



MODEL PREDIKSI KADAR AIR MEDIA TANAM MENGGUNAKAN ALGORITMA REGRESI DECISION TREE, SUPPORT VECTOR MACHINE, DAN RANDOM FOREST (STUDI KASUS GREENHOUSE CABAI RAWIT DI KEBUN EDUKASI EPTILU MITRA HABIBI GARDEN)

Hasani Abdulazizi Cahyadi^{1*}, Drupadi Ciptaningtyas², Lukito Hasta Pratopo³, Ahmad Thoriq⁴

Universitas Padjadjaran, Indonesia
E-mail : hasani19001@mail.unpad.ac.id

Kata Kunci

decision tree, cabai rawit, machine learning, random forest, kadar air tanah, support vector machine

Abstrak

Tanaman cabai rawit merupakan salah satu komoditas hortikultura yang umum ditemukan di Indonesia. Data BPS (2022) menunjukkan produksi cabai rawit mengalami peningkatan dari tahun 2018 sampai dengan tahun 2022, dengan laju pertumbuhan sebesar 15%. Produksi cabai rawit yang meningkat tidak menandakan permintaan pasar di Indonesia telah terpenuhi. Indonesia pada tahun 2022 bulan Januari sampai dengan September masih melakukan impor komoditas cabai dengan jumlah 35.962 ton. Permintaan pasar untuk komoditas cabai rawit masih belum terpenuhi dapat terjadi karena produksi cabai rawit masih belum maksimal. Tanaman cabai rawit rentan terhadap kekurangan air, di mana kekurangan air dapat menyebabkan melambatnya laju pertumbuhan tanaman cabai rawit dan penurunan dalam jumlah buah yang dihasilkan saat panen. Salah satu produsen tanaman cabai rawit adalah Kebun Edukasi Eptilu. Greenhouse cabai rawit di Kebun Edukasi Eptilu dapat mengalami penundaan penyiraman akibat sumber air sedang digunakan untuk menyirami kebun lain. Penundaan penyiraman dapat menyebabkan tanaman cabai rawit mengalami kekurangan air. Solusi yang dapat dikembangkan adalah membuat beberapa model algoritma prediksi kadar air tanah menggunakan machine learning dan membandingkan nilai akurasi dari masing-masing algoritma. Algoritma yang dibuat merupakan algoritma decision tree, support vector machine, dan random forest. Variabel bebas adalah suhu lingkungan (°C), kelembapan lingkungan (%), suhu tanah (°C), dan kadar air tanah (%). Variabel terikat adalah kadar air tanah (%) satu jam ke depan. Model dengan nilai akurasi tertinggi adalah model dengan algoritma Support Vector Regression (SVR) dengan kernel linear dan nilai epsilon (ϵ) 0.1, dengan nilai akurasi sebesar 0.938 pada data uji dan 0.958 pada data baru

Keywords

decision tree, chili pepper, machine learning, random forest, soil water content, support vector machine

Abstract

Chili pepper plants are one of the horticultural commodities commonly found in Indonesia. BPS data (2022) shows that chili pepper production has increased from 2018 to 2022, with a growth rate of 15%. The increasing production of chili pepper does not indicate that

market demand in Indonesia has been met. In 2022, from January to September, Indonesia will still import chili commodities totaling 35,962 tons. Market demand for chili pepper commodities is still not fulfilled, this could be because chili pepper production is still not optimal. Chili pepper plants are susceptible to water shortages, where lack of water can cause a slowdown in the growth rate of chili pepper plants and a decrease in the number of fruit produced at harvest. One of the chili pepper producers is Eptilu Education Garden. The chili pepper greenhouse at the Eptilu Education Garden may experience watering delays due to the water source being used to water another garden. Delaying watering can cause chili pepper plants to experience a lack of water. A solution that can be developed is to create several algorithm models for predicting soil water content using machine learning and comparing the accuracy values of each algorithm. The algorithms created are decision tree, support vector machine and random forest algorithms. The independent variables are greenhouse temperature ($^{\circ}\text{C}$), relative humidity (%), soil temperature ($^{\circ}\text{C}$), and soil water content (%). The dependent variable is soil water content (%) in the next hour. The model with the highest accuracy value is the model with the Support Vector Regression (SVR) algorithm with a linear kernel and an epsilon (ϵ) value of 0.1, with an accuracy value of 0.938 on test data and 0.958 on new data

