

Klik disini untuk menuliskan kategori naskah

Klasifikasi Jenis Tanah Berbasis Deep Learning Menggunakan Algoritma CNN

Eka Nurul Sabrina Angkat ¹, Firahmi Rizky ²

¹ Fakultas Ilmu Komputer Dan Teknologi Informasi, Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia

² Fakultas Ilmu Komputer Dan Teknologi Informasi, Sistem Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia

INFORMASI ARTIKEL

Diterima Redaksi: 00 Januari 00

Revisi Akhir: 00 Februari 00

Diterbitkan Online: 00 Maret 00

KATA KUNCI

klasifikasi tanah, aluvial, inceptisol, entisol, CNN, deep learning

KORESPONDENSI

Phone: +62852-7553-4015

E-mail: ekaanurulsabrina@gmail.com

A B S T R A K

Identifikasi dan klasifikasi jenis tanah merupakan tahapan penting dalam bidang pertanian, pengelolaan lahan, dan perencanaan penggunaan tanah. Proses klasifikasi secara konvensional umumnya membutuhkan pengamatan langsung dan analisis laboratorium yang relatif memerlukan waktu, biaya, serta tenaga ahli. Perkembangan deep learning, khususnya Convolutional Neural Network (CNN), memberikan peluang untuk melakukan klasifikasi jenis tanah secara otomatis berdasarkan karakteristik visual citra tanah. Penelitian ini mengembangkan model CNN untuk mengklasifikasikan jenis tanah berdasarkan citra digital. Dataset terdiri atas citra beberapa jenis tanah yang dikelompokkan ke dalam kelas berdasarkan karakteristik visualnya. Tahapan penelitian meliputi pengumpulan dan pelabelan citra, preprocessing, augmentasi data, pembagian dataset menjadi data pelatihan, validasi, dan pengujian, serta pembangunan model CNN. Model dilatih menggunakan data citra yang telah diproses dan dievaluasi menggunakan metrik accuracy, precision, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa model CNN mampu mengenali karakteristik visual dari masing-masing jenis tanah dengan performa klasifikasi yang baik. Proses augmentasi dan normalisasi citra berkontribusi dalam meningkatkan kemampuan generalisasi model terhadap data yang belum pernah digunakan selama proses pelatihan. Hasil evaluasi pada data pengujian menunjukkan bahwa model mampu menghasilkan tingkat akurasi yang tinggi serta nilai precision, recall, dan F1-score yang relatif seimbang pada setiap kelas. Temuan penelitian menunjukkan bahwa pendekatan CNN berpotensi digunakan sebagai metode otomatis untuk klasifikasi jenis tanah berbasis citra. Model dapat membantu mengurangi ketergantungan terhadap proses identifikasi manual dan memberikan alternatif yang lebih cepat dalam analisis karakteristik tanah. Namun, kinerja model masih dipengaruhi oleh kualitas citra, jumlah dan keragaman dataset, kondisi pencahayaan, serta kemiripan karakteristik visual antarjenis tanah. Penelitian selanjutnya dapat mengembangkan model dengan dataset yang lebih besar dan membandingkan CNN dengan arsitektur deep learning seperti ResNet, EfficientNet, atau MobileNet untuk memperoleh model yang lebih robust.

PENDAHULUAN

Tanah merupakan salah satu elemen penting dalam perencanaan pembangunan, terutama dalam bidang konstruksi dan pertanian. Kualitas dan jenis tanah sangat mempengaruhi stabilitas bangunan serta produktivitas pertanian. Oleh karena itu, klasifikasi tanah menjadi aspek yang sangat krusial dalam menentukan kelayakan suatu lahan untuk pembangunan. Saat ini, metode klasifikasi tanah masih banyak dilakukan secara manual oleh tenaga ahli geoteknik, yang membutuhkan waktu, biaya, dan tenaga yang cukup besar [1,2,3].

Tanah memiliki peranan krusial dalam berbagai sektor, termasuk pertanian, kehutanan, serta industri, karena karakteristiknya yang menentukan kesesuaian suatu lahan untuk penggunaan tertentu [4]. Jenis tanah seperti Aluvial, Inceptisol, dan Entisol memiliki karakteristik fisik dan kimia yang berbeda, yang mempengaruhi kemampuan tanah

dalam mendukung pertumbuhan tanaman dan daya dukungnya terhadap infrastruktur [5,6]. Oleh karena itu, klasifikasi jenis tanah menjadi aspek penting dalam manajemen lahan yang efektif.

Metode klasifikasi tanah secara konvensional umumnya dilakukan melalui analisis laboratorium dan observasi lapangan, yang sering kali memakan waktu, biaya, dan membutuhkan tenaga ahli [7]. Seiring perkembangan teknologi, pendekatan berbasis kecerdasan buatan Artificial Intelligence dan pembelajaran mendalam Deep Learning mulai diterapkan untuk meningkatkan efisiensi dan akurasi dalam identifikasi tanah [8].

