

Pemodelan Spasial Kelembaban Tanah Berbasis Indeks Spektral dengan Integrasi Citra Satelit Multi-sensor

Al Fath Riza Kholdani¹, Adani Dharmawati², Desy Ika Puspitasari^{3*}, Tri Wahyu Qur'ana⁴, Rezky Izzatul Y. Anwar⁵

¹Fakultas Teknologi Informasi
Universitas Islam Kalimantan MAB
Banjarmasin

¹alfathkholdani@uniska-bjm.ac.id

³Fakultas Teknologi Informasi
Universitas Islam Kalimantan MAB
Banjarmasin

³desyika@uniska-bjm.ac.id*

⁵Fakultas Teknologi Informasi
Universitas Islam Kalimantan MAB
Banjarmasin

⁵rezky.izzatul@uniska-bjm.ac.id*

²Fakultas Teknologi Informasi
Universitas Islam Kalimantan MAB
Banjarmasin

²adanidharmawati@uniska-
bjm.ac.id

⁴Fakultas Teknologi Informasi
Universitas Islam Kalimantan MAB
Banjarmasin

⁴triwahyuqurana@uniska-bjm.ac.id

Abstrak— Keakuratan estimasi kelembaban tanah merupakan faktor penting dalam memonitor dan manajemen sumber daya air serta mitigasi dampak lingkungan. Pengukuran kelembaban tanah secara in-situ terbatas oleh biaya dan cakupan spasial yang rendah. Karenanya, integrasi data iklim dan citra satelit menjadi alternatif yang menarik untuk meningkatkan keakuratan estimasi kelembaban tanah. Penelitian ini mengembangkan model spasial kelembaban tanah dengan menggabungkan data iklim (suhu permukaan tanah dan curah hujan) dan indeks spektral dari citra satelit multi-sensor, termasuk Landsat 8 dan Sentinel-2, serta menggunakan algoritma Random Forest untuk klasifikasi kelembaban tanah. Hasil penelitian menunjukkan bahwa pendekatan ini menghasilkan peta kelembaban tanah dengan akurasi Overall Accuracy (OA) sebesar 0.8 dan kappa 0.75 untuk Random Forest, dan akurasi OA sebesar 0.93 dan kappa 0.92 untuk Gradient Boosting. Penelitian ini menyimpulkan bahwa integrasi data iklim dan citra satelit multi-sensor secara signifikan meningkatkan akurasi prediksi kelembaban tanah, memberikan manfaat signifikan bagi perencanaan dan pengelolaan lahan.

Kata kunci— estimasi, kelembaban tanah, citra satelit, multi-sensor, Random Forest.

Abstract— The accuracy of soil moisture estimation is an important factor in monitoring and managing water resources and mitigating environmental impacts. In-situ soil moisture measurements are limited by cost and low spatial coverage. Therefore, the integration of climate data and satellite imagery is an attractive alternative to improve the accuracy of soil moisture estimation. This research develops a spatial model of soil moisture by combining climate data (land surface temperature and rainfall) and spectral indices from multi-sensor satellite imagery, including Landsat 8 and Sentinel-2, and using the Random Forest algorithm for soil moisture classification. The research results show that this approach produces soil moisture maps with Overall Accuracy (OA) accuracy of 0.8 and kappa 0.75 for Random Forest, and OA accuracy of 0.93 and kappa 0.92 for Gradient Boosting. This research concludes that the integration of climate data and multi-sensor satellite imagery significantly improves the accuracy of soil moisture predictions, providing significant benefits for land planning and management.

Keywords— estimation, soil moisture, satellite imagery, multi-sensor, Random Forest.

I. PENDAHULUAN

Keakuratan estimasi kelembaban tanah merupakan faktor penting untuk pemantauan lingkungan dan manajemen sumber daya. Kelembaban tanah mempengaruhi pertumbuhan tanaman, siklus hidrologi, dan manajemen irigasi, sehingga pemodelannya memiliki nilai signifikan dalam pertanian dan pengelolaan sumber daya alam [1]. Saat ini, integrasi data dari berbagai sensor satelit telah menjadi metode yang handal dalam pemodelan spasial kelembaban tanah [2].

Namun, tantangan utama dalam klasifikasi kelembaban tanah adalah kesulitan mengklasifikasi area dengan vegetasi tinggi [3]. Vegetasi tinggi dapat menyebabkan variasi spektral yang signifikan,

sehingga menyulitkan pemisahan kelembaban tanah dari sinyal spektral lainnya [4]. Kondisi ini mengakibatkan ketidakakuratan dalam estimasi kelembaban tanah dan membutuhkan pendekatan yang lebih canggih untuk mengatasinya.

Pemanfaatan citra satelit Sentinel-2 dan Landsat 8 yang diintegrasikan menawarkan keunggulan dari kedua sensor tersebut dalam hal resolusi spasial dan temporal, serta cakupan spektral [5]. Kombinasi ini memungkinkan akurasi yang lebih tinggi dalam estimasi kelembaban tanah. Spektral indeks seperti NDVI (Normalized Difference Vegetation Index), MNDWI (Mean Normalized Difference Water Index), BSI (Bare Soil Index), MSI (Moisture Stress Index), dan NDMI (Normalized Difference Moisture

Index) digunakan untuk memperkaya dataset yang digunakan untuk pemodelan.

Selain data dari citra satelit, informasi lain seperti suhu permukaan tanah, data elevasi digital (DEM), dan curah hujan (CHIRPS) juga digunakan untuk memberikan gambaran yang lebih komprehensif mengenai kondisi kelembaban tanah.

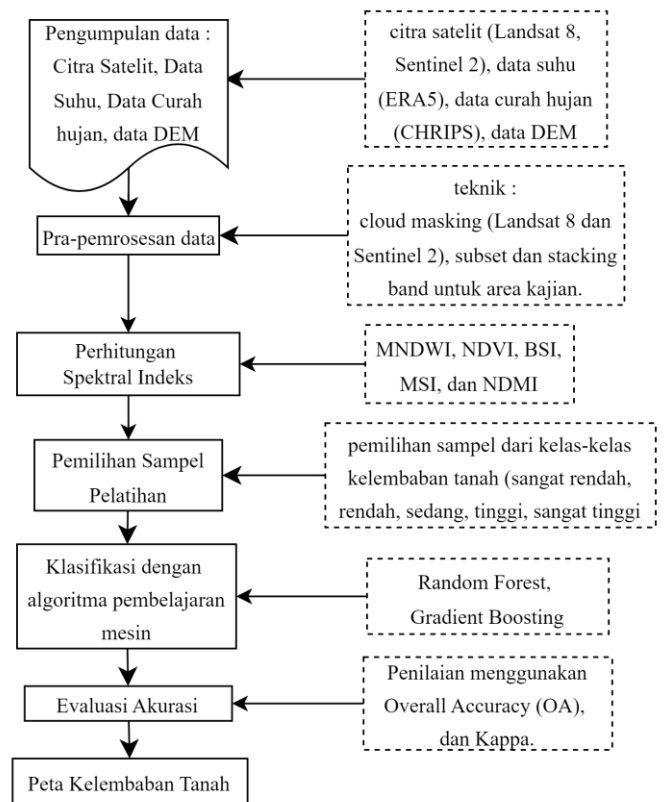
Klasifikasi kelembaban tanah menggunakan algoritma machine learning seperti Random Forest dan Gradient Boosting. Gradient Boosting memungkinkan pemodelan yang lebih akurat dengan memanfaatkan berbagai variabel input gradien membantu menangani kumpulan data yang luas dan heterogen, mengatasi korelasi non-linier [6]. Random Forest dipilih karena kemampuannya untuk menangani data yang kompleks dan memberikan hasil klasifikasi yang robust [7].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model spasial kelembaban tanah berbasis spektral indeks dan integrasi citra satelit multi-sensor. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang pemetaan kelembaban tanah, serta dapat diimplementasikan dalam berbagai aplikasi seperti pertanian presisi, manajemen air, dan mitigasi bencana.

II. METODOLOGI PENELITIAN

Pembuatan peta kelembaban tanah menggunakan citra satelit melibatkan beberapa langkah seperti yang ditunjukkan pada gambar 1. Gambar tersebut menjelaskan langkah-langkah dalam pemodelan spasial kelembaban tanah berbasis indeks spektral dengan integrasi citra satelit multi-sensor. Melalui tahapan pra-proses dengan teknik cloud masking dan subset serta band stacking untuk area kajian/region.

Indeks spektral seperti MNDWI, NDVI, BSI, MSI, dan NDMI dihitung. Sampel pelatihan dipilih dari kelas-kelas kelembaban tanah yang bervariasi (sangat rendah hingga sangat tinggi). Data ini digunakan untuk melatih algoritma Random Forest yang mengklasifikasikan kelembaban tanah. Evaluasi akurasi dilakukan menggunakan Overall Accuracy (OA), Kappa, dan F1-score, menghasilkan peta kelembaban tanah berdasarkan klasifikasi kelembaban yang sudah ditentukan.



Gambar 10. Metode Penelitian Pemodelan Spasial Kelembaban Tanah

A. PENGUMPULAN DATA

Proses dimulai dengan pengumpulan data dari citra satelit (Landsat 8 dan Sentinel 2), data suhu (ERA5), data curah hujan (CHIRPS), dan DEM. Sentinel-2, diluncurkan oleh Badan Antariksa Eropa (ESA), menawarkan citra multispektral resolusi tinggi (10 meter), ideal untuk pemantauan real-time. Landsat 8, dari USGS dan NASA, menyediakan citra resolusi 30 meter dengan cakupan spektral yang luas, memungkinkan deteksi perubahan jangka panjang dan analisis multitemporal [8], [9].

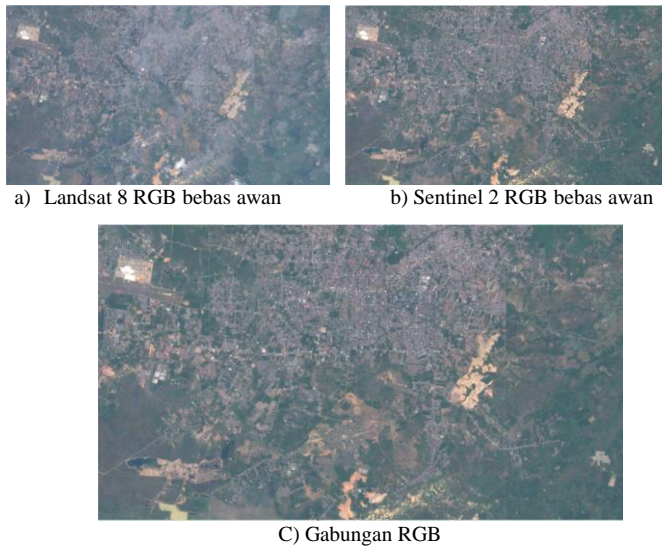
B. PRA PEMROSESAN DATA

Data yang digunakan dalam penelitian ini adalah data citra satelit antara tahun 2019 bulan Februari (musim hujan) dan 2020 bulan Agustus (musim kemarau) wilayah Martapura, Kalimantan Selatan yang diambil melalui Google Earth Engine (GEE).

Proses cloud masking untuk Landsat 8 dan Sentinel-2 bertujuan untuk mengidentifikasi dan menghilangkan piksel yang terpengaruh oleh awan dan bayangan untuk menghasilkan gambar yang lebih akurat. Koleksi gambar disaring berdasarkan daerah area kajian (Region) dan rentang tanggal,

kemudian faktor skala untuk reflektansi optik dan termal diterapkan. Untuk Landsat 8, cloud masking menggunakan bitmask pada pita piksel QA. Nilai median untuk periode tersebut dihitung dan dipotong ke Region. Pada citra satelit Sentinel-2, cloud masking menggunakan pita QA60, dengan bitmask pada bit ke-10 dan ke-11 untuk mendeteksi piksel cloud dan cirrus [10].

Gambar 2 menunjukkan perbandingan citra RGB bebas awan dari satelit Landsat 8 (a) dan Sentinel 2 (b) yang memenuhi kondisi bebas awan disesuaikan, difilter menurut Region kemudian nilai median dihitung dan dipotong ke Region.



Gambar 11. RGB Citra Satelit bebas awan (Cloud Masking)

Pita terpilih dari Landsat 8 adalah SR_B2 (Blue), SR_B3 (Green), SR_B4 (Red), SR_B5 (NIR), SR_B6 (SWIR1), dan SR_B7 (SWIR2), serta dari Sentinel-2 Koleksi Gambar tersebut adalah B2 (Blue), B3 (Green), B4 (Red), B8 (NIR), B11 (SWIR1), dan B12 (SWIR2). Selanjutnya, parameter visualisasi diatur untuk menampilkan gambar gabungan dalam format RGB (Red, Green, Blue), menggunakan pita B4 (Red), B3 (Green), dan B2 (Blue) untuk visualisasi. Gambar gabungan citra satelit landsat 8 dan sentinel 2 ditampilkan pada layer peta berlabel 'Gabungan RGB', memberikan tampilan yang lebih kaya informasi dengan cakupan spektral yang lebih luas.

C. PERHITUNGAN INDEKS SPEKTRAL

Indeks spektral dalam citra satelit adalah rasio matematis atau kombinasi pita spektral berbeda yang dimaksudkan untuk menarik perhatian pada karakteristik atau fitur tertentu dari permukaan bumi [4]. Tujuan dari indeks spektral, yang merupakan kombinasi matematis dari beberapa pita spektral dari citra satelit, adalah untuk mengekstrak data spesifik tentang objek atau kondisi di permukaan bumi.

Spektral Indeks	Formula	Penulis
NDVI	$\frac{NIR - Red}{NIR + Red}$	[11]
MSI	$\frac{MidIR (band5)}{NIR (band4)}$	[12]
MNDWI	$\frac{Green - SWIR1}{Green + SWIR1}$	[13]
NDMI	$\frac{NIR - SWIR}{NIR + SWIR}$	[14]
BSI	$\frac{(\rho Red + \rho SWIR) - (\rho NIR + \rho Blue)}{(\rho Red + \rho SWIR) + \rho NIR + \rho Blue}$	[15]

Tabel 1. Perhitungan Variabel Spektral Indeks yang digunakan


III. HASIL DAN PEMBAHASAN

Dalam studi ini, area kajian dianalisis menggunakan estimasi kategori kelembaban tanah dengan rentang yang ditunjukkan pada tabel 2. Dari segi jumlah sampel, setiap kategori terdapat 4 titik point per kelas, dengan total 20 sampel yang digunakan untuk analisis berdasarkan rentang kelembaban tanah.

Tabel 2. Rentang Kelembaban Tanah berdasarkan nilai dan warna

Kelas Kelembaban Tanah	Rentang Nilai	Warna
Sangat Kering	0 - 0.1	Merah
Kering	0.1 - 0.2	Orange
Sedang	0.2 - 0.3	Kuning
Lembab	0.3 - 0.4	Hijau
Sangat Lembab	> 0.4	Magenta

Hasil pemodelan spasial estimasi kelembaban tanah dengan klasifikasi sesuai pada tabel 2 ditunjukkan oleh gambar 3 dan gambar 4.



Gambar 12. Hasil Pemodelan Spasial Kelembaban Tanah dengan Gradient Boosting



Gambar 13. Hasil Pemodelan Spasial Kelembaban Tanah dengan Random Forest

Tabel 3. Hasil Akurasi Pemodelan Spasial Kelembaban Tanah

Metode	Overall Accuracy	Kappa
Random Forest (RF)	0.8	0.75
Gradient Boosting (GB)	0.933	0.92

Gambar 3 dan 4 menunjukkan hasil klasifikasi kelembaban tanah di suatu wilayah berdasarkan data satelit yang telah diolah menggunakan algoritma yang berbeda (Random Forest dan Gradient Boosting). Tabel 3 menunjukkan hasil akurasi Overall Accuracy (OA) sebesar 0.8 dan kappa 0.75 untuk Random Forest, dan akurasi OA sebesar 0.93 dan kappa 0.92 untuk Gradient Boosting. Area dengan warna merah menunjukkan wilayah dengan kelembaban tanah yang sangat rendah, yang bisa jadi indikasi kekurangan air atau kondisi tanah yang tidak subur. Warna oranye menunjukkan kelembaban tanah rendah, namun tidak se-ekstrem daerah merah, dan membutuhkan tambahan irigasi. Kuning menunjukkan kelembaban sedang, cukup untuk mendukung pertumbuhan tanaman tanpa kebutuhan irigasi mendesak. Warna hijau menunjukkan

kelembaban tanah yang baik, optimal untuk pertanian dan vegetasi lainnya. Magenta menunjukkan kelembaban tanah sangat tinggi, bisa jadi daerah rawa atau area dengan irigasi berlebihan.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model spasial kelembaban tanah dengan menggabungkan data iklim dan citra satelit multi-sensor menggunakan algoritma Random Forest dan Gradient Boosting. Hasil menunjukkan bahwa integrasi data iklim dan citra satelit multi-sensor secara signifikan meningkatkan akurasi prediksi kelembaban tanah, dengan Gradient Boosting menunjukkan kinerja lebih unggul dibandingkan Random Forest. Akurasi keseluruhan model Gradient Boosting mencapai 0.93 dengan nilai kappa 0.92, sedangkan Random Forest mencapai akurasi 0.8 dengan nilai kappa 0.75. Penerapan metode ini memberikan manfaat signifikan dalam perencanaan dan pengelolaan sumber daya air serta mitigasi dampak lingkungan. Penelitian lebih lanjut dapat fokus pada peningkatan resolusi spasial dan temporal serta aplikasi pada berbagai wilayah geografis untuk validasi lebih lanjut.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih kepada pihak LPPM UNISKA MAB Banjarmasin yang telah mendanai penelitian ini dengan APBU UNISKA tahun ajaran semester genap 2023/2024. Dukungan ini sangat berarti bagi keberhasilan penelitian kami dan pengembangan lebih lanjut di bidang ini. Kami juga berterima kasih kepada komunitas Geosoftware (Geosoftware.ID), materi webinar dan dukungan komunitas mereka telah memberikan kontribusi besar terhadap keberhasilan penelitian ini.

REFERENSI

- [1] S. K. Chaudhary *et al.*, "Machine learning algorithms for soil moisture estimation using Sentinel-1: Model development and implementation," *Advances in Space Research*, vol. 69, no. 4, pp. 1799–1812, Feb. 2022, doi: 10.1016/j.asr.2021.08.022.
- [2] A. Singh and K. Gaurav, "Deep learning and data fusion to estimate surface soil moisture from multi-sensor satellite images," *Sci Rep*, vol. 13, no. 1, Art. no. 1, Feb. 2023, doi: 10.1038/s41598-023-28939-9.
- [3] M. Aboutaleb, L. N. Allen, A. F. Torres-Rua, M. McKee, and C. Coopmans, "Estimation of soil moisture at different soil levels using machine learning techniques and unmanned aerial vehicle (UAV) multispectral imagery," in *Proceedings of SPIE - The International Society for Optical Engineering*, SPIE, 2019. doi: 10.1117/12.2519743.
- [4] D. Montero, C. Aybar, M. D. Mahecha, F. Martinuzzi, M. Söchting, and S. Wieneke, "A standardized catalogue of spectral indices to advance the use

- of remote sensing in Earth system research,” *Sci Data*, vol. 10, no. 1, p. 197, Apr. 2023, doi: 10.1038/s41597-023-02096-0.
- [5] T. T. Nguyen *et al.*, “A low-cost approach for soil moisture prediction using multi-sensor data and machine learning algorithm,” *Science of the Total Environment*, vol. 833, 2022, doi: 10.1016/j.scitotenv.2022.155066.
- [6] W. H. Alawee, L. A. Al-Haddad, A. Basem, D. J. Jasim, H. Sh. Majdi, and A. J. Sultan, “Forecasting sustainable water production in convex tubular solar stills using gradient boosting analysis,” *Desalination and Water Treatment*, vol. 318, p. 100344, Apr. 2024, doi: 10.1016/j.dwt.2024.100344.
- [7] N. Farmonov *et al.*, “Effectiveness of machine learning and deep learning models at county-level soybean yield forecasting,” *HunGeoBull*, vol. 72, no. 4, pp. 383–398, Jan. 2024, doi: 10.15201/hungeobull.72.4.4.
- [8] D. K. Bolton, J. M. Gray, E. K. Melaas, M. Moon, L. Eklundh, and M. A. Friedl, “Continental-scale land surface phenology from harmonized Landsat 8 and Sentinel-2 imagery,” *Remote Sensing of Environment*, vol. 240, p. 111685, Apr. 2020, doi: 10.1016/j.rse.2020.111685.
- [9] J. Li and D. P. Roy, “A Global Analysis of Sentinel-2A, Sentinel-2B and Landsat-8 Data Revisit Intervals and Implications for Terrestrial Monitoring,” *Remote Sensing*, vol. 9, no. 9, Art. no. 9, Sep. 2017, doi: 10.3390/rs9090902.
- [10] X. Gao, H. Chi, J. Huang, Y. Han, Y. Li, and F. Ling, “Comparison of Cloud-Mask Algorithms and Machine-Learning Methods Using Sentinel-2 Imagery for Mapping Paddy Rice in Jiangnan Plain,” *Remote Sensing*, vol. 16, no. 7, Art. no. 7, Jan. 2024, doi: 10.3390/rs16071305.
- [11] G. Mancino, A. Ferrara, A. Padula, and A. Nolè, “Cross-Comparison between Landsat 8 (OLI) and Landsat 7 (ETM+) Derived Vegetation Indices in a Mediterranean Environment,” *Remote Sensing*, vol. 12, no. 2, Art. no. 2, Jan. 2020, doi: 10.3390/rs12020291.
- [12] P. Welikhe, J. E. Quansah, S. Fall, and W. McElhenney, “Estimation of Soil Moisture Percentage Using LANDSAT-based Moisture Stress Index,” *J Remote Sensing & GIS*, vol. 06, no. 02, 2017, doi: 10.4172/2469-4134.1000200.
- [13] H. S. Pokhariya, D. P. Singh, and R. Prakash, “Evaluation of different machine learning algorithms for LULC classification in heterogeneous landscape by using remote sensing and GIS techniques,” *Eng. Res. Express*, vol. 5, no. 4, p. 045052, Dec. 2023, doi: 10.1088/2631-8695/acfa64.
- [14] F. Trevisiol, P. Mattivi, E. Mandanici, and G. Bitelli, “Cross-Sensors Comparison of Popular Vegetation Indexes From Landsat TM, ETM+, OLI, and Sentinel MSI for Time-Series Analysis Over Europe,” *IEEE Trans. Geosci. Remote Sensing*, vol. 62, pp. 1–16, 2024, doi: 10.1109/TGRS.2023.3343071.
- [15] J. Useya, S. Chen, and M. Murefu, “Cropland Mapping and Change Detection: Toward Zimbabwean Cropland Inventory,” *IEEE Access*, vol. 7, pp. 53603–53620, 2019, doi: 10.1109/ACCESS.2019.2912807.