**Correspondence Author: Hasani Abdulazizi Cahyadi
Email: hasani19001@mail.unpad.ac.id*



PENDAHULUAN

Cabai rawit (*Capsicum frutescens* L.) merupakan salah satu komoditas hortikultura yang umum ditemukan di Indonesia. Cabai rawit umum diperlukan dalam berbagai bidang, seperti bumbu masakan, industri makanan, obat-obatan dan lain-lain (Wisnujati & Siswati, 2021). Produksi cabai rawit di Indonesia mulai dari tahun 2018 sampai dengan tahun 2022 berturut-turut adalah 1,34 juta ton, 1,37 juta ton, 1,5 juta ton, 1,39 juta ton, dan 1,54 juta ton. Produksi cabai rawit di Indonesia selama lima tahun terakhir dengan laju 15% (BPS, 2022). Produksi cabai rawit yang meningkat tidak menandakan permintaan pasar di Indonesia telah terpenuhi. Indonesia pada tahun 2022 bulan Januari sampai dengan September masih melakukan impor komoditas cabai dengan jumlah 35.962 ton (Kementan, 2022). Hal tersebut menandakan Indonesia masih belum mampu memenuhi permintaan pasar pada komoditas cabai. Salah satu alasan hal tersebut terjadi adalah hasil panen kebun di Indonesia yang masih belum maksimal karena beberapa faktor, misalnya faktor pemberian air pada tanaman cabai yang masih kurang. Kekeringan pada tanaman cabai rawit memiliki dampak negatif pada pertumbuhan tanaman dan jumlah buah yang dihasilkan (Khan et al., 2008). Hasil panen yang maksimal dapat dicapai jika ketersediaan air bagi tanaman cabai rawit diperhatikan dengan baik.

Ketersediaan air bagi tanaman cabai rawit memiliki hubungan dengan kadar air tanah. Kurangnya air pada tanaman akan menyebabkan tanaman menutup stomata (Clarah et al., 2017). Stomata yang tertutup menyebabkan tanaman kesulitan melakukan proses fotosintesis akibat tidak mendapat CO_2 yang dibutuhkan dalam proses fotosintesis (Holding & Streich, 2013). Kadar air tanah yang terlalu tinggi pada tanaman cabai rawit juga berdampak negatif pada pertumbuhan

tanaman karena aerasi tanah yang buruk dan menghambat pertumbuhan akar. Kadar air tanah yang optimal pada tanaman cabai rawit adalah 60% - 80% (Wahjuni et al., 2022).

Tanaman cabai sensitif terhadap kekurangan air (Wahjuni et al., 2022). Berdasarkan hasil wawancara dengan karyawan greenhouse Kebun Edukasi Eptilu, diketahui bahwa greenhouse cabai melakukan penyiraman tanaman menggunakan sumber air yang sama dengan komoditas tanaman lain. Sumber air yang sama mengakibatkan greenhouse terkadang harus menunda proses penyiraman akibat kurangnya air yang masuk ke dalam sistem irigasi greenhouse. Penundaan penyiraman dapat membuat kadar air tanah tanaman cabai rawit berkurang sampai menjadi terlalu rendah dan berdampak buruk bagi pertumbuhan tanaman. Tanaman cabai rawit yang terganggu pertumbuhannya dapat menyebabkan hasil panen cabai rawit yang tidak maksimal. Solusi yang dapat dikembangkan untuk mengatasi masalah ini adalah membuat model prediksi kadar air tanah untuk keputusan penyiraman tanaman (Dwiyatno et al., 2022).

Kebun Edukasi Eptilu mengelola greenhouse tanaman cabai rawit dengan bantuan alat dari perusahaan Habibi Garden. Habibi Garden merupakan perusahaan start-up yang berfokus pada teknologi pertanian berbasis Internet of Things (IoT). Salah satu teknologi yang diterapkan di greenhouse Kebun Edukasi Eptilu adalah alat bernama HabibiClimate Pro. HabibiClimate Pro merupakan alat yang mampu menyediakan data kondisi lingkungan greenhouse setiap menit menggunakan sensor. Data sensor yang dihasilkan antara lain suhu udara ($^{\circ}\text{C}$), suhu tanah ($^{\circ}\text{C}$), kelembapan relatif udara (%), kadar air tanah (%), dan lain-lain. Data kondisi lingkungan greenhouse yang ada dapat digunakan untuk membuat model prediksi kadar air tanah untuk keputusan penyiraman.

Model prediksi kadar air tanah dapat dibuat menggunakan machine learning. Penerapan machine learning dapat menjadi solusi karena komputer dapat mempelajari suatu data tanpa perlu diprogram secara eksplisit (Fani, 2023). Model prediksi dapat dibuat menggunakan algoritma regresi karena analisis regresi umum digunakan untuk membuat prediksi suatu variabel terikat dari variabel-variabel bebas yang disediakan. Algoritma regresi yang dapat digunakan untuk membuat model prediksi antara lain Decision Tree Regression (DTR), Support Vector Regression (SVR), dan Random Forest Regression (RFR).

Pembuatan model prediksi kadar air tanah telah dilakukan sebelumnya menggunakan algoritma machine learning yaitu K-Nearest Neighbors (KNN). Model prediksi kadar air tanah menggunakan KNN dengan jumlah neighbors (k) 7 menghasilkan nilai koefisien determinasi (R^2) tertinggi yaitu 70,3% (di Serenity Farm & Garden, n.d.). Nilai R^2 menggunakan KNN pada data baru belum masuk ke kategori prediksi model yang cukup presisi yaitu di rentang 0.81 – 0.90 (Man et al., 2022). Upaya membuat dan membandingkan model prediksi kadar air tanah menggunakan tiga model regresi dilakukan dengan harapan diketahui model regresi dengan nilai koefisien determinasi (R^2) tertinggi dari ketiga model dan masuk ke rentang cukup presisi yaitu di atas 0.81.

METODE PENELITIAN

Alat yang digunakan pada penelitian ini adalah smartphone (Samsung A14, Samsung, Indonesia) untuk dokumentasi, laptop (HP, China) untuk mengolah data dan modelling, software Visual Studio Code (Microsoft (versi 1.82.2)) sebagai aplikasi kode editor dan menjalankan program, Google Colab (Python versi 3.6.9), dan software Microsoft Excel (Microsoft Corporation, Redmond, USA (Versi 2010) untuk mengolah dataset dan menghitung nilai validasi. Bahan yang digunakan sebagai objek penelitian adalah cabai rawit dan data sensor lingkungan.

Prosedur Penelitian

1. Persiapan data-data yang diperlukan

Persiapan data dilakukan untuk memenuhi kriteria model yaitu menghasilkan nilai prediksi kadar air tanah (%) dan keputusan penyiraman 1 jam berikutnya. Nilai prediksi kadar air tanah dipengaruhi oleh data suhu lingkungan ($^{\circ}\text{C}$), suhu tanah ($^{\circ}\text{C}$), kelembapan relatif udara (%), dan kadar air tanah (%) 1 jam sebelumnya. Detail variabel disajikan pada tabel 1.

Tabel 1. Penentuan variabel bebas dan terikat model

Variabel Bebas (Data 1 Jam Sebelumnya)		Variabel Terikat
No	Parameter	
1	Suhu lingkungan (°C)	Prediksi kadar air tanah (%) 1 jam berikutnya
2	Kelembaban (%)	
3	Suhu tanah (°C)	
4	Kadar air tanah (%)	

2. Pembersihan data

Pembersihan data dilakukan untuk menghilangkan nilai error. Nilai error yang umum terdapat pada data sensor lingkungan adalah nilai 0. Nilai 0 menandakan alat sedang dinonaktifkan sehingga sensor lingkungan tidak aktif. Pembersihan data dilakukan dengan cara melakukan imputasi pada seluruh data dengan nilai error dengan cara interpolasi linear pada data.

3. Pembuatan model prediksi kadar air tanah menggunakan algoritma *Decision Tree Regression*, *Support Vector Regression*, dan *Random Forest Regression*

Pembuatan model dilakukan menggunakan bahasa pemrograman Python pada web IDE Google Colab. Algoritma yang digunakan antara lain adalah DTR, SVR, dan RFR. Variabel terikat dari data sensor lingkungan adalah kadar air tanah 1 jam berikutnya (%). Variabel bebas dari data sensor antara lain suhu udara (°C), kelembaban relatif udara (%), suhu tanah (°C), dan kadar air tanah (%) 1 jam sebelumnya. Proses pembuatan model dilakukan melalui beberapa tahap. Tahap pertama adalah pembagian dataset bulan Agustus sampai dengan Oktober menjadi 80% data latih dan 20% data uji. Tahap kedua adalah pelatihan model. Model dibuat dan dilatih dengan variasi parameter yang berbeda sesuai dengan ketentuan. Setiap variasi model yang sudah dilatih kemudian dihitung nilai R²-nya menggunakan data uji. Tahap ketiga adalah evaluasi model. Evaluasi model dilakukan dengan cara model memprediksi data baru dan dihitung nilai R²-nya. Model akan dianggap berhasil jika nilai R² pada data uji dan data baru berada di atas batas minimum yaitu 0.81

Pada algoritma DTR, model dilatih dengan kombinasi variasi parameter utama, yaitu *criterion* dan *max depth*. Parameter *criterion* memiliki dua variasi, yaitu MSE dan MAE. Parameter *max depth* digunakan dalam rentang 1-20. Terdapat total 40 variasi model yang akan dihasilkan menggunakan algoritma DTR.

Pada algoritma SVR, model dilatih dengan kombinasi variasi parameter utama, yaitu *kernel*, nilai *C*, dan nilai ϵ . Parameter *kernel* memiliki dua variasi, yaitu *kernel linear* dan *RBF*. Parameter *C* memiliki empat variasi, yaitu 0.1, 1, 10, dan 100. Parameter ϵ memiliki empat variasi, yaitu 0.01, 0.1, 0.5, dan 1. Terdapat total 32 variasi model yang akan dihasilkan menggunakan algoritma SVR.

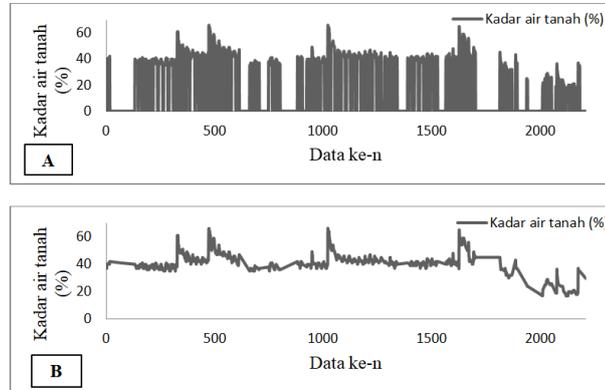
Pada algoritma RFR, model dilatih dengan kombinasi variasi parameter utama, yaitu *criterion*, *max depth*, dan jumlah pohon. Parameter *criterion* memiliki dua variasi, yaitu *criterion MSE* dan *MAE*. Parameter *max depth* digunakan dalam rentang 1-20. Parameter jumlah pohon digunakan dalam rentang 1-50. Terdapat total 2000 variasi model yang akan dihasilkan menggunakan algoritma RFR.

HASIL DAN PEMBAHASAN

Karakteristik Dataset

Data yang diolah menjadi dataset awal untuk melatih dan menguji model machine learning merupakan data parameter greenhouse setiap menit selama 24 jam selama 3 bulan, yaitu bulan Agustus sampai dengan Oktober. Data baru yang belum pernah digunakan pada model untuk menguji keakuratan model adalah dataset pada bulan November yang mengandung baris data sebanyak 30 hari dikalikan dengan 24 jam, yaitu 720 baris data. Imputasi pada dataset dilakukan untuk menghilangkan semua nilai error pada dataset. Terdapat 1148 baris data yang masih memiliki nilai error pada dataset awal dan terdapat 437 baris data yang mengandung nilai error

pada data baru. Dataset yang diimputasi dapat menghasilkan model prediksi kadar air tanah pada satu jam ke depan yang lebih akurat jika dibandingkan dengan model yang dibuat menggunakan dataset yang tidak diimputasi (di Serenity Farm & Garden, n.d.). Grafik data real dan data hasil imputasi disajikan dalam gambar 1.



Gambar 1. Grafik data *real* (A) dan data hasil imputasi (B) kadar air tanah (%)

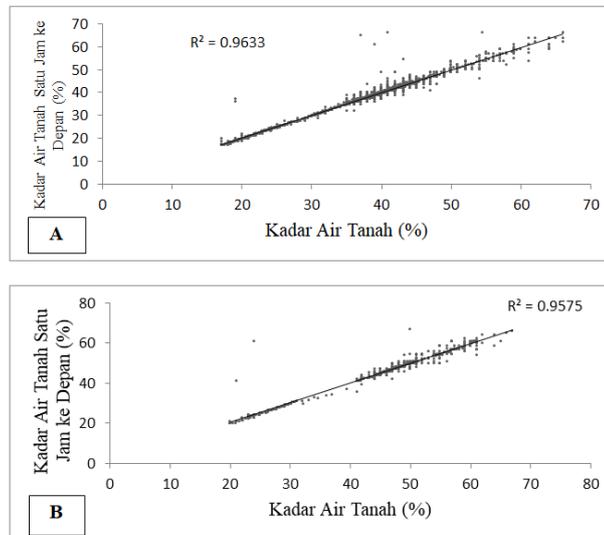
Karakteristik selanjutnya yang perlu diketahui adalah outlier. Data outlier merupakan data yang berada di luar interquartile range. Pada dataset awal dan data baru, interquartile range dihitung pada setiap parameter agar dapat diketahui nilai-nilai outlier yang ada pada dataset. Pada dataset awal, parameter suhu lingkungan dan suhu tanah tidak memiliki outlier. Parameter kelembapan pada dataset awal memiliki 14 outlier. Parameter kadar air tanah dan kadar air tanah satu jam ke depan pada dataset awal masing-masing memiliki 334 outlier. Total outlier pada dataset awal adalah 682 data. Pada data baru, parameter kelembapan dan suhu tanah tidak memiliki outlier. Parameter suhu pada data baru memiliki 21 outlier. Parameter kadar air dan kadar air pada satu jam ke depan pada data baru masing-masing memiliki 140 outlier. Total outlier pada data baru adalah 301. Berikut adalah data jumlah outlier pada dataset awal dan data baru. Data jumlah outlier pada dataset awal dan data baru disajikan pada tabel 2.

Tabel 2. Data Jumlah Outlier pada Dataset Awal dan Baru

Parameter	Jumlah Outliers	
	Dataset Awal	Data Baru
Suhu Lingkungan	0	21
Kelembapan	14	0
Suhu Tanah	0	0
Kadar Air	334	140
Kadar Air Satu Jam ke Depan	334	140
Total	682	301

Dataset awal dan data baru mengandung 4 variabel independen dan 1 variabel dependen. 4 variabel independen tersebut antara lain suhu lingkungan, kelembapan, suhu tanah, dan kadar air. Variabel dependen pada data adalah kadar air satu jam ke depan. Setiap variabel independen perlu diketahui apakah ada hubungan linear terhadap variabel dependen. Hubungan linear antar parameter dapat diketahui menggunakan fungsi regresi linear antara variabel independen dan variabel dependen dan dinilai berdasarkan nilai koefisien determinasinya (R^2). Pada dataset awal dan data baru, tidak terdapat hubungan linear antara suhu lingkungan, kelembapan, dan suhu tanah dengan kadar air tanah satu jam ke depan. Pada dataset awal dan data baru, hubungan linear hanya terdapat pada parameter kadar air dengan kadar air satu jam ke depan. Pada dataset awal,

nilai R² untuk kadar air tanah dan kadar air tanah satu jam ke depan adalah 0.963, sedangkan pada data baru nilainya 0.960.



Gambar 2. Grafik hubungan linear dalam dataset awal (A) dan data baru (B) pada kadar air tanah dan kadar air tanah satu jam ke depan.

Model Prediksi Kadar Air Tanah dengan Algoritma DTR

Pada algoritma DTR, terdapat dua parameter utama, yaitu *criterion* dan *max depth*. Berdasarkan hasil prediksi, kombinasi parameter *criterion* MAE dan *max depth* 5 menghasilkan model dengan nilai akurasi tertinggi pada data uji dan data baru, yaitu 0.936 dan 0.948. *Criterion* MAE memiliki nilai akurasi lebih tinggi daripada MSE. Hal tersebut dapat terjadi karena adanya data *outlier* yang terkandung pada dataset yang digunakan. MAE lebih tidak sensitif terhadap data *outlier* sehingga *criterion* MSE menghasilkan model dapat menghasilkan yang lebih sesuai pada data training dan akurasi yang tinggi pada data uji, namun model kurang menggeneralisasi jika dibandingkan dengan model *criterion* MAE (Jadon et al., 2024). Data akurasi prediksi menggunakan algoritma DTR disajikan dalam tabel 3.

Tabel 3. Data Akurasi Prediksi Algoritma DTR

Max Depth	Akurasi (R ²)			
	MSE		MAE	
	Data Uji	Data Baru	Data Uji	Data Baru
1	0.569	0.249	0.555	0.116
2	0.807	0.775	0.746	0.571
3	0.893	0.916	0.898	0.879
4	0.929	0.944	0.928	0.921
5	0.922	0.938	0.936	0.948

Model Prediksi Kadar Air Tanah dengan Algoritma SVR

Pada algoritma SVR, terdapat tiga parameter utama, yaitu kernel, parameter regularisasi (C), dan epsilon (ε). Berdasarkan hasil prediksi, kombinasi parameter kernel linear dan nilai ε 0.1 yang mampu menghasilkan nilai akurasi tertinggi pada data uji dan data baru, yaitu sebesar 0.938 pada data uji dan 0.958 pada data baru. Model dengan kernel linear memiliki nilai rata-rata akurasi lebih tinggi daripada kernel RBF. Hal tersebut dapat terjadi karena adanya hubungan linear parameter yang terkandung dalam dataset yang digunakan (Annas et al., 2023), yaitu hubungan antara kadar air tanah dan kadar air tanah satu jam ke depan. Pada parameter ε, nilai ε dengan rata-rata akurasi tertinggi adalah 0.1. Parameter ε dengan nilai 1 menghasilkan nilai rata-rata akurasi terendah. nilai ε yang tinggi dapat menghasilkan overfitting pada model akibat banyaknya

nilai error yang masuk ke dalam ϵ -tube, sedangkan semakin kecil nilai ϵ maka nilai error yang masuk ke dalam ϵ -tube lebih sedikit sehingga dapat membuat model yang akurat pada data uji dan data baru (Awad & Khanna, 2015). Data akurasi prediksi menggunakan algoritma DTR disajikan dalam tabel 4.

Tabel 4. Data Akurasi Prediksi Algoritma SVR

C	ϵ	Akurasi (R^2)			
		Linear		RBF	
		Data Uji	Data Baru	Data Uji	Data Baru
0.1	0.01	0.938	0.957	0.919	0.922
1	0.01	0.938	0.957	0.940	0.957
100	0.01	0.938	0.957	0.936	0.952
0.1	0.1	0.938	0.958	0.917	0.922
1	0.1	0.938	0.958	0.937	0.957
10	0.1	0.938	0.958	0.935	0.954
100	0.1	0.938	0.958	0.934	0.952

Model Prediksi Kadar Air Tanah dengan Algoritma RFR

Pada algoritma RFR, terdapat tiga parameter utama, yaitu *criterion*, *max depth*, dan jumlah pohon. Berdasarkan hasil prediksi, kombinasi parameter *criterion* MAE, *max depth* 5, dan jumlah pohon 32 menghasilkan model dengan akurasi tertinggi pada data uji dan data baru, yaitu sebesar 0.940 pada data uji dan 0.953 pada data baru. Model dengan *max depth* 5 menghasilkan nilai rata-rata akurasi tertinggi pada data uji dan data baru untuk setiap *criterion*. Model dengan *max depth* 1 gagal menghasilkan model dengan nilai akurasi di atas batas minimum pada kedua *criterion*. Model dengan *max depth* yang rendah dapat mengalami *underfitting*, yaitu model gagal dalam menangkap hubungan yang ada dalam data sehingga menghasilkan prediksi yang tidak akurat (Assegie & Elaraby, 2023). *Criterion* MAE menghasilkan nilai akurasi lebih tinggi daripada MSE, karena adanya data *outlier* yang terkandung dalam dataset yang digunakan (Jadon et al., 2024). Data akurasi prediksi menggunakan algoritma RFR disajikan dalam tabel 5.

Tabel 5. Data Akurasi Prediksi Algoritma RFR

Criterion	Max depth	Jumlah Pohon	Akurasi	
			Data Uji	Data Baru
MAE	5	32	0.940	0.953
	5	47	0.939	0.953
	5	19	0.937	0.953
	1	18	0.561	0.104
	1	1	0.552	0.097
MSE	5	34	0.935	0.952
	5	31	0.934	0.952
	5	14	0.933	0.951

KESIMPULAN

Algoritma SVR dengan parameter kernel linear dan ϵ bernilai 0.1 menghasilkan nilai akurasi prediksi tertinggi untuk memprediksi kadar air tanah pada satu jam ke depan jika dibandingkan dengan algoritma DTR dan RFR, dengan nilai akurasi prediksi tertinggi sebesar 0.938 pada data uji dan 0.958 pada data baru. Algoritma DTR yang menggunakan parameter *criterion* MAE dan *max depth* 5 menghasilkan nilai akurasi prediksi tertinggi pada algoritma tersebut, yaitu sebesar 0.936 pada data uji dan 0.948 pada data baru. Algoritma RFR yang menggunakan parameter *criterion* MAE dan *max depth* 5 menghasilkan nilai akurasi prediksi tertinggi pada algoritma tersebut, yaitu sebesar 0.939 pada data uji dan 0.953 pada data baru.

Saran untuk penelitian selanjutnya yaitu penambahan parameter yang digunakan serta jumlah variasi dari parameter untuk menghasilkan model regresi dengan nilai akurasi yang lebih tinggi. Optimasi model dapat dilakukan dengan mencoba pengukuran data historis lingkungan secara terkontrol sehingga mencegah dan meminimalisir data yang hilang.

REFERENSI

- Annas, S., Rais, Z., & Aswi, A. (2023). Implementation of Support Vector Regression (SVR) Analysis in Predicting Gold Prices in Indonesia. *5th International Conference on Statistics, Mathematics, Teaching, and Research 2023 (ICSMTR 2023)*, 97–107.
- Assegie, T. A., & Elaraby, A. (2023). Optimal tree depth in decision tree classifiers for predicting heart failure mortality. *Healthcraft Front*, 1(1), 58–66.
- Awad, M., & Khanna, R. (2015). *Efficient learning machines: theories, concepts, and applications for engineers and system designers*. Springer nature.
- Clarah, S., Hastuti, R. B., & Darmanti, S. (2017). Pengaruh pupuk nanosilika terhadap pertumbuhan, ukuran stomata dan kandungan klorofil cabai rawit (*Capsicum frutescens* Linn) varietas cakra hijau. *Jurnal Akademika Biologi*, 6(2), 26–33.
- di Serenity Farm, K. T. B., & Garden, M. H. (n.d.). *Model Prediksi Kadar Air Media Tanam Menggunakan Regresi Linear Berganda (Studi Kasus)*.
- Dwiyatno, S., Krisnaningsih, E., & Hidayat, D. R. (2022). S Smart Agriculture Monitoring Penyiraman Tanaman Berbasis Internet Of Things. *PROSISKO: Jurnal Pengembangan Riset Dan Observasi Sistem Komputer*, 9(1), 38–43.
- Fani, K. (2023). *Estimasi Biomassa Tanaman Nanas Berdasarkan Lebar Daun Menggunakan Algoritma Machine Learning*.
- Holding, D. R., & Streich, A. M. (2013). Plant growth processes: transpiration, photosynthesis, and respiration. *The Board of Regents of the University of Nebraska*, 1–10.
- Jadon, A., Patil, A., & Jadon, S. (2024). A Comprehensive Survey of Regression-Based Loss Functions for Time Series Forecasting. *International Conference on Data Management, Analytics & Innovation*, 117–147.
- Khan, M. A. I., Farooque, A. M., Haque, M. A., Rahim, M. A., & Hoque, M. A. (2008). Effects of water stress at various growth stages on the physio-morphological characters and yield in chilli. *Bangladesh Journal of Agricultural Research*, 33(3), 353–362.
- Man, A., Chaichana, C., Wicharuck, S., & Rinchumphu, D. (2022). Predicting sunlight availability for vertical shelves using simulation. *IOP Conference Series: Earth and Environmental Science*, 1094(1), 12011.
- Wahjuni, S., Wulandari, W., & Kholili, M. (2022). Development of Fuzzy-Based Smart Drip Irrigation System for Chili Cultivation. *JUITA: Jurnal Informatika*, 10(1), 115–125.

Wisnujati, N. S., & Siswati, E. (2021). Analisis produksi dan produktivitas cabai rawit (*Capsicum frutescens* L) di Indonesia. *Jurnal Ilmiah Sosio Agribis*, 21(1).



© 2024 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY SA) license (<https://creativecommons.org/licenses/by-sa/4.0/>).