

Estimasi Evapotranspirasi Potensial Menggunakan Algoritma *Random Forest* di Daerah Irigasi Tungkub, Bali

Estimation of Potential Evapotranspiration Using Random Forest Algorithm in the Tungkub Irrigation Area, Bali

Luh Made Putri Apriliani, Ni Nyoman Sulastri*, I Wayan Widia, I Putu Gede Budisanjaya

Program Studi Teknik Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Universitas Udayana, Badung, Bali, Indonesia.

*email: sulastri@unud.ac.id

Abstrak

Besaran nilai Evapotranspirasi Potensial (ETp) sangat diperlukan untuk perencanaan distribusi air dan pola tanam. Umumnya, perhitungan ETp diperoleh dari perhitungan model empiris, seperti model *Penman Monteith* (PM) yang direkomendasikan oleh *Food and Agriculture Organization* (FAO). Namun, penerapan model ini memerlukan variabel cuaca yang banyak dan ketersediaan data cuaca yang tidak memadai. Tujuan penelitian ini adalah menghasilkan model estimasi ETp dengan algoritma *Random Forest* (RF). Variabel cuaca yang digunakan pada penelitian ini yang dijadikan input dalam pemodelan ETp yaitu (1) radiasi matahari (R_s); (2) suhu udara (T); (3) kelembaban udara (RH); (4) dan kombinasi R_s dan T . Data variabel cuaca diperoleh dari *automatic weather station* (AWS) di Daerah Irigasi (DI) Tungkub, Bali. Hasil penelitian menunjukkan masukan variabel cuaca R_s merupakan model estimasi terbaik, sedangkan masukan variabel cuaca RH merupakan model estimasi terlemah. Pada kalibrasi model terdapat tiga metrik evaluasi untuk mengevaluasi kinerja model yaitu R^2 , MSE, dan RMSE. Sementara pada validasi model menggunakan tiga teknik yaitu *prediction error plot*, *residuals plot*, dan *k-fold CV*. Hasil penelitian menunjukkan estimasi nilai ETp rata-rata dengan skenario masukan R_s menggunakan algoritma RF di DI Tungkub 0,14 mm/jam ($R^2 = 1,00$, MSE = 0,00, RMSE = 0,01). Sementara itu, nilai rata-rata ETp PM yaitu 0,15 mm/jam. Skenario masukan R_s menggunakan algoritma RF menunjukan estimasi nilai yang mendekati nilai ETp PM.

Kata kunci: *evapotranspirasi potensial, machine learning, random forest, variabel cuaca*

Abstract

The estimation of Potential Evapotranspiration (ETp) is crucial for water distribution planning and cropping patterns. Generally, ETp calculation is obtained from empirical models such as the Penman-Monteith (PM) model recommended by the Food and Agriculture Organization (FAO). However, implementing this model requires numerous weather variables and adequate weather data availability. This research aims to develop an ETp estimation model using the Random Forest (RF) algorithm. The weather variables used in this research as inputs for ETp modeling are solar radiation (R_s); air temperature (T); air humidity (RH); and a combination of R_s and T . Weather variable data were obtained from an automatic weather station (AWS) in the Tungkub Irrigation Area, Bali. The research results indicate that the weather variable R_s is the best estimation model input, while the weather variable RH is the weakest. In model calibration, three evaluation metrics were used to assess model performance, R^2 , MSE, and RMSE. Meanwhile, for model validation, three techniques were employed, *prediction error plot*, *residuals plot*, and *k-fold cross-validation*. The research results indicate that the average ETp estimation value with the scenario of input R_s using the RF algorithm in the Tungkub Irrigation Area is 0,14 mm/hour ($R^2 = 1,00$, MSE = 0,00, RMSE = 0,01). Meanwhile, the average ETp PM value is 0,15 mm/hour. The scenario of input R_s using the RF algorithm shows estimation values close to the PM ETp value.

Keywords: *machine learning, potential evapotranspiration, random forest, weather variabel*

PENDAHULUAN

Evapotranspirasi (ET) telah menjadi fokus penting dalam bidang hidrologi, pertanian, dan perubahan iklim (Ajjur & Al-Ghamdi, 2021). Dalam bidang hidrologi, ET telah menjadi peranan penting dalam keseimbangan siklus hidrologi dan neraca air (Pino-

Vargas et al., 2022; Supangat, 2016; Tanny, 2022). Pada bidang pertanian, ET memiliki peranan dalam perancangan dan pengelolaan sistem irigasi, produktivitas pertanian, serta estimasi kebutuhan air tanaman (Dinpashoh et al., 2019; Lotfi et al., 2020). Selain itu, perubahan iklim juga mempengaruhi proses ET seperti kenaikan suhu udara yang

fluktuatif (Supangat, 2016). Proses ET ini dibedakan menjadi tiga (3) yaitu Evapotranspirasi Potensial (ETp), Evapotranspirasi Standar (ETo), dan Evapotranspirasi Tanaman (ETc). ETp merupakan suatu proses penguapan air dari permukaan melalui proses evaporasi dan transpirasi berdasarkan kondisi variabel cuaca (Allen et al., 1998). Salah satu model untuk perhitungan ETp yaitu model empiris *Penman Monteith* (PM). Model PM merupakan model baku yang direkomendasikan oleh *Food and Agriculture Organization* (FAO) (Allen et al., 1998). Namun, perhitungan menggunakan model ini hanya memungkinkan jika data variabel cuaca tersedia secara lengkap (Saidah et al., 2020). Kompleksnya variabel cuaca yang digunakan menyebabkan penerapan model ini belum sepenuhnya diaplikasikan di Indonesia. Maka dari itu, model ETp dengan masukan variabel cuaca terbatas diperlukan untuk memperoleh hasil perhitungan ETp yang akurat seperti model PM (Saidah et al., 2020).

Perhitungan ETp yang akurat seperti standar baku sangat penting untuk merencanakan sumber daya air dan mengelola irigasi pertanian. Perencanaan ini memerlukan ketersediaan data variabel cuaca yang kontinyu dan lengkap di masa depan. Namun, ketersediaan stasiun pengamatan cuaca yang mampu mengamati perubahan variabel cuaca secara lengkap dan kontinyu masih terbatas (Runtuwuwu et al., 2008). Oleh karena itu, estimasi ETp selama berbagai periode merupakan hal yang sangat penting karena keterbatasan data cuaca di masa depan (Abedi-Koupai et al., 2022). Salah satu metode yang dapat digunakan untuk estimasi ETp yaitu *Machine Learning* (ML).

Penerapan ML telah banyak diaplikasikan dalam pengembangan model ETp. ML merupakan bidang studi yang memberikan komputer kemampuan untuk belajar tanpa diprogram secara eksplisit (Horvitz & Mulligan, 2015). Algoritma ML telah menjadi metode yang baik untuk menghasilkan estimasi yang akurat (Granata, 2019). Salah satu algoritma ML adalah algoritma *Random Forest* (RF). Algoritma RF dapat digunakan untuk klasifikasi dan regresi yang menggunakan pohon keputusan (*decision tree*) dengan pengambilan sampel secara acak. Algoritma ini dapat menghasilkan akurasi yang lebih tinggi daripada model regresi yang lebih sederhana, karena menggabungkan prediksi dari pohon keputusan yang berbeda (Nur et al., 2023). Algoritma RF ini juga dapat mengatasi kompleksitas antara variabel cuaca yang mempengaruhi nilai ETp. Algoritma RF ini telah digunakan untuk estimasi ETp di *Yellow River Basin* (Liu et al., 2022). Penerapan algoritma ML yaitu algoritma RF dengan masukan variabel cuaca yang terbatas untuk mengestimasi ETp di Indonesia

relatif rendah. Penelitian ini menerapkan algoritma RF untuk mengestimasi ETp menggunakan masukan variabel cuaca yang terbatas. Algoritma RF digunakan sebagai metode yang digunakan untuk estimasi ETp. Estimasi ETp dengan masukan variabel cuaca terbatas diharapkan dapat memperoleh hasil perhitungan yang akurat seperti model PM. Dengan adanya estimasi ini, diharapkan dapat membantu dalam perencanaan distribusi air dan perencanaan pola tanam dengan menggunakan data variabel cuaca yang terbatas.

METODE

Tempat dan Waktu penelitian

Penelitian ini dilaksanakan di Laboratorium Pengelolaan Sumber Daya Alam, Fakultas Teknologi Pertanian, Universitas Udayana, Kampus Sudirman dan Kantor Pengamat Tukad Yeh Sungai, Daerah Irigasi Tungkub, Mengwi, Badung, Bali. Pelaksanaan penelitian ini dilakukan pada bulan November 2023 sampai dengan bulan April 2024.

Bahan dan Alat

Bahan dan alat yang digunakan pada penelitian ini terbagi menjadi dua, yaitu perangkat lunak dan perangkat keras. Perangkat lunak yang digunakan meliputi *google colab*, *python version 3.8*, *numpy*, *pandas*, *matplotlib*, *seaborn*, *scikit-learn*, *joblib*, *microsoft excel*, *github*, dan *HOBOWare*. Perangkat keras yang digunakan terdiri dari sensor variabel cuaca dengan spesifikasi *HOBOWare*. Sensor tersebut meliputi, sensor radiasi matahari, suhu udara, kelembaban udara, kecepatan dan arah angin.

Pelaksanaan Penelitian

Penelitian ini dilakukan dalam beberapa tahapan, yaitu pengumpulan data, *Exploratory Data Analysis* (EDA), pra-pemrosesan data, pelatihan model dengan algoritma RF, kalibrasi, dan validasi model. Data yang digunakan untuk estimasi ETp diperoleh dari *Automatic Weather Station* (AWS) yang terletak di Kantor Pengamat Tukad Yeh Sungai, Daerah Irigasi Tungkub, Mengwi, Badung, Bali. Tahapan EDA dilakukan untuk menganalisis data untuk memahami karakteristik, pola, dan mendeteksi *outlier* (Orji & Ukwandu, 2024). Tahapan selanjutnya yaitu pembersihan data, tahapan ini akan membersihkan data dari potensi masalah seperti nilai data yang hilang dan nilai *outlier*. Secara umum, proses pembersihan data dapat dibagi dalam tiga tahapan, yaitu *define*, *code*, dan *test*. Tahapan selanjutnya yaitu pemisahan data fitur dan target. Data fitur merupakan variabel independen yang digunakan sebagai *input*, sedangkan data target merupakan variabel dependen yang digunakan sebagai nilai target atau *output*. Pada data fitur terdapat empat

skenario masukan yang berbeda, dapat dilihat pada Tabel 1. Sedangkan data target diperoleh dari hasil perhitungan *latent heat flux* (LE) berdasarkan model PM (Fereses & Villalobos, 2016). Hasil perhitungan

LE kemudian dikonversi menjadi nilai ETp PM. Tahapan selanjutnya yaitu pembagian data latih dan data uji dilakukan dengan perbandingan 70:30.

Tabel 1. Skenario masukan variabel cuaca untuk pembangunan model

Skenario masukan	Variabel cuaca
Skenario 1	Rs
Skenario 2	T
Skenario 3	RH
Skenario 4	Rs dan T

Kalibrasi

Pengukuran kinerja model merupakan langkah penting dalam mengevaluasi model untuk memastikan bahwa model tersebut efektif dalam melakukan estimasi atau perkiraan yang akurat. Kalibrasi model dilakukan menggunakan tiga metrik evaluasi yaitu *R-squared* (R^2), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE).

Validasi Model

Validasi model dilakukan dengan tiga teknik yaitu *prediction error plot*, *residuals plot*, dan *k-fold CV*. Teknik-teknik validasi model ini digunakan untuk meningkatkan keyakinan terhadap keakuratan dan kehandalan estimasi yang diberikan oleh model. *Prediction error plot* merupakan visualisasi yang digunakan untuk membandingkan nilai target aktual dengan nilai yang diprediksi oleh model (Bengfort & Bilbro, 2019; Sofos & Karakasidis, 2021). *Residuals Plot* merupakan visualisasi hubungan kesalahan pada data latih dan data uji, serta menunjukkan variabilitas yang meningkat dalam model estimasi (Bengfort & Bilbro, 2019). Penerapan teknik *K-fold CV* dalam evaluasi model menggunakan *library Scikit-learn* dengan nilai k yang ditetapkan yaitu 10. Dataset akan dibagi menjadi 10 lipatan yang sama besar.

titik-titik pada grafik menyimpang dari garis tren (Yong et al., 2023).

Variabel cuaca Rs memiliki hubungan linear dan korelasi *pearson* yang paling kuat diantara parameter lainnya. Hal tersebut ditunjukkan dengan sebaran titik-titik pada grafik sejajar dengan garis diagonal dan koefisien korelasi 0,99. Hasil tersebut didukung oleh hasil penelitian lain yang menunjukkan Rs merupakan variabel cuaca yang berpengaruh besar terhadap nilai ETp (Arif et al., 2020; Bayram & Çitakoğlu, 2023; Ge et al., 2022; Yong et al., 2023).

Variabel cuaca T dan RH memiliki hubungan linier dan koefisien korelasi *pearson* yang relatif sama. Hal tersebut ditunjukkan dengan koefisien korelasi *pearson* yaitu 0,77, namun RH memiliki korelasi dan hubungan negatif terhadap ETp PM. Variabel cuaca T memiliki hubungan linier dan korelasi yang berbanding terbalik dengan RH. Korelasi negatif antara variabel cuaca RH dan nilai ETp juga didukung oleh penelitian lainnya (Arif et al., 2020; Ge et al., 2022). Hal tersebut disebabkan karena T dan RH merupakan variabel cuaca yang terkait langsung dalam kondisi tekanan atmosfer (Arif et al., 2020).

Variabel cuaca u memiliki hubungan linier dan koefisien korelasi *pearson* terlemah terhadap nilai ETp PM. Hal tersebut ditunjukkan dengan sebaran titik-titik pada grafik tidak sejajar dengan garis diagonal dan koefisien korelasi *pearson* yaitu 0,53. Hasil tersebut relatif sama dengan penelitian lainnya yang menunjukkan bahwa variabel cuaca u memiliki hubungan dan korelasi yang lemah terhadap nilai ETp (Ge et al., 2022). Hal tersebut disebabkan karena hubungan u tidak signifikan dalam perubahan nilai ETp, namun apabila variabel cuaca lainnya dan u dikombinasikan dapat mengubah nilai ETp secara signifikan (Adib et al., 2023).

Hasil hubungan variabel cuaca terhadap ETp PM konsisten dengan penelitian sebelumnya. ETp berkorelasi negatif dengan RH dan berkorelasi positif dengan variabel cuaca lainnya, yaitu Rs, T, dan u (Gao et al., 2017).

HASIL DAN PEMBAHASAN


Hubungan antara Variabel Cuaca dengan ETp PM

Variabel cuaca yang diamati dalam penelitian ini meliputi Rs, T, RH, dan kecepatan angin (u). Parameter ini diamati untuk memahami hubungannya dengan ETp PM. Selain itu, pemilihan variabel cuaca yang tepat sangat berpengaruh dalam estimasi ETp yang akurat (Yong et al., 2023)

Tabel 2 menampilkan koefisien korelasi *pearson* dan Gambar 1 mengilustrasikan hubungan linier variabel cuaca terhadap nilai ETp PM. Hubungan linier yang baik ditunjukkan dengan sebaran titik-titik pada grafik sejajar dengan garis tren diagonal, sementara hubungan yang buruk ditunjukkan ketika sebaran

Tabel 2. koefisien korelasi pearson antara variabel cuaca dan nilai ETp PM

Variabel cuaca	Korelasi Pearson
Rs	0,99
T	0,77
RH	-0,77
u	0,53



Gambar 1. Perbandingan hubungan linier antara variabel cuaca terhadap nilai ETp PM; (a) Rs; (b) T; (c) RH; (d) u

Validasi Model

Validasi model digunakan untuk meningkatkan keyakinan terhadap keakuratan dan kehandalan estimasi yang diberikan oleh model. Pada penelitian ini validasi model dilakukan dengan tiga teknik yaitu *prediction error plot*, *residuals plot*, dan *k-fold CV*.

Prediction Error Plot

Sumbu x pada grafik *prediction error* merupakan nilai ETp PM, sedangkan sumbu y merupakan nilai ETp yang diprediksi oleh algoritma RF. Selain itu, garis *best fit* dan garis *identity* pada grafik *prediction error* dibandingkan untuk dapat mengevaluasi kinerja model (Orji & Ukwandu, 2024). Apabila garis *best fit* sejajar dengan garis *identity* atau garis referensi 45 derajat dan sebaran titik-titik mengikuti garis tersebut, menunjukkan kesalahan prediksi rendah.

Perbandingan grafik *prediction error* algoritma RF dapat dilihat pada Gambar 2. *Prediction error plot* pada algoritma RF menggunakan data AWS Tungku menunjukkan bahwa skenario masukan Rs memiliki kesalahan prediksi antara nilai ETp PM dan

nilai ETp yang diprediksi dengan algoritma RF rendah. Hal tersebut ditunjukkan dengan sebaran titik-titik pada grafik mengikuti garis *best fit* dan garis *identity*. *Prediction error plot* juga dilakukan pada penelitian lain yang menunjukkan garis *best fit* dan garis *identity* sejajar dan sebaran titik-titik mengikuti garis tersebut, yang mengindikasikan kesalahan prediksi pada model tersebut rendah (Jha et al., 2020). Namun, grafik *prediction error* pada skenario masukan T, RH, dan kombinasi Rs dan T terjadi penyimpangan antara garis *best fit* dan garis *identity*. Hal tersebut mengindikasikan kesalahan prediksi antara nilai ETp PM dan nilai ETp yang diprediksi dengan algoritma RF tergolong menengah.

Sumbu x pada *residuals plot* merupakan nilai ETp PM, sedangkan sumbu y merupakan kesalahan prediksi (*residuals*) oleh algoritma RF. Apabila titik-titik pada grafik tersebut tersebar secara merata sepanjang garis nol pada sumbu y, perbedaan antara nilai target dan nilai yang diprediksi secara signifikan lebih rendah (Jha et al., 2020).

Residuals Plot


Perbandingan grafik *residuals* algoritma RF dapat dilihat pada Gambar 3. *Residuals plot* pada algoritma RF menggunakan data AWS Tungku menunjukkan bahwa skenario masukan Rs perbedaan antara nilai ETp PM dan nilai yang diprediksi dengan algoritma RF secara signifikan lebih rendah. Hal ini dapat dilihat dari sebaran titik-titik yang terdapat pada grafik tersebar merata di sepanjang garis nol pada sumbu y. Pernyataan yang mendukung hasil tersebut yaitu apabila sebaran titik-titik pada grafik berada sepanjang garis 0, kesalahan prediksi yang dihasilkan model lebih rendah (Jha et al., 2020). Namun, grafik *residuals* pada skenario masukan T, RH, dan kombinasi Rs dan T menampilkan sebaran titik-titik yang kurang merata di sepanjang garis nol pada sumbu y. Hal tersebut mengindikasikan bahwa model dengan skenario masukan T, RH, dan kombinasi Rs dan T kurang mampu melakukan prediksi secara tepat.

K-Fold Cross Validation


Evaluasi kinerja model menggunakan teknik *k-fold Cross Validation (CV)* dengan bahasa pemrograman

python dan *library scikit-learn*. Pada *library scikit-learn* untuk *k-fold CV* menggunakan modul *cross_val_score*. Keluaran dari modul tersebut menghasilkan nilai negatif karena konvensi *scikit-learn* (Sua et al., 2023). Meskipun bernilai negatif, interpretasinya serupa dengan metrik MSE yaitu semakin rendah nilai MSE, maka semakin baik kinerja model (Iannelli et al., 2020). Oleh karena itu, nilai negatif yang dihasilkan oleh modul *cross_val_score* menunjukkan bahwa semakin rendah nilai MSE yang negatif, semakin baik kinerja model dalam memprediksi data uji.

K-fold CV dengan algoritma RF menggunakan data AWS Tungku menghasilkan nilai yang dapat dilihat pada Tabel 3. Pada tabel tersebut menunjukkan bahwa skenario masukan Rs pada algoritma RF merupakan nilai *k-fold CV* yang paling rendah. Hal tersebut mengindikasikan kinerja model pada algoritma tersebut memiliki tingkat kesalahan yang rendah dalam memprediksi data.



Gambar 2. Perbandingan *prediction error plot* algoritma RF menggunakan data AWS Tungku pada skenario masukan; (a) Rs; (b) T; (c) RH; (d) Rs dan T



Gambar 3. Perbandingan *residuals plot* algoritma RF menggunakan data AWS Tungku pada skenario masukan; (a) Rs; (b) T; (c) RH; (d) Rs dan T

Tabel 3. K-fold CV dengan algoritma RF menggunakan data AWS Tungku

Algoritma	Skenario Masukan	K-fold CV	
		Data Latih	Data Uji
RF	Rs	-0,0001	-0,0001
	T	-0,0221	-0,0248
	RH	-0,0334	-0,0306
	Rs & T	-0,0223	-0,0246

Simulasi Estimasi ETP dengan Algoritma RF

Estimasi ETP dengan algoritma RF menggunakan empat skenario masukan variabel cuaca yang berbeda. Skenario masukan tersebut, dapat dilihat pada Tabel 1. Pada setiap skenario masukan tersebut menghasilkan nilai metrik evaluasi yang berbeda-beda. Metrik evaluasi yang digunakan yaitu R^2 , MSE, dan RMSE. Hasil metrik evaluasi algoritma RF menggunakan data AWS Tungku, dapat dilihat pada Tabel 4.

Skenario masukan Rs menghasilkan nilai R^2 pada data latih dan uji dengan nilai 1,00. Selain itu, metrik MSE dan RMSE memiliki nilai yang rendah yaitu 0,00 dan 0,01. Nilai R^2 yang lebih besar dan nilai RMSE lebih kecil mengindikasikan efisiensi model yang kuat (Dou & Yang, 2018). Hasil tersebut didukung oleh hasil penelitian lain yang menunjukkan Rs merupakan variabel cuaca yang berpengaruh besar terhadap nilai ETP (Arif et al., 2020; Bayram & Çitakoğlu, 2023; Ge et al., 2022; Yong et al., 2023).

Model estimasi dengan variabel cuaca masukan Rs merupakan model estimasi terbaik. Peningkatan Rs secara global menyebabkan peningkatan jumlah energi yang diserap oleh permukaan bumi, yang mengakibatkan peningkatan suhu udara dan permukaan (Gad, 2010). Variabel cuaca Rs secara kuat dapat mengendalikan penguapan dari tanaman dan tanah, serta perubahan kecil dalam Rs memiliki efek yang signifikan pada nilai ETP (Wang et al., 2024).

Pada skenario masukan T menghasilkan nilai R^2 0,77 pada data latih dan 0,62 pada data uji. Nilai R^2 tersebut menunjukkan kategori yang kuat terhadap model (Hair et al., 2011). Selain itu, nilai MSE dan RMSE pada data latih 0,01 dan 0,12, sedangkan pada data uji 0,02 dan 0,15. Pada skenario masukan RH menghasilkan nilai R^2 0,90 pada data latih yang menunjukkan kategori baik, namun pada data uji nilai R^2 menurun menjadi 0,48 yang menunjukkan kategori moderat (Hair et al., 2011). Selain itu, metrik MSE dan RMSE menghasilkan nilai 0,01 dan 0,08 pada data latih, sedangkan pada data uji menghasilkan nilai 0,03 dan 0,18.

Variabel cuaca T memiliki hubungan linier dan korelasi yang berbanding terbalik dengan RH. Hal tersebut disebabkan karena T dan RH merupakan variabel cuaca yang terkait langsung dalam kondisi tekanan atmosfer (Arif et al., 2020). RH yang tinggi mengindikasikan bahwa udara jenuh dengan uap air, sehingga proses ETp terhambat karena tidak dapat menampung lebih banyak uap air.

Skenario kombinasi Rs dan T menghasilkan metrik evaluasi yang serupa dengan skenario masukan T. Hal ini menunjukkan bahwa penambahan variabel cuaca Rs tidak memberikan peningkatan yang signifikan dalam kinerja model baik pada data latih dan data uji.

Tabel 4. Hasil metrik evaluasi algoritma RF menggunakan data AWS Tungkub

Algoritma	Data	Skenario Masukan	R ²	MSE	RMSE
RF	Latih	Rs	1,00	0,00	0,01
		T	0,77	0,01	0,12
		RH	0,90	0,01	0,08
		Rs & T	0,77	0,01	0,12
RF	Uji	Rs	1,00	0,00	0,01
		T	0,62	0,02	0,15
		RH	0,48	0,03	0,18
		Rs & T	0,63	0,02	0,15

Evaluasi Kinerja Model Estimasi

Hasil metrik evaluasi dan validasi model dengan algoritma RF menunjukkan bahwa skenario masukan Rs merupakan model estimasi terbaik. Nilai rata-rata estimasi ETp dengan model Rs algoritma RF adalah 0,14 mm/jam. Sementara itu, nilai ETp PM yaitu 0,15 mm/jam. Hasil nilai rata-rata estimasi ETp dengan ETp PM menghasilkan nilai yang tidak jauh berbeda yaitu dengan selisih 0,01.

KESIMPULAN

Variabel cuaca Rs memiliki hubungan linear dan korelasi *pearson* yang paling kuat diantara variabel lainnya. Model estimasi ETp dengan algoritma RF menggunakan variabel Rs telah menghasilkan model estimasi ETp terbaik dengan nilai ETp yang diestimasi mendekati nilai ETp PM. Hal tersebut ditunjukkan dengan koefisien metrik evaluasi di DI Tungkub ($R^2 = 1,00$, $MSE = 0,00$, $RMSE = 0,01$) dengan nilai rata-rata estimasi ETp 0,14 mm/jam dan nilai rata-rata ETp PM yaitu 0,15 mm/jam. Selain itu, pada validasi model telah dilakukan dengan teknik *prediction error plot*, *residuals plot*, dan *k-fold CV* yang menunjukkan tingkat kesalahan prediksi yang rendah.

DAFTAR PUSTAKA

- Abedi-Koupai, J., Dorafshan, M. M., Javadi, A., & Ostad-Ali-Askari, K. (2022). Estimating potential reference evapotranspiration using time series models (case study: synoptic station of Tabriz in northwestern Iran). *Applied Water Science*, 12(9), 1–8. <https://doi.org/10.1007/s13201-022-01736-x>
- Adib, A., Kalantarzadeh, S. S. O., Shoushtari, M. M., Lotfirad, M., Liaghat, A., & Oulapour, M. (2023). Sensitive analysis of meteorological data and selecting appropriate machine learning model for estimation of reference evapotranspiration. *Applied Water Science*, 13(3), 1–17. <https://doi.org/10.1007/s13201-023-01895-5>
- Ajjur, S. B., & Al-Ghamdi, S. G. (2021). Evapotranspiration and water availability response to climate change in the Middle East and North Africa. *Climatic Change*, 166(3–4), 1–18. <https://doi.org/10.1007/s10584-021-03122-z>
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop Evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and Drainage Paper 56*. <https://www.fao.org/3/X0490E/x0490e00.htm#Contents>
- Arif, C., Setiawan, B. I., & Sofiyuddin, H. A. (2020). Analisis evapotranspirasi potensial pada berbagai model empiris dan jaringan syaraf tiruan dengan data cuaca terbatas. *Jurnal Irigasi*, 15(2), 71–84. <https://doi.org/10.31028/ji.v15.i2.71-84>
- Bayram, S., & Çıtakoğlu, H. (2023). Modeling monthly reference evapotranspiration process in Turkey: application of machine learning methods. *Environmental Monitoring and Assessment*, 195(1). <https://doi.org/10.1007/s10661-022-10662-z>
- Bengfort, B., & Bilbro, R. (2019). Yellowbrick: Visualizing the Scikit-Learn Model Selection Process. *Journal of Open Source Software*, 4(35), 1075. <https://doi.org/10.21105/joss.01075>
- Dinpashoh, Y., Jahanbakhsh-Asl, S., Rasouli, A. A.,

- Foroughi, M., & Singh, V. P. (2019). Impact of climate change on potential evapotranspiration (case study: west and NW of Iran). *Theoretical and Applied Climatology*, 136(1–2), 185–201. <https://doi.org/10.1007/s00704-018-2462-0>
- Dou, X., & Yang, Y. (2018). Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems. *Computers and Electronics in Agriculture*, 148(February), 95–106. <https://doi.org/10.1016/j.compag.2018.03.010>
- Fereres, E., & Villalobos, F. J. (2016). *Agriculture and Agricultural Systems BT - Principles of Agronomy for Sustainable Agriculture* (F. J. Villalobos & E. Fereres (eds.); pp. 1–12). Springer International Publishing. https://doi.org/10.1007/978-3-319-46116-8_1
- Gad, H. E. (2010). the Effect of Solar Radiation on Animals. *Medical Journal of Australia*, 2(23), 795–795. <https://doi.org/10.5694/j.1326-5377.1936.tb103240.x>
- Gao, Z., He, J., Dong, K., & Li, X. (2017). Trends in reference evapotranspiration and their causative factors in the West Liao River basin, China. *Agricultural and Forest Meteorology*, 232, 106–117. <https://doi.org/10.1016/j.agrformet.2016.08.006>
- Ge, J., Zhao, L., Yu, Z., Liu, H., Zhang, L., Gong, X., & Sun, H. (2022). Prediction of Greenhouse Tomato Crop Evapotranspiration Using XGBoost Machine Learning Model. *Plants*, 11(15), 1–17. <https://doi.org/10.3390/plants11151923>
- Granata, F. (2019). Evapotranspiration evaluation models based on machine learning algorithms—A comparative study. *Agricultural Water Management*, 217(March), 303–315. <https://doi.org/10.1016/j.agwat.2019.03.015>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2011). *Multivariate Data Analysis* (Fifth Edit).
- Horvitz, E., & Mulligan, D. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 253–255.
- Iannelli, M., Rahman, M. R., Choi, N., & Wang, L. (2020). Applying machine learning to end-to-end slice SLA decomposition. *Proceedings of the 2020 IEEE Conference on Network Softwarization: Bridging the Gap Between AI and Network Softwarization, NetSoft 2020*, 92–99. <https://doi.org/10.1109/NetSoft48620.2020.9165317>
- Jha, S. B., Babiceanu, R. F., Pandey, V., & Jha, R. K. (2020). *Housing Market Prediction Problem using Different Machine Learning Algorithms: A Case Study*. <http://arxiv.org/abs/2006.10092>
- Liu, J., Yu, K., Li, P., Jia, L., Zhang, X., Yang, Z., & Zhao, Y. (2022). Estimation of Potential Evapotranspiration in the Yellow River Basin Using Machine Learning Models. *Atmosphere*, 13(9). <https://doi.org/10.3390/atmos13091467>
- Lotfi, M., Kamali, G. A., Meshkatee, A. H., & Varshavian, V. (2020). Study on the impact of climate change on evapotranspiration in west of Iran. *Arabian Journal of Geosciences*, 13(15). <https://doi.org/10.1007/s12517-020-05715-x>
- Nur, N., Wajidi, F., Sulfayanti, S., & Wildayani, W. (2023). Implementasi Algoritma Random Forest Regression untuk Memprediksi Hasil Panen Padi di Desa Minanga. *Jurnal Komputer Terapan*, 9(1), 58–64. <https://doi.org/10.35143/jkt.v9i1.5917>
- Orji, U., & Ukwandu, E. (2024). Machine learning for an explainable cost prediction of medical insurance. *Machine Learning with Applications*, 15(July 2023), 100516. <https://doi.org/10.1016/j.mlwa.2023.100516>
- Pino-Vargas, E., Taya-Acosta, E., Ingol-Blanco, E., & Torres-Rúa, A. (2022). Deep Machine Learning for Forecasting Daily Potential Evapotranspiration in Arid Regions, Case: Atacama Desert Header. *Agriculture (Switzerland)*, 12(12). <https://doi.org/10.3390/agriculture12121971>
- Runtunuwu, E., H. Syahbuddin, & A. Pramudia. (2008). Validasi Model Pendugaan Evapotranspirasi: Upaya Melengkapi Sistem Database Iklim Nasional. *Jurnal Tanah Dan Iklim*, 27, 1–12.
- Saidah, H., Sulistyono, H., & Budianto, M. B. (2020). Kalibrasi Persamaan Thornthwaite Dan Evaporasi Panci Untuk Memprediksi Evapotranspirasi Potensial Pada Daerah Dengan Data Cuaca Terbatas. *Jurnal Sains Teknologi & Lingkungan*, 6(1), 72–84. <https://doi.org/10.29303/jstl.v6i1.155>
- Sofos, F., & Karakasidis, T. E. (2021). Nanoscale slip length prediction with machine learning tools. *Scientific Reports*, 11(1), 1–10. <https://doi.org/10.1038/s41598-021-91885-x>
- Sua, L. S., Wang, H., Ortiz, J., Sua, L. S., Wang, H., Ortiz, J., Huang, J., & Alidaee, B. (2023). Predicting renewable energy production outputs from climate factors: A machine learning approach Predicting renewable energy production outputs from climate factors : A machine learning approach. 0–14.
- Supangat, A. B. (2016). Analisis perubahan nilai pendugaan evapotranspirasi potensial akibat perubahan iklim di kawasan hutan tanaman eucalyptus pellita. *Balai Penelitian Dan Pengembangan Teknologi Pengelolaan DAS*,

112–122.

- Tanny, J. (2022). Evapotranspiration Measurements and Modeling. *Water (Switzerland)*, 14(16), 16–18. <https://doi.org/10.3390/w14162474>
- Wang, Y., Meili, N., & Fatichi, S. (2024). *Ecohydrological responses to solar radiation changes*. March, 1–24.
- Yong, S. L. S., Ng, J. L., Huang, Y. F., & Ang, C. K. (2023). Estimation of Reference Crop Evapotranspiration with Three Different Machine Learning Models and Limited Meteorological Variables. *Agronomy*, 13(4). <https://doi.org/10.3390/agronomy13041048>