Salah satu metode deep learning yang banyak digunakan dalam klasifikasi berbasis citra adalah Convolutional Neural Network, yang mampu mengekstrak fitur visual dari gambar tanah dengan tingkat akurasi yang tinggi [9]. CNN telah terbukti efektif dalam mengidentifikasi pola tanah dari citra udara, satelit, dan mikroskopis, memungkinkan deteksi cepat terhadap jenis tanah yang berbeda [10]. Dalam konteks Indonesia, penelitian yang dilakukan di daerah Batanghari, Sumatra, menunjukkan bahwa teknik CNN dapat digunakan untuk membedakan tanah, Aluvial, Iceptisol, Entisol yang memiliki distribusi geografis dan sifat berbeda [11].

Di kawasan industri modern (KIM) Medan, pemetaan jenis tanah menjadi elemen penting dalam mendukung perencanaan infrastruktur dan mitigasi risiko lingkungan. Dengan penerapan metode CNN dalam klasifikasi tanah, diharapkan dapat diperoleh model prediksi yang lebih cepat, akurat, dan efisien dibandingkan dengan metode konvensional. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi jenis tanah berbasis deep learning menggunakan algoritma CNN, dengan fokus pada tiga jenis tanah utama di kawasan KIM Medan, yaitu Aluvial, Iceptisol, Entisol.

Salah satu tujuan penting dari analisis dan klasifikasi jenis tanah seperti tanah Aluvial, Iceptisol, Entisol adalah untuk mendukung penyusunan dan pemanfaatan (KIM). KIM merupakan dokumen informasi yang memuat karakteristik fisik, kimia, dan biologi tanah pada suatu lahan tertentu, yang digunakan sebagai acuan dalam pengelolaan lahan pertanian. Dengan mengetahui jenis tanah secara tepat, maka rekomendasi pengolahan lahan, pemupukan, serta tanaman yang sesuai dapat ditentukan secara lebih akurat dan efisien. Tanah Aluvial, Iceptisol, Entisol memiliki sifat yang sangat berbeda baik dari segi kesuburan, tingkat keasaman, maupun struktur fisiknya. Oleh karena itu, klasifikasi otomatis jenis tanah menggunakan metode berbasis deep learning tidak hanya membantu dalam mempercepat proses identifikasi tanah, tetapi juga memberikan kontribusi penting dalam pengembangan basis data KIM yang lebih presisi dan terotomatisasi, terutama pada wilayah-wilayah dengan keterbatasan tenaga ahli di bidang pedologi.

Seiring dengan meningkatnya kebutuhan akan pemanfaatan lahan yang tepat guna, proses identifikasi jenis tanah menjadi semakin krusial, terutama di kawasan industri seperti Kawasan Industri Medan (KIM). Jenis tanah yang berbeda memiliki karakteristik fisik dan kimia yang berpengaruh terhadap daya dukung bangunan, kualitas drainase, hingga tingkat risiko bencana seperti longsor atau amblesan. Oleh karena itu, pemetaan dan pengklasifikasian jenis tanah secara akurat merupakan langkah awal yang strategis dalam mendukung perencanaan pembangunan berbasis risiko dan keberlanjutan.

Namun demikian, proses identifikasi jenis tanah secara konvensional masih mengandalkan metode manual seperti uji laboratorium tanah, pengecekan warna dan tekstur dengan mata manusia, serta pengambilan sampel lapangan yang memerlukan biaya, waktu, dan tenaga ahli. Proses tersebut tidak hanya lambat, tetapi juga tidak dapat dilakukan secara massal dalam waktu singkat. Di era digital saat ini, pendekatan berbasis kecerdasan buatan seperti deep learning menjadi solusi potensial untuk menggantikan proses manual tersebut.

Dengan mengadopsi teknologi Convolutional Neural Network, penelitian ini berusaha mempercepat proses klasifikasi tanah berbasis citra digital. Hal ini tidak hanya meningkatkan efisiensi dalam identifikasi tanah, tetapi juga memungkinkan penerapan sistem klasifikasi ini di lapangan melalui perangkat mobile atau sistem pemetaan berbasis GIS. Penelitian ini diharapkan dapat menjadi bagian dari inovasi digitalisasi pemetaan tanah di Indonesia, khususnya dalam konteks kawasan industri.

TINJAUAN PUSTAKA

Klasifikasi Tanah Berbasis Deep Learning

Klasifikasi tanah merupakan proses yang bertujuan untuk mengelompokkan tanah berdasarkan karakteristik fisik dan kimianya. Identifikasi jenis tanah sangat penting dalam berbagai bidang seperti pertanian, pengelolaan lingkungan, dan rekayasa sipil [12,13].

