

**KLASIFIKASI JENIS TANAH BERBASIS DEEP LEARNING
MENGUNAKAN ALGORITMA CNN**

SKRIPSI

DI SUSUN OLEH

EKA NURUL SABRINA ANGKAT

2109020141



UMSU

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI TEKNOLOGI INFORMASI FAKULTAS
ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

2025

**KLASIFIKASI JENIS TANAH BERBASIS DEEP LEARNING
MENGUNAKAN ALGORITMA CNN**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana
Komputer (S.Kom) dalam Program Studi Teknologi Informasi pada
Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas
Muhammadiyah Sumatera Utara**

EKA NURUL SABRINA ANGKAT

2109020141

**PROGRAM STUDI TEKNOLOGI INFORMASI FAKULTAS
ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

2025

LEMBAR PENGESAHAN

Judul Skripsi : Klasifikasi Jenis Tanah Berbasis Deep Learning
Menggunakan Algoritma CNN

Nama Mahasiswa : Eka Nurul Sabrina Angkat

NPM : 2109020141

Program Studi : Teknologi Informasi

Menyetujui
Komisi Pembimbing



(Dr. Firahmi Rizky, S.Kom. M.Kom)

NIDN. 0116079201

Ketua Program Studi



(Fatma Sari Hutagalung, S.Kom, M.Kom)
NIDN. 0117019301

Dekan



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

**KLASIFIKASI JENIS TANAH BERBASIS DEEP LEARNING
MENGUNAKAN ALGORITMA CNN**

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapakutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, Juli 2025

Yang membuat pernyataan



Eka Nurul Sabrina. Angkat

NPM. 2109020141

**PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK
KEPENTINGAN AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : Eka Nurul Sabrina. Angkat
NPM : 2109020141
Program Studi : Teknologi Informasi
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bebas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul :

**KLASIFIKASI JENIS TANAH BERBASIS DEEP LEARNING
MENGUNAKAN ALGORITMA CNN**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, Juli 2025

Yang membuat pernyataan



Eka Nurul Sabrina. Angkat
NPM. 2109020141

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Eka Nurul Sabrina. Angkat
Tempat dan Tanggal Lahir : Medan, 17 Juni 2003
Alamat Rumah : Jln. Titi Pahlawan Gg. Mekar 3 LK.2
Telepon/Faks/HP : 0852-7553-4015
E-mail : ekaanurulsabrina@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : Negeri 066430 Tamat : 2015
SMP : Swasta Brigjend Katamso II Tamat : 2018
SMA : Swasta Dharmawangsa Tamat : 2021

KLASIFIKASI JENIS TANAH BERBASIS DEEP LEARNING MENGUNAKAN ALGORITMA CNN

ABSTRAK

Klasifikasi jenis tanah seperti aluvial, inceptisol, dan entisol memiliki peranan penting dalam perencanaan penggunaan lahan, pertanian, serta pengembangan infrastruktur. Proses identifikasi jenis tanah secara manual melalui observasi lapangan dan analisis laboratorium seringkali memakan waktu, biaya besar, serta memerlukan keahlian khusus. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis terhadap jenis tanah aluvial, inceptisol, dan entisol menggunakan metode *deep learning* dengan algoritma *Convolutional Neural Network* (CNN). Dataset berupa citra tanah diperoleh dari sumber primer (pengambilan langsung) dan sekunder (pangkalan data online). Proses penelitian mencakup preprocessing data seperti normalisasi, augmentasi, dan perubahan ukuran citra, dilanjutkan dengan pelabelan dan pelatihan model CNN. Hasil pengujian menunjukkan bahwa model mampu mengklasifikasikan ketiga jenis tanah tersebut dengan tingkat akurasi yang tinggi, sehingga pendekatan ini efektif untuk mempercepat proses klasifikasi dan mengurangi ketergantungan pada metode manual. Temuan ini diharapkan dapat menjadi solusi inovatif dalam mendukung pengambilan keputusan berbasis teknologi di bidang geoteknik dan lingkungan.

Kata kunci: klasifikasi tanah, aluvial, inceptisol, entisol, CNN, deep learning

SOIL TYPE CLASSIFICATION BASED ON DEEP LEARNING USING THE CNN ALGORITHM

ABSTRACT

The classification of soil types such as alluvial, inceptisol, and entisol plays a vital role in land-use planning, agriculture, and infrastructure development. Traditional identification methods through field observation and laboratory analysis are often time-consuming, costly, and require specialized expertise. This study aims to develop an automatic classification system for alluvial, inceptisol, and entisol soil types using deep learning techniques, specifically the Convolutional Neural Network (CNN) algorithm. The dataset consists of soil images obtained from both primary sources (direct capture) and secondary sources (online databases). The research stages include data preprocessing such as normalization, augmentation, and image resizing, followed by labeling and training of the CNN model. The evaluation results indicate that the model is capable of classifying the three soil types with high accuracy, demonstrating the effectiveness of this approach in accelerating the classification process and reducing reliance on manual methods. This study is expected to serve as an innovative solution to support data-driven decision-making in the fields of geotechnics and environmental science.

Keywords: soil classification, alluvial, inceptisol, entisol, CNN, deep learning



KATA PENGANTAR

Alhamdulillah rabbi ‘aalamiin, segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, serta hidayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul :

“Klasifikasi Jenis Tanah Berbasis Deep Learning Menggunakan Algoritma CNN”. sebagai syarat dalam memperoleh gelar Sarjana Komputer (S.Kom) pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara.

Penulis tentunya berterima kasih kepada berbagai pihak dalam dukungan serta doa dalam penyelesaian skripsi. Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Agussani, M.AP., selaku Rektor Universitas Muhammadiyah Sumatera Utara (UMSU).
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. selaku Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Bapak Halim Maulana, S.T., M.Kom., selaku Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
4. Bapak Lutfi Basit, S.Sos., M.I.Kom., selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom., selaku Ketua Program Studi Teknologi Informasi.
6. Bapak Mhd. Basri, S.Si., M.Kom., selaku Sekretaris Program Studi Teknologi Informasi
7. Ibu Dr. Firaahmi Rizky, S.Kom, M.Kom., selaku dosen pembimbing skripsi yang telah berperan penting dalam proses penulis selama ini. Terimakasih atas segala kebahagiaan, dukungan, arahan, dan doa yang telah membantu penulis sehingga meraih prestasi membanggakan selama perkuliahan.
8. Kepada cinta pertama dan pintu surga, Bapak Khairuddin Angkat dan Ibu

Nuraisah Sarumaha. Terima kasih atas segala kasih sayang, doa, dan dukungan berupa moril maupun materil yang tidak terhingga sehingga penulis mampu menyelesaikan studi sarjana hingga selesai di Universitas Muhammadiyah Sumatera Utara.

9. Kepada abang dan kakak tercinta, Herli Rizaldi Angkat dan Nadila Huda Agustina Angkat. Terima kasih telah memberikan dukungan secara materi dan semangat selama masa perkuliahan. Bantuanmu bukan hanya soal angka tapi bentuk kasih sayang yang tak pernah putus dan dengan sabar menemani proses penyusunan skripsi ini hingga turut andil dalam setiap prosesnya.
10. Sahabat-sahabat penulis yaitu Sri Cantika Dwi Ningsih, Nurul Hakiki, Dhea Fayza, Liza Azzahra Zein. Terima kasih telah menjadi rumah kedua bagi penulis. Terima kasih atas segala canda, tawa, pengalaman, dan dukungan sehingga penulis bisa menyelesaikan skripsi ini.
11. Untuk saya sendiri, Eka Nurul Sabrina.A. Terima kasih telah menjadi pribadi yang kuat dan mampu mengendalikan diri dari tekanan luar. Terima kasih sudah mengatur ego dan memilih bangkit dengan rasa semangat sehingga dapat menyelesaikan studi di Universitas Muhammadiyah Sumatera Utara.

Dengan ini penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu dalam proses penyelesaian penulisan skripsi ini. Dengan kerendahan hati, penulis berharap semoga skripsi ini dapat bermanfaat bagi kita semua terutama bagi penulis sendiri. Amin Ya Rabbal'Alamin.

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Medan, Juli 2025

Penulis

Eka Nurul Sabrina. A

DAFTAR ISI

LEMBAR PENGESAHAN	iii
PERNYATAAN ORISINALITAS	iv
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS	v
RIWAYAT HIDUP	vi
ABSTRAK	vii
ABSTRACT	viii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	5
BAB II LANDASAN TEORI	6
2.1 Tinjauan Teori Jenis Tanah	6
2.1.1 Tanah aluvial	6
2.1.2 Tanah Inceptisol	7
2.1.3 Tanah Entisol	9
2.2 Klasifikasi Tanah Berbasis <i>Deep Learning</i>	11
2.3 Algoritma <i>Convolutional Neural Network</i> dalam Klasifikasi Tanah	12
2.3.1 Pengantar <i>Convolutional Neural Network</i>	12
2.3.2 Arsitektur CNN dalam Klasifikasi Tanah	14
2.3.3 Implementasi CNN dalam Penelitian Klasifikasi Tanah di	20
2.4 <i>Transfer Learning</i> dalam Klasifikasi Gambar	21

2.5	Penelitian Terdahulu	22
BAB III METODOLOGI PENELITIAN		24
3.1	Pendekatan Penelitian.....	24
3.2	Lingkungan Penelitian.....	25
3.2.1	Lokasi Penelitian	25
3.2.2	Waktu Penelitian.....	26
3.3	Data dan Sumber Data	27
3.4	Teknik Pengumpulan Data	27
3.5	Arsitektur dan Tahapan CNN	30
3.6	Evaluasi dan Validasi Model	33
3.7	Kebutuhan Hardware & Software	34
3.8	<i>Flowchart</i> Proses Penelitian.....	35
3.9	Fungsi Aktivasi Softmax dan Output Klasifikasi	38
3.10	Penjelasan Arsitektur CNN dan Transfer Learning.....	38
3.11	Metode Analisis Data	39
BAB IV HASIL & PEMBAHASAN		42
4.1	Pembahasan dan Persiapan Data	42
4.2	Pembagian Data Training dan Testing.....	44
4.3	Implementasi Metode Convulational Neural Network	45
4.3.1	Penelitian dan Insialisasi Base Model	45
4.3.2	Pembangunan Arsitektur Fine-Tuning	47
4.3.3	Strategi Fine-Tuning	49
4.3.4	Proses Kompilasi Model.....	51
4.3.5	Ringkasan Arsitektur Model	52
4.3.6	Pelatihan Model dan Penggunaan Callback EarlyStopping.....	53
4.3.7	Perhitungan Epoch	56
4.4	Evaluasi Penforma Model Berdasarkan Pelatihan.....	61
4.4.1	Perkembangan Accuracy dan Loss	61
4.4.2	Analisis Categorical Accuracy	63
4.4.3	Learning Rate Scheduling	63
4.4.4	Konsistensi dan Stabilitas	63
4.5	Hasil Prediksi	64
4.5.1	Upload Gambar	64
4.5.2	Preprocessing Gambar	64
4.5.3	Prediksi	65

4.5.4 Menampilkan Hasil Probabilitas.....	66
4.5.5 Prediksi Akhir (Kelas dengan Probabilitas Tertinggi.....	66
4.6 Confusion Matrix.....	66
4.6.1 Hasil Confusion Matrix	67
4.6.2 Interpretasi Hasil.....	67
4.6.3 Kesimpulan	68
BAB V KESIMPULAN DAN SARAN	70
5.1 Kesimpulan.....	70
5.2 Saran.....	71
DAFTAR PUSTAKA	73

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu	22
Tabel 3.1 Waktu Penelitian.....	26
Tabel 3.2 Kebutuhan Hardware.....	35
Tabel 4.1 Kelas Dataset Tanah	43

DAFTAR GAMBAR

Gambar 2.1 Tanah Aluvial (Izandi, 2024)	7
Gambar 2.2 Tanah Inceptisol (Britannica)	9
Gambar 2.3 Tanah Entisol (Detiktanicom).....	11
Gambar 2.4 Lapisan Konvolusi	12
Gambar 3.1 <i>Flowchart</i> Proses Penelitian	36
Gambar 4.1 Dataset Tanah	42
Gambar 4.2 Kelas Dataset Tanah	43
Gambar 4.3 Pembagian Dataset.....	44
Gambar 4.4 Inisialisasi Base Model	46
Gambar 4.5 Arsitektur <i>Fine Tuning</i>	48
Gambar 4.6 Strategi <i>Fine Tuning</i>	49
Gambar 4.7 Kompilasi Model	51
Gambar 4.8 <i>callback earllystopping</i>	53
Gambar 4.9 Proses Training Model.....	54
Gambar 4.10 Model <i>Accuracy</i>	61
Gambar 4.11 Model <i>Loss</i>	62
Gambar 4.12 <i>Tanah Inceptisol</i>	63
Gambar 4.13 Confusion Matrix.....	67

BAB 1

PENDAHULUAN

1.1. Latar Belakang Masalah

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 (Prasetyo et al., 2021).

Tanah memiliki peranan krusial dalam berbagai sektor, termasuk pertanian, kehutanan, serta industri, karena karakteristiknya yang menentukan kesesuaian suatu lahan untuk penggunaan tertentu (Yulianto et al., 2023). 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 (Raharjo et al., 2022). 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 (Yulianto et al., 2022). Seiring perkembangan teknologi, pendekatan berbasis kecerdasan buatan *Artificial*

Intelligence dan pembelajaran mendalam *Deep Learning* mulai diterapkan untuk meningkatkan efisiensi dan akurasi dalam identifikasi tanah (Raharjo et al., 2023).

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 (Yulianto et al., 2023). CNN telah terbukti efektif dalam mengidentifikasi pola tanah dari citra udara, satelit, dan mikroskopis, memungkinkan deteksi cepat terhadap jenis tanah yang berbeda (Raharjo et al., 2022). 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 (Yulianto et al., 2022).

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, Inceptisol, 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.

1.2. Rumusan Masalah

Ada beberapa rumusan masalah berdasarkan latar belakang yang akan diselesaikan pada penelitian ini, antara lain:

1. Bagaimana menganalisa jenis tanah menggunakan model klasifikasi jenis tanah berbasis deep learning algoritma CNN?
2. Bagaimana merancang dan membangun system klasifikasi jenis tanah Aluvial, Iceptisol, Entisol di KIM Medan?
3. Bagaimana menