pemanenan tanaman namun banyak *greenhouse* yang cara pengontrolan dan perawatan tanamannya masih dilakukan secara manual oleh petani mulai dari penyiraman yang dilakukan dipagi dan sore hari tanpa memperhatikan kelembaban tanah yang dibutuhkan tanaman, pemupukan yang dilakukan kurang sesuai dengan nutrisi yang dibutuhkan tanaman dan pengaturan suhu *greenhouse* yang dilakukan dengan cara membuka jendela yang ada di *greenhouse* yang memungkinkan adanya hama yang masuk ke *greenhouse*, sehingga pertumbuhan tanaman belum optimal [4-5-6]. Selain itu pengelolaan waktu dan minimnya alat yang dapat membantu kinerja petani menjadi sebuah permasalahan dalam pengelolaan *greenhouse* secara manual. Kolaborasi teknologi, khususnya penggunaan sensor untuk mendeteksi kelembaban tanah, menjadi solusi penting dalam mendukung konsep pertanian berkelanjutan.[4-5]

Salah satu sensor yang dapat digunakan untuk mendeteksi kelembaban tanah adalah Sensor *Capcitive Soil Moisture*, dimana pada saat sensor tersebut mendeteksi kurangnya kelembaban pada tanah, maka sensor tersebut akan memberikan sinyal untuk menghidupkan pompa sehingga pompa tersebut akan otomatis melakukan penyiraman pada tanaman. Sensor ini tentu saja memerlukan *input* dalam menghidupkan pompa, dimana tegangan tersebut memiliki nilai yang berbeda-beda disetiap aksinya dalam menghidupkan pompa.

Oleh karena itu, diperlukannya pendekatan prediksi dan pembuktian dengan bantuan optimalisasi untuk memprediksi *input* sensor agar dapat terus mendukung kelancaran keberlangsungan pertanian pada *greenhouse*. Dalam memprediksi Tegangan *Input Sensor Capcitive Soil Moisture* ini menggunakan *Random Forest* menghasilkan prediksi *input* sensor kedepannya.

2. Metode Penelitian

Penelitian ini menerapkan teknologi *deep learning* dengan menggunakan *random forest* yang mampu melakukan pengolahan data dan melakukan prediksi. Diharapkan penelitian ini dapat memberikan wawasan dalam penggunaan *random forest* dalam memprediksi tegangan *input* sensor *Capcitive Soil Moisture* guna mendukung kelembaban tanah pada *greenhouse* tetap terjaga dan dapat mempermudah petani dalam melakukan pengecekan. Metode prediksi menggunakan model *random forest* ini juga mampu memberikan gambaran kepada petani tentang kondisi tanah pada tanaman.



Gambar 2.1 Blok Diagram Proses Pengolahan Data

2.1 Historical Data

Data yang digunakan merupakan data historis dari sensor dan pompa. Data ini bersumber dari 20 sensor *Capcitive Soil Moisture* yang terhubung dengan satu pompa. Dimana ketika sensor mendeteksi kurangnya kadar air pada tanah, maka pompa akan aktif dan tegangan pada pompa akan terdeteksi.

2.2 Input Dataset

Input dataset merupakan tahapan memasukan data yang akan digunakan pada model. Data yang digunakan pada penelitian kali ini merupakan data tegangan input sensor satu hari, yang dimulai pada pukul 08.00 WIB – 16.00 WIB, data ini diambil di setiap jamnya pada satu hari yang sama. Jumlah data yang digunakan, sebanyak 724 data yang terdiri dari tegangan input sensor, tegangan pompa dan kategori (pompa aktif atau pompa tidak aktif).

2.2.1 Data Proses

a. *Exploratory Data Analysis* (EDA)

Exploratory Data Analysis (EDA) *random Forest* adalah proses analisis yang dilakukan untuk memahami dan menganalisis karakteristik data sebelum diterapkan dalam model *Random forest*. Untuk data yang digunakan dalam pengujian kali ini berupa *integer*, *float*, dan *string* [12-13].

b. *Data Cleaning*

Data cleaning merupakan tahapan pembersihan atau pembersihan data agar keberadaan data kosong (*missing value*) dapat terdeteksi dan setelah itu dilakukan pengisian terhadap data kosong. Hal ini tentu saja berfungsi untuk mengurangi kesalahan dalam mengolah dan memprediksi data [14-15]. Keberadaan *missing value* dapat merugikan dalam analisis data dan mempengaruhi performa model prediktif. Oleh karena itu, setelah berhasil mendeteksi *missing value*, langkah selanjutnya adalah melakukan pengisian atau imputasi terhadap nilai yang kosong tersebut. Pengisian ini dapat dilakukan dengan berbagai metode, seperti menggantinya dengan nilai rata-rata, median, atau menggunakan teknik imputasi yang lebih kompleks sesuai dengan konteks data [16-17].

2.3 Model Building *Random Forest*

Random Forest (RF) adalah suatu teknik yang dapat meningkatkan tingkat keakuratan dengan melakukan pembangkitan atribut untuk setiap node secara acak [18-19]. *Random forest* memiliki beberapa keunggulan, termasuk kemampuannya untuk meningkatkan akurasi ketika berhadapan dengan data yang tidak lengkap dan ketahanannya terhadap variasi data yang ekstrim. Dengan memanfaatkan seleksi fitur ini, *random forest* dapat secara efektif menangani data besar dengan parameter yang kompleks [20].

Algoritma *random forest* menghasilkan pohon keputusan dengan menggunakan keacakan dalam proses konstruksi pohon. Setiap pohon keputusan dilatih

dengan versi yang sedikit berbeda dari set pembelajaran asli, sehingga menghasilkan sekumpulan pohon yang beragam. Kemudian, prediksi dari semua pohon ini digabungkan menggunakan teknik agregasi [21].

Random forest mempunyai dua parameter utama, yaitu parameter m yang merupakan presentasi dari jumlah pohon yang akan dipakai dan parameter k yang merupakan representasi dari banyaknya fitur maksimal yang dipertimbangkan ketika proses percabangan pada pohon (Widjiyati, 2021).

Pada gugus data yang terdiri atas n amatan dan p peubah penjelas, *random forest* dilakukan dengan cara (Breiman 2001; Breiman & Cutler 2003):

1. Lakukan penarikan contoh acak berukuran n dengan pemulihan pada gugus data. Tahapan ini merupakan tahapan *bootstrap*.
2. Dengan menggunakan contoh *bootstrap*, pohon dibangun sampai mencapai ukuran maksimum (tanpa pemangkasan). Pada setiap simpul, pemilihan pemilah dilakukan dengan memilih m peubah penjelas secara acak, dimana $m \ll p$. Pemilah terbaik dipilih dari m peubah penjelas tersebut. Tahapan ini adalah tahapan *random feature selection*.
3. Ulangi langkah 1 dan 2 sebanyak k kali, sehingga terbentuk sebuah hutan yang terdiri atas k pohon.

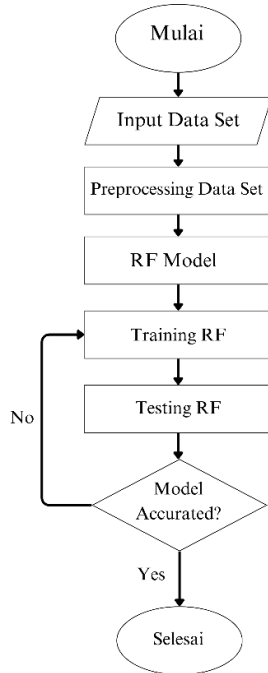
Random forest bersifat *ensemble learning*. *Ensemble learning* adalah penggabungan dari beberapa algoritma *machine learning* untuk mendapatkan solusi prediksi yang lebih baik. Metode ini melakukan klasifikasi dengan penggabungan model *tree*. *Random forest* mampu mengklasifikasi data yang memiliki atribut yang tidak lengkap dan cocok digunakan untuk pengklasifikasian data sampel yang banyak [22]. Proses klasifikasi pada *Random forest* melakukan *split* (memecah) data sampel yang ada ke dalam *decision tree* secara acak. Dengan menggunakan *random forest* respons suatu amatan diprediksi dengan menggabungkan (*aggregating*) hasil prediksi k pohon, yang mana klasifikasi dilakukan berdasarkan *majority vote* (suara terbanyak) [23].

2.3 Model Evaluation

Model Evaluation merupakan tahapan melakukan validasi terhadap model *random forest* yang akan digunakan. Model evaluasi yang akan digunakan pada penelitian kali ini terdiri dari dua kategori, yaitu *Mean Squared Error* (MSE) dan *Root Mean Squared Error* (RMSE). MSE digunakan untuk mengetahui seberapa baik model dalam memprediksi nilai, sedangkan RMSE digunakan untuk mengukur rata-rata dari jarak antara nilai sebenarnya dan nilai hasil prediksi nantinya.

Model evaluation lainnya yang digunakan adalah *macro average* dan *weighted average*. *Macro average* merupakan evaluasi dengan menghitung matriks secara bebas kemudian mengambil rata-ratanya untuk setiap kelas atau kategori. Sedangkan *weigthed average*, akan menghitung rata-rata dengan memperhitungkan bobot pada setiap datanya.

2.4 Flowchart



Gambar 2.2 Flowchart penelitian


Gambar 2.2 merupakan *flowchart* dari penelitian yang akan di lakukan, di mulai dari melakukan input dataset dan dilanjutkan preprocessing dataset yang dibagi menjadi data training 80%, data validasi 10% dan data testing 10%. Ditahap akhir model tersebut akan dievaluasi, jika nilai model evaluasi tidak optimal, maka data akan kembali berada pada proses training data, begitupun sebaliknya, jika model berada dalam kategori optimal maka proses akan selesai.

3. Hasil dan Pembahasan

3.1 Data Input

Pada Gambar 3.1, terlihat bahwa grafik tertinggi berada pada tegangan pompa *off* atau tidak memiliki tegangan, ini merupakan data yang dominan atau terbanyak yang digunakan pada percobaan pengolahan data kali ini, hal tersebut dikarenakan data 0.0 merupakan data yang didapatkan dari data pompa yang akan hidup ketika sensor mendeteksi tanah dalam keadaan kering. Data lainnya dalam kategori “Yes” merupakan variasi data yang digunakan dalam

menghidupkan pompa. Untuk data yang digunakan dalam pengujian kali ini berupa data dalam bentuk *integer*, *float* dan *string*.




Gambar 3.1 Grafik data yang digunakan

Data tipe *integer* terdiri dari angka bilangan bulat baik yang positif maupun negatif dengan range tertentu. Dengan kata lain, dalam data integer tidak ada huruf maupun bilangan desimal. Sedangkan untuk tipe data *float* terdiri dari angka pecahan. Data integer dan float merupakan data *input* yang terdiri dari data sensor dan tegangan pompa yang akan digunakan dalam memprediksi. [18-19]

Selanjutnya untuk data string ini sendiri merupakan tipe data yang dapat digunakan pada teks atau urutan karakter, yang pada pengujian kali ini digunakan pada input Pompa aktif dan Pompa Mati yang berisi teks “Yes” dan “No”. Pilihan ini penting dalam memberikan interpretasi yang jelas terhadap keadaan sistem, mempermudah analisis, dan mendukung pengambilan keputusan yang efektif.


Penggunaan data *string* pada variabel tersebut juga mendukung interpretasi hasil dengan lebih baik. Ketika melibatkan klasifikasi atau prediksi terkait kondisi pompa, penggunaan data string memastikan bahwa hasil dapat diartikan secara langsung sebagai keputusan yang mudah dimengerti, mengurangi potensi kebingungan atau kesalahan interpretasi. [20-21]



Gambar 3.2 Grafik dan boxplot hasil prediksi tegangan pompa (V)

Sesuai dengan Gambar 3.2 boxplot dan grafik yang telah dihasilkan pada prediksi tegangan pompa (v), dapat dilihat bahwa tegangan pada pompa, memiliki grafik tertinggi berada pada angka 0 volt dan hasil lainnya berada pada angka 11 hingga 12 volt. Analisis terhadap grafik tersebut mengindikasikan adanya variasi yang signifikan dalam data tegangan pada pompa. Hal ini menunjukkan adanya variasi yang ada pada data tegangan pompa dengan sebagian besar prediksi berkumpul pada nilai-nilai yang lebih tinggi, kecuali untuk kasus khusus pada 0 volt yang merupakan data pompa mati.


Dapat dilihat pada boxplot Gambar 3.3 panjang *whisker* tidak sama antara sisi sebelah kanan dan sisi sebelah kiri. *Whisker* kanan lebih panjang dibandingkan *whisker* kiri menandakan data cenderung miring ke kiri (*positif skewness*) karena data lainnya yang mendominasi berada pada angka 0.



Gambar 3.3 Grafik dan boxplot hasil prediksi input tegangan sensor


Untuk data selanjutnya, Gambar 3.3 ini merupakan boxplot dan grafik dari hasil prediksi pada input sensor *capcitive soil moisture*, terlihat untuk *input* sensor itu sendiri memiliki nilai penyebaran data yang cukup merata, dengan data tertinggi berada pada kisaran angka 4,8 volt sampai dengan 5.0 volt dan data prediksi terendah berada pada angka 0 yaitu pada saat kondisi pompa mati dan di ikuti dengan data lainnya yang terlihat pada boxplot.

Dapat dilihat pada boxplot Gambar 3.3 garis median tidak berada pada tengah kotak, sedangkan garis *whisker* memiliki panjang yang sama antara sisi sebelah kiri dan sisi sebelah kanan. Hal ini berarti data tersebut memiliki penyebaran yang cukup luas, dimana hal ini dibuktikan dengan panjang

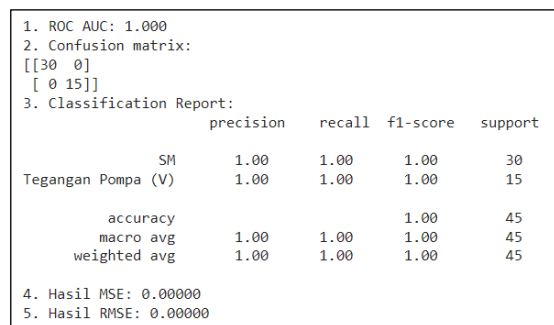


Gambar 3.4 Grafik hasil prediksi pompa aktif

Dari hasil prediksi didapatkan grafik pompa aktif dan mati, dimana grafik yang memperlihatkan pompa tidak aktif memiliki kurva yang naik, hal ini tentu saja dipengaruhi oleh nilai *input* dari sensor yang terhubung pada pompa. Kenaikan kurva pada kondisi pompa tidak aktif bisa mengindikasikan adanya fluktuasi atau perubahan dalam nilai sensor yang diprediksi oleh *random forest*.




Gambar 3.5 *Confusion Matrix* Prediksi



Gambar 3.6 Data hasil prediksi *input*

Ini merupakan hasil prediksi input menggunakan *random forest*. Berdasarkan hasil tersebut percobaan pada *input* prediksi sensor mendapatkan nilai evaluasi menggunakan *macro average* dan *weighted average* dengan nilai *precision* 1.00, *recall* 1.00, *f1-score* 1.00 dan *support* 30. Selanjutnya, pada kategori "tegangan pompa (V)", hasil prediksi juga menunjukkan performa yang sangat baik dengan nilai *precision*, *recall*, dan *f1-score* masing-masing sebesar 1.00. *Support* sebanyak 15 menandakan bahwa percobaan pada data tegangan pompa dilakukan dengan menggunakan jumlah sampel yang cukup signifikan. Konsistensi nilai yang tinggi pada setiap metrik evaluasi menandakan kehandalan model dalam melakukan prediksi terhadap data yang diuji.

Matrix evaluasi lainnya yaitu menggunakan MSE dan RMSE. Dimana semakin kecil nilai yang di dapatkan maka akan semakin besar akurasi dari model tersebut, hal ini menandakan model yang digunakan dapat menghasilkan data yang akurat. Nilai MSE dan RMSE yang di dapat adalah 0.0000 dan 0.0000.



Gambar 3.7 Grafik hasil akurasi menggunakan ROC

Dari Gambar 3.7 merupakan gambar grafik tipe *Receiver Operating Characteristic (ROC)* dari hasil prediksi menggunakan *random forest* didapatkan nilai akurasi prediksi sebesar 1.00. Nilai akurasi yang di dapat ini menunjukkan hasil bahwa model 100% berhasil memprediksi semua data pengujian dengan benar.

Hasil tersebut disebabkan oleh beberapa faktor, antar lain yaitu *overfitting* dimana model mungkin cocok dengan data pelatihan dan "*memorizing*" data tersebut, selanjutnya data *training* yang bersih dan ukuran dataset yang kecil [22-23].

4. Kesimpulan

Dalam penelitian ini, prediksi tegangan input dari sensor kapasitif kelembaban tanah menggunakan metode *Random forest* guna mendukung konsep pertanian pintar menunjukkan hasil pengujian mendapatkan hasil dengan tingkat akurasi sebesar 100% menciptakan harapan positif terhadap keberhasilan model dalam memprediksi kondisi tanah. Hal ini memungkinkan petani untuk mengambil keputusan yang lebih tepat waktu dan efisien dalam pengelolaan tanaman. *Random forest* dapat mengatasi masalah *overfitting* dan memberikan hasil yang stabil dan konsisten.

Hasil penelitian menggunakan *random forest* ini juga mendapatkan nilai evaluasi model yang optimal dengan nilai *macro average* dan *weighted average* dengan nilai *precision* 1.00, *recall* 1.00, *f1-score* 1.00 dan *support* 45. Serta nilai MSE dan RMSE di angka 0,0000. Keunggulan ini sangat penting dalam konteks pemodelan prediktif di mana ketepatan prediksi menjadi fokus utama, hal ini juga membuat *random forest* pada percobaan kali ini tidak lagi memerlukan bantuan *optimizer*.

Daftar Rujukan

- [1] H. Suhardiyanto, Teknologi Rumah Tanaman untuk Iklim Tropika Basah, Bogor: IPB Press, 2009. Na'am J., Harlan J., Madenda S., and Wibowo E. P. 2016. Identification of the Proximal Caries of Dental X-Ray Image with Multiple Morphology Gradient Method. *International Journal on Advanced Science, Engineering and Information Technology (IJASEIT)*, 6(3), pp. 343-346. doi:10.18517/ijaseit.6.3.827.
- [2] Muhammad Ali, Muliadi dkk, "Random Forest Dengan Random Search Terhadap Ketidakseimbangan Kelas Pada Prediksi Gagal Jantung" *Jurnal Informatika*, Vol.10 No.1 April 2023, Halaman 13-18.
- [3] Suci Amaliah, Muhammad Nusrang, Aswi, "Penerapan Metode Random Forest Untuk Klasifikasi Varian Minuman Kopi Di Kedai Kopi Konijiwa Bantaeng
- [4] Kumar, dkk "IoT enabled system to monitor and control greenhouse"
- [5] G. Singh, dkk "Formulation and validation of a mathematical model of the microclimate of a greenhouse, Renewable Energy"
- [6] T. K. Hariadi, "Sistem Pengendali Suhu, Kelembapan dan Cahaya Dalam Rumah Kaca," vol. 10, pp. 82-93, 2007.
- [7] Alvita, dkk, "Perbandingan Algoritma Random Forest, Naïve Bayes, Dan Decision Tree Dengan Oversampling Untuk Klasifikasi Bakteri E. Coli" Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA).
- [8] Vishnu Suresh, dkk "Forecasting Solar PV Output Using Convolutional Neural Networks with a SlidingWindow Algorithm".
- [9] I Wayan Suartika, dkk "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) pada Caltech 101".
- [10] Dewi, T., Rusdianasari, R., Kusumanto, R., & Siproni, S. (2022). Pengolahan citra Application on Automatic Fruit Detection for Agriculture Industry.

- [11] Indra dkk, "Implementasi Deep Learning Dengan Metode Convolutional Neural Network Untuk Identifikasi Objek Secara Real Time Berbasis Android".
- [12] Risma P., Dewi T., Oktarina Y., and Wijanarko Y., 2019. Neural Network Controller Application on a Visual based Object Tracking and Following Robot.
- [13] N. Hadianto, H. B. Novitasari, and A. Rahmawati, "Klasifikasi Pemijaman Nasabah Bank Menggunakan Metode Neural Network," *J. Pilar Nusa Mandiri*, vol. 15, no. 2, pp. 163–170, 2019, doi: 10.33480/pilar.v15i2.658.
- [14] R. Supriyadi, W. Gata, N. Maulidah, and A. Fauzi, "Penerapan Algoritma Random Forest Untuk Menentukan Kualitas Anggur Merah," *E-Bisnis J. Ilm. Ekon. dan Bisnis*, vol. 13, no. 2, pp. 67–75, 2020, doi: 10.51903/e-bisnis.v13i2.247.
- [15] S. Levantesi and G. Piscopo, "The importance of economic variables on London real estate market: A random forest approach," *Risks*, vol. 8, no. 4, pp. 1–17, 2020, doi: 10.3390/risks8040112
- [16] Larasati N., Dewi T., and Oktarina Y., 2017. Object Following Design for a Mobile Robot using Neural Network.
- [17] Lindawati, Andi Ramadhan, "Random Forest, Adaptive Boosting, and Multi-Layer Perceptron for Android Malware"
- [18] Dewi T., Risma P., Oktarina Y., and Roseno M.T., 2017. Neural Network Design for a Mobile Robot Navigation a Case Study.
- [19] Farooq U., Amar M., Asad M.U., Hanif A., and Saleh S.O., 2014. "Design and Implementation of Neural Network of Based Controller for Mobile Robot Navigation in Unknown Environment"
- [20] Perri, M. Simonetti, and O. Gervasi, "Synthetic data generation to speed-up the object recognition pipeline."
- [21] Yudha H. M., Dewi T., Hasana N., Risma P., Oktarina, Y. Kartini S., 2019, Performance Comparison of Fuzzy Logic and Neural Network Design for Mobile Robot Navigation
- [22] Vasilev, Ivan. 2019. Python Deep Learning: Exploring Deep Learning Techniques and Neural Network Architectures with PyTorch, Keras, and TensorFlow.
- [23] E. Wijaya, W. Swastika, and O. H. Kelana, "Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra XRay,"