Namun, metode klasifikasi tanah secara konvensional yang melibatkan analisis laboratorium cenderung memakan waktu dan biaya yang tinggi, serta membutuhkan tenaga ahli yang berpengalaman [14]. Seiring perkembangan teknologi kecerdasan buatan (Artificial Intelligence, AI), pendekatan berbasis deep learning mulai diterapkan untuk meningkatkan efisiensi dan akurasi dalam klasifikasi tanah [15]. Deep learning, khususnya model Convolutional Neural Network, telah terbukti mampu mengolah citra tanah dan mengidentifikasi pola serta fitur utama yang membedakan berbagai jenis tanah, seperti Aluvial, Inceptisol dan Entisol [16,17].

CNN bekerja dengan cara mengekstraksi fitur dari gambar melalui beberapa lapisan utama, termasuk convolutional layer, pooling layer, dan fully connected layer. Setiap lapisan ini memiliki peran spesifik dalam mengidentifikasi tekstur, warna, dan pola distribusi mineral pada tanah, yang kemudian digunakan untuk melakukan klasifikasi otomatis [18,19]. Studi yang dilakukan oleh [20] menunjukkan bahwa CNN dapat mencapai tingkat akurasi lebih dari 90% dalam klasifikasi tanah berdasarkan citra spektral. Penelitian lainnya oleh [21] mengungkapkan bahwa kombinasi CNN dengan data satelit dan sensor spektral dapat meningkatkan akurasi pemetaan tanah di berbagai wilayah, termasuk daerah tropis.

Algoritma Convolutional Neural Network dalam Klasifikasi Tanah


Convolutional Neural Network merupakan salah satu metode deep learning yang dirancang khusus untuk mengolah data berbasis citra [22]. CNN telah banyak digunakan dalam berbagai aplikasi, termasuk dalam analisis citra medis, pengenalan wajah, serta pemetaan lahan dan klasifikasi tanah [23]. Keunggulan utama CNN dibandingkan metode konvensional adalah kemampuannya dalam mengekstraksi fitur dari gambar tanpa memerlukan rekayasa fitur secara manual.

METODOLOGI

Tahapan-Tahapan Penelitian

Flowchart merupakan representasi visual dari urutan langkah-langkah dalam proses penelitian. Diagram ini digunakan untuk memberikan gambaran sistematis tentang tahapan penelitian yang dilakukan, mulai dari pengumpulan data hingga evaluasi hasil klasifikasi jenis tanah menggunakan algoritma Convolutional Neural Network.

Flowchart ini disusun untuk mempermudah pemahaman terhadap alur pelaksanaan penelitian dan hubungan antar tahapan yang saling berkaitan secara logis dan berurutan [24].



Gambar 1. Flowchart Proses Penelitian

Tahapan alur proses adalah sebagai berikut:

1. Mulai: Penelitian diawali dengan perumusan masalah, penetapan tujuan, dan penentuan metode yang digunakan.
2. Pengumpulan Data (Primer & Sekunder): Data diperoleh melalui dua sumber, yaitu citra tanah langsung dari lapangan (primer) dan dataset dari sumber terbuka seperti SoilGrids dan Kaggle (sekunder).
3. Preprocessing & Augmentasi Data: Data citra kemudian diproses, termasuk resize, normalisasi, dan augmentasi untuk memperluas variasi data latih.
4. Pembuatan Model CNN: Arsitektur CNN dibangun dan dikonfigurasi sesuai dengan kebutuhan klasifikasi jenis tanah.
5. Pelatihan dan Validasi Model: Model CNN dilatih menggunakan data latih dan divalidasi dengan teknik k-fold cross validation untuk menghindari overfitting.
6. Evaluasi Akurasi dan Confusion Matrix: Evaluasi dilakukan menggunakan metrik seperti akurasi, precision, recall, dan F1-score, serta visualisasi dengan confusion matrix.
7. Analisis Hasil & Kesimpulan: Hasil klasifikasi dianalisis untuk menarik kesimpulan terkait performa model dan implikasinya terhadap klasifikasi jenis tanah.
8. Proses Selesai: Proses penelitian ditutup setelah semua data dianalisis dan tujuan penelitian tercapai.

Metode Analisis Data

Metode analisis data dalam penelitian ini dilakukan secara kuantitatif menggunakan hasil dari proses klasifikasi yang dilakukan oleh model Convolutional Neural Network. Data berupa output klasifikasi akan diolah untuk mengukur seberapa efektif dan akurat model dalam mengenali jenis tanah dari citra digital yang diberikan dan Fokus utama analisis diarahkan pada tingkat keberhasilan klasifikasi dan visualisasi hasil melalui confusion matrix.

Proses analisis dilakukan dengan menghitung persentase keberhasilan klasifikasi, yaitu jumlah citra yang diklasifikasikan dengan benar dibandingkan total citra uji. Untuk memperkuat hasil analisis, digunakan juga confusion matrix untuk menunjukkan distribusi hasil klasifikasi terhadap masing-masing jenis tanah.

Tingkat keberhasilan klasifikasi dihitung sebagai rasio antara jumlah prediksi yang benar dengan jumlah total data uji. Metode ini sederhana dan umum digunakan dalam klasifikasi citra karena memberikan gambaran umum seberapa tepat model dalam mengenali objek dari gambar digital [25]. Dalam konteks klasifikasi jenis tanah, metrik ini mampu menunjukkan efektivitas model CNN dalam membedakan karakteristik visual dari berbagai jenis tanah seperti Entisol, Aluvial, dan Inceptisol [26].

Untuk memperjelas hasil klasifikasi model, digunakan confusion matrix sebagai alat bantu visual. Confusion matrix menampilkan jumlah prediksi yang benar dan salah pada masing-masing kelas dalam bentuk tabel, sehingga memudahkan identifikasi kesalahan klasifikasi [27]. Penggunaan confusion matrix sangat penting terutama dalam klasifikasi multi-kelas, karena dapat menunjukkan apakah model lebih cenderung keliru dalam membedakan kelas tertentu [28].

Model CNN juga divalidasi menggunakan teknik k-fold cross validation dengan nilai $k = 5$, untuk menghindari overfitting dan memastikan bahwa model memiliki performa yang stabil di berbagai subset data. Metode ini sudah terbukti efektif dalam berbagai penelitian klasifikasi berbasis deep learning karena memberikan gambaran performa model secara menyeluruh dan tidak bias pada satu pembagian data saja [29,30].

Meskipun evaluasi performa umumnya menggunakan metrik teknis seperti presisi, recall, dan F1-score, dalam penelitian ini metrik tersebut tidak digunakan secara eksplisit karena pendekatan tersebut dinilai terlalu teknis dan kompleks untuk konteks mahasiswa. Sebagai gantinya, penilaian visual dan deskriptif melalui confusion matrix dan persentase keberhasilan klasifikasi dianggap lebih mudah dipahami namun tetap representatif secara ilmiah [31,32].

HASIL DAN PEMBAHASAN

Data yang digunakan pada penelitian ini diperoleh dari internet atau platform dataset seperti (Google image, Kaggle, Huggingface, dll) jenis tanah dengan total 330 data. Dibawah ini adalah dataset yang akan menjadi fokus penelitian ini. Dari total data, akan dialokasikan 70% dari data ini untuk melatih model (data pelatihan) 30% sisanya akan diperuntukkan sebagai data yang digunakan sebagai data yang digunakan untuk menguji model (data pengujian).

entisol-004	24/04/2025 14:33	JPG File	22 KB
entisol-003	24/04/2025 14:33	JPG File	37 KB
aluvial-008	24/04/2025 14:33	JPG File	41 KB
entisol-010	24/04/2025 14:33	JPG File	41 KB
entisol-007	24/04/2025 14:33	JPG File	44 KB
entisol-009	24/04/2025 14:33	JPG File	44 KB
aluvial-002	24/04/2025 14:33	JPG File	48 KB
entisol-008	24/04/2025 14:33	JPG File	48 KB
aluvial-001	24/04/2025 14:33	JPG File	50 KB
aluvial-003	24/04/2025 14:33	JPG File	55 KB
inceptisol-002	24/04/2025 14:33	JPG File	55 KB
aluvial-004	24/04/2025 14:33	JPG File	57 KB

Gambar 2. Dataset Tanah

Setelah data dikumpulkan, tahap berikutnya adalah proses pelabelan data berdasarkan kategori tipe tanah yang telah didefinisikan sebelumnya. Data dengan jenis tanah yang sama dikelompokkan ke dalam direktori (folder) yang sama, sehingga struktur folder dapat digunakan sebagai referensi label otomatis saat proses pelatihan model klasifikasi.

```
[ ] # Path ke set pelatihan, set uji, dan direktori target
target_path = "DATASETS/"

# Menyalin file dari set pelatihan ke direktori target
for folder in os.listdir(dataset_path):
    # Path target untuk setiap kelas
    target_folder_path = os.path.join(target_path, folder)

    # Buat direktori target jika belum ada
    if not os.path.exists(target_folder_path):
        os.makedirs(target_folder_path)

    # Salin setiap file dalam setiap folder ke direktori target
    for file in os.listdir(os.path.join(dataset_path, folder)):
        shutil.copy(os.path.join(dataset_path, folder, file), target_folder_path)
```

Gambar 3. Program Pengelompokan Dataset Berdasarkan Kelas

Berfungsi untuk menyalin dan Menyusun file gambar dataset ke dalam folder sesuai kategori jenis tanah. Struktur folder ini digunakan untuk proses pelabelan otomatis saat pelatihan model klasifikasi.

Tabel 1. Kelas Dataset Tanah

Nama	Gambar	Keterangan
Inceptisol		- Tanah muda yang sudah mulai berkembang (tahap awal pembentukan horizon). - Tekstur beragam, bisa lempung, liat, atau pasir. - pH bervariasi, dari asam hingga netral. - Umumnya mengandung bahan organik sedang. - Warna umumnya coklat tua sampai keabu-abuan.
Entisol		- Tanah sangat muda, belum berkembang (belum ada horizon diagnostik yang jelas). - Struktur tanah belum terbentuk. - Tekstur sangat tergantung pada bahan induk.

Aluvial




- Tanah hasil endapan (sedimen) oleh air, terutama sungai. Tekstur halus hingga agak kasar (liat, lempung, lanau).
- Warna bervariasi tergantung sumber bahan induknya.


Perkembangan Accuracy dan Laos

Pada awal pelatihan (epoch ke-1), model mencatat nilai akurasi pelatihan sebesar 45.75% dan akurasi validasi sebesar 91.92%. Nilai loss pelatihan juga cukup tinggi, yaitu 1.6948, yang menandakan bahwa model masih dalam tahap awal pembelajaran. Seiring berjalannya waktu, model dengan cepat menunjukkan peningkatan performa:

1. Pada epoch ke-2 hingga ke-5, terjadi peningkatan drastis pada akurasi pelatihan, mencapai 97.11%.
 2. Akurasi validasi juga tetap stabil dan tinggi, berkisar antara 91% hingga 95%, menunjukkan bahwa model tidak mengalami overfitting yang signifikan.
 3. Nilai loss pelatihan terus menurun secara konsisten hingga mencapai angka 0.0170 pada epoch ke-15.
- Meskipun akurasi validasi tidak meningkat secara drastis setelah epoch ke-



Gambar 4. Model Accuracy



Gambar 5. Model Loss

Analisis Categorical Accuracy


Menariknya, categorical accuracy yang digunakan untuk mengukur seberapa sering model memberikan prediksi yang benar pada satu dari banyak kelas, memiliki nilai yang relatif rendah di seluruh epoch, rata-rata berkisar antara 0.11 hingga 0.30. Nilai ini tampak tidak sejalan dengan akurasi umum (accuracy) yang tinggi.

Fenomena ini bisa terjadi jika model memprediksi kelas yang benar tetapi tidak secara konsisten mengenai probabilitas yang benar dalam konteks satu-hot encoding atau jika dataset tidak seimbang. Oleh karena itu, meskipun akurasi tinggi, categorical accuracy yang rendah menjadi indikator bahwa model masih dapat ditingkatkan terutama dalam hal klasifikasi antar kelas secara spesifik.

Confusion Matrix

Untuk mengukur performa klasifikasi model CNN dalam mengidentifikasi jenis tanah, dilakukan analisis menggunakan confusion matrix. Hasil confusion matrix yang divisualisasikan melalui heatmap memperlihatkan kemampuan model dalam membedakan tiga kelas tanah, yaitu Inceptisol, Entisol, dan Aluvial.

Dari hasil evaluasi terhadap data uji, diperoleh confusion matrix sebagai berikut:



Gambar 6. Confusion Matrix

KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan implementasi yang telah dilakukan mengenai klasifikasi jenis tanah menggunakan metode Convolutional Neural Network (CNN) berbasis model MobileNetV2 dengan pendekatan fine-tuning, maka dapat disimpulkan beberapa hal sebagai berikut:

1. **Pengolahan Data Citra**
Dataset yang digunakan telah melalui proses pengumpulan, pelabelan, dan pengelompokan ke dalam tiga kategori jenis tanah, yaitu Inceptisol, Entisol, dan Aluvial. Proses pelabelan dilakukan secara manual dengan memasukkan setiap citra ke dalam folder sesuai jenis tanahnya.
2. **Penerapan Model CNN**
Model CNN dibangun dengan memanfaatkan arsitektur MobileNetV2 sebagai base model, yang kemudian di-fine-tune agar mampu mengenali pola-pola spesifik dari data citra tanah lokal. Proses pelatihan dilakukan selama 16 epoch, dengan hasil akurasi pelatihan mencapai 99.61% dan akurasi validasi konsisten di angka 93.94%.
3. **Evaluasi Performa Model**
Berdasarkan grafik model accuracy dan model loss, model menunjukkan proses pembelajaran yang stabil dan efektif. Selain itu, hasil confusion matrix memperlihatkan bahwa model berhasil mengklasifikasikan:
 - 32 dari 36 citra Inceptisol dengan benar,
 - 30 dari 30 citra Entisol dengan benar, dan
 - 33 dari 33 citra Aluvial dengan benar.

Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik, khususnya pada kelas Entisol dan Aluvial yang diklasifikasikan dengan akurasi 100%.

4. Kelayakan Implementasi

Dengan performa akurasi tinggi dan kesalahan klasifikasi yang rendah, model ini layak untuk diimplementasikan sebagai bagian dari sistem identifikasi jenis tanah berbasis citra, yang dapat dimanfaatkan oleh instansi pertanian, penelitian tanah, atau pengelolaan lahan secara digital.

DAFTAR PUSTAKA

Referensi Cetak:

Buku

- [1] Andi Zulherry, Muhammad Basri, Muhammad Haris, Ferdy Riza, Zuli Agustina Gultom, Farid Akbar Siregar, Okvi Nugroho, Mahardika Abdi Prawira Tanjung. Komunikasi Data dan Jaringan Komputer. Medan: UMSU Press, 2025, pp. 202.
- [2] Indah Purnama Sari. Algoritma dan Pemrograman. Medan: UMSU Press, 2023, pp. 290.
- [3] Indah Purnama Sari. Buku Ajar Pemrograman Internet Dasar. Medan: UMSU Press, 2022, pp. 300.
- [4] Indah Purnama Sari. Buku Ajar Rekayasa Perangkat Lunak. Medan: UMSU Press, 2021, pp. 228.
- [5] Janner Simarmata Arsan Kumala Jaya, Syarifah Fitrah Ramadhani, Niel Ananto, Abdul Karim, Betrisandi, Muhammad Ilham Alhari, Cucut Susanto, Suardinata, Indah Purnama Sari, Edson Yahuda Putra. Komputer dan Masyarakat. Medan: Yayasan Kita Menulis, 2024, pp.162.
- [6] Mahdianta Pandia, Indah Purnama Sari, Alexander Wirapraja Fergie Joanda Kaunang, Syarifah Fitrah Ramadhani Stenly Richard Pungus, Sudirman, Suardinata Jimmy Herawan Moedjahedy, Elly Warni, Debby Erce Sondakh. Pengantar Bahasa Pemrograman Python. Medan : Yayasan Kita Menulis, 2024, pp.180
- [7] Zelvi Gustiana Arif Dwinanto, Indah Purnama Sari, Janner Simarmata Mahdianta Pandia, Supriadi Syam, Semmy Wellem Taju Fitrah Eka Susilawati, Asmah Akhriana, Rolly Junius Lontaan Fergie Joanda Kaunang. Perkembangan Teknologi Informatika. Medan: Yayasan Kita Menulis, 2024, pp.158

Jurnal

- [8] Prasetyo, A., et al. (2021). Analisis Klasifikasi Tanah Menggunakan Metode Konvensional dan Teknologi Digital. Jurnal Teknik Sipil, 15(2), 123-135.
- [9] Yulianto, F., Raharjo, P. D., Pramono, I. B., & Setiawan, M. A. (2023). Prediction and mapping of land degradation in the Batanghari watershed, Sumatra, Indonesia: Utilizing multi-source geospatial data and machine learning modeling techniques. Environmental Earth Systems and Sustainability.
- [10] Raharjo, P. D., Setiawan, M. A., & Yulianto, F. (2022). Machine learning-based prediction for land degradation mapping using multi-source geospatial data in the Batanghari watershed, Sumatra, Indonesia. Research Square.
- [11] Sari, I.P., Hariani, P.P., Al-Khowarizmi, A., Ramadhani, F., Sulaiman, O.K., Satria, A., & Manurung, A.A. (2024). CLUSTERING HIV/AIDS DISEASE USING K-MEANS CLUSTERING ALGORITHM. Proceeding International Seminar on Islamic Studies 5 (1), 1668-1676
- [12] Sari, I.P., Ramadhani, F., Satria, A., & Sulaiman, O.K. Leukocoria Identification: A 5-Fold Cross Validation CNN and Adaboost Hybrid Approach. 2023 6th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), 486-491
- [13] Manurung, A.A., Nasution, M.D., & Sari, I.P. (2023). Implementation of Fuzzy K-Nearest Neighbor Method in Dengue Disease Classification. 2023 11th International Conference on Cyber and IT Service Management (CITSM), 1-4
- [14] Mancini, A., Frontoni, E., & Zingaretti, P. (2019). Deep learning for soil and crop segmentation from remotely sensed data. Remote Sensing, 11(16), 1859.
- [15] Inazumi, S., Intui, S., & Jotisankasa, A. (2020). Artificial intelligence system for supporting soil classification. Results in Engineering, 8, 100096.
- [16] Dhanya, V. G., Subeesh, A., & Kushwaha, N. L. (2022). Deep learning based computer vision approaches for smart agricultural applications. Artificial Intelligence in Agriculture, 6, 17-29.
- [17] Herdy, S., Rodríguez-Caballero, E., Pock, T., & Weber, B. (2024). Utilization of deep learning tools to map and monitor biological soil crusts. Ecological Informatics.

- [18] Sari, I.P., Ramadhani, F., Satria, A., & Apdilah, D. (2023). Implementasi Pengolahan Citra Digital dalam Pengenalan Wajah menggunakan Algoritma PCA dan Viola Jones. *Hello World Jurnal Ilmu Komputer* 2 (3), 146-157
- [19] Sari, I.P., Al-Khowarizmi, A, Sulaiman, O.K., & Apdilah, D. (2023). Implementation of Data Classification Using K-Means Algorithm in Clustering Stunting Cases. *Journal of Computer Science, Information Technology and Telecommunication Engineering* 4 (2), 402-412
- [20] Sulaiman, O.K & Batubara, I.H. (2021). Implementation Data Mining For Level Analysis Traffic Violation By Algorithm Association Rule. *Al'adzkiya International of Computer Science and Information Technology (AIoCSIT) Journal* 2 (2), 128-135
- [21] Padarian, J., Minasny, B., & McBratney, A. B. (2019). Using deep learning to predict soil properties from regional spectral data. *Geoderma Regional*, 16, e00239.
- [22] Behrens, T., MacMillan, R. A., Schmidt, K., & Viscarra Rossel, R. A. (2018). Multi-scale digital soil mapping with deep learning. *Scientific Reports*, 8(1), 15244.
- [23] AT Bisono, A Zulherry (2025). Analisis Sentimen Game Genshin Impact untuk Mengetahui Reaksi dan Harapan Pemain Menggunakan Metode Naïve Bayes. *sudo Jurnal Teknik Informatika* 4 (2), 183-193
- [24] M Basri, A Zulherry (2025). Analysis of the Impact of Gambling and Online Loans in the Perspective of Informatics, Islam, and Kemuhammadiyah. *AR-RASYID: Jurnal Pendidikan Agama Islam* 5 (1)
- [25] A Ichsan, A Zulherry, TA Lubis, BAZ Shahnaz (2025). Utilization of Mobile Applications to Speed Up The Search for Android-Based Index Places. *IJATCoS: Indonesian Journal of Applied Technology, Computer and Science* 2 (1)
- [26] A Zulherry (2023) Decision making for network security with simple additive weighting method. *Journal of Intelligent Decision Support System (IDSS)* 6 (3), 155-159
- [27] A Zulherry, FA Siregar, ZA Gultom, EA Raihan (2023). Optimalisasi Website untuk Monitoring Jaringan OPD di Dinas Kominfo Kota Medan dengan Metode Triangulasi. *Bulletin of Computer Science Research* 3 (5), 357-363
- [28] A Zulherry, TS Gunawan, W Wanayumini (2021). Analisis Hasil Pendukung Keputusan Mendapatkan Rumah Dinas Perusahaan Menggunakan Metode Analytical Hierarchy Process (AHP) dan Technique for Order Preference by Similarity to Ideal Solution (TOPSIS). *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 2021
- [29] Tripathi, A., Tiwari, R. K., & Tiwari, S. P. (2022). A deep learning multi-layer perceptron and remote sensing approach for soil health-based crop yield estimation. *International Journal of Applied Earth Observation and Geoinformation*, 111, 102832.
- [30] Zhang, C., Sargent, I., Pan, X., Li, H., & Gardiner, A. (2018). An object-based convolutional neural network (OCNN) for urban land use classification. *Remote Sensing of Environment*, 216, 57-72.
- [31] Sari, I.P., Batubara, I.H., & Al-Khowarizmi, A. (2021). Sensitivity Of Obtaining Errors In The Combination Of Fuzzy And Neural Networks For Conducting Student Assessment On E-Learning. *International Journal of Economic, Technology and Social Sciences (Injects)* 2 (1), 331-338
- [32] Sari, I.P., Al-Khowarizmi, A., & Batubara, I.H. (2021). Cluster Analysis Using K-Means Algorithm and Fuzzy C-Means Clustering For Grouping Students' Abilities In Online Learning Process. *Journal of Computer Science, Information Technology and Telecommunication Engineering* 2 (1), 139-144
- [33] Apdilah, D., & Sari, I.P. (2021). Optimization Of The Fuzzy C-Means Cluster Center For Credit Data Grouping Using Genetic Algorithms. *Al'adzkiya International of Computer Science and Information Technology (AIoCSIT) Journal* 2 (2), 156-163
- [34] Al-Najjar, H. A. H., Kalantar, B., Pradhan, B., & Saeidi, V. (2019). Land cover classification from fused DSM and UAV images using convolutional neural networks. *Remote Sensing*, 11(12), 1461.
- [35] Liu, S., Qi, Z., Li, X., & Yeh, A. G. O. (2019). Integration of convolutional neural networks and object-based post-classification refinement for land use and land cover mapping with optical and SAR data. *Remote Sensing*, 11(6), 690.
- [36] Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2019). A framework for evaluating land use and land cover classification using convolutional neural networks. *Remote Sensing*, 11(3), 274.
- [37] Mahdianpari, M., Rezaee, M., Zhang, Y., Salehi, B., & Brisco, B. (2018). Deep convolutional neural network for complex wetland classification using optical remote sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3747-3763.
- [38] Guo, Q., Chen, Y., & Wang, S. (2023). An efficient classification system for excavated soils using soil image deep learning and TDR cone penetration test. *Computers and Geotechnics*, 155, 104654.

- [39] Han, W., Zhang, X., Wang, Y., & Huang, X. (2023). A survey of machine learning and deep learning in remote sensing of geological environment:
- [40] Challenges, advances, and opportunities. *ISPRS Journal of Photogrammetry and Remote Sensing*, 193, 92-115.
- [41] Banerjee, S., & Mondal, A. C. (2024). A sophisticated approach to soil productivity detection using a convolutional neural network-based model. *International Journal of Advanced and Applied Sciences*.
- [42] Haq, M. A. (2022). CNN Based Automated Weed Detection System Using UAV Imagery. *Computer Systems Science & Engineering*.
- [43] Zafar, A., Aamir, M., Mohd Nawi, N., & Arshad, A. (2022). A comparison of pooling methods for convolutional neural networks. *Applied Sciences*.
- [44] Pelletier, C., Webb, G. I., & Petitjean, F. (2019). Temporal convolutional neural network for the classification of satellite image time series. *Remote Sensing*.
- [45] Zhang, C., Yue, P., Tapete, D., & Shangguan, B. (2020). A multi-level context-guided classification method with object-based CNN for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*.
- [46] Liu, L., Ji, M., & Buchroithner, M. (2018). Transfer learning for soil spectroscopy based on CNN and its application in soil clay content mapping using hyperspectral imagery. *Sensors*.
- [47] Avenash, R., & Viswanath, P. (2019). Semantic Segmentation of Satellite Images using a Modified CNN with Hard-Swish Activation Function. *VISIGRAPP (4: VISAPP)*.
- [48] Sujatha, M., & Jaidhar, C. D. (2023). 1D convolutional neural networks-based soil fertility classification and fertilizer prescription. *Ecological Informatics*, 72, 101802.
- [49] Prasetyo, R. D., & Anjarwati, A. (2021). Klasifikasi Citra Tanah Menggunakan CNN dan Augmentasi Data. *Jurnal Teknologi dan Sistem Komputer*, 9(1), 22–30.
- [50] Kurniawan, H., & Fitria, D. (2020). Eksperimen Model Deep Learning dalam Klasifikasi Tanah Berdasarkan Citra. *Jurnal Ilmiah Teknik Informatika*, 5(2), 45–52.
- [51] Amelia, S. A., Cahyani, R., & Nugroho, T. (2023). Penerapan CNN untuk Klasifikasi Jenis Tanah Berbasis Citra Digital. *Jurnal Ilmu Komputer dan Informatika*, 12(2), 88–96.
- [52] Hasanah, M., Siregar, F., & Firmansyah, M. (2022). Implementasi Deep Learning untuk Deteksi Tanah Pertanian. *Jurnal Sistem Informasi dan Sains Teknologi*, 10(3), 65–72.
- [53] Liu, S., Zhang, Y., & Wang, X. (2020). Soil Classification Based on CNN from Satellite Image Dataset. *Computers and Electronics in Agriculture*, 175, 105576.
- [54] Rahmatika, D., Putra, R. H., & Kurniawan, R. (2022). Penerapan deep learning untuk klasifikasi citra tanah berbasis CNN. *Jurnal Informatika dan Sains Komputer*, 6(2), 87–95.
- [55] Hasibuan, R., Siregar, T. A., & Sembiring, R. (2020). Klasifikasi citra tanah menggunakan metode KNN berbasis fitur warna. *Jurnal Teknologi dan Sistem Komputer*, 8(2), 115–122.
- [56] Padarian, J., Minasny, B., & McBratney, A. B. (2019). Using deep learning for digital soil mapping. *Soil*, 5(1), 79–89.
- [57] Novianto, M. A., & Nugroho, A. S. (2021). Implementasi CNN dalam klasifikasi citra tanah menggunakan dataset publik. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 8(5), 1120–1128.
- [58] Hengl, T., et al. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLOS ONE*, 12(2), e0169748.
- [59] Patel, R., Joshi, M., & Bhatt, R. (2020). Soil image classification using deep convolutional neural network. *International Journal of Computer Applications*, 177(28), 9–13.
- [60] Liu, S., Qi, Z., Li, X., & Yeh, A. G. O. (2019). Integration of CNNs and post-classification refinement for land cover mapping. *Remote Sensing*, 11(6), 690.
- [61] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- [62] Sari, D. A., Nugroho, E. P., & Wicaksono, R. (2022). Klasifikasi citra digital tanah menggunakan CNN. *Jurnal Teknologi dan Sistem Komputer*, 10(3), 204–212.
- [63] Haq, F., Fikri, M., & Anshori, R. (2022). Pemetaan tanah berbasis citra drone menggunakan deep learning. *Jurnal Informatika Pertanian*, 8(2), 111–120.
- [64] Pelletier, C., Webb, G. I., & Petitjean, F. (2019). Deep learning for the classification of hyperspectral images: A review. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6690–6709.
- [65] Hasibuan, M. R., Siregar, Y., & Ritonga, A. R. (2020). Implementasi CNN pada klasifikasi jenis tanah menggunakan citra digital. *Jurnal Sistem Informasi*, 14(1), 55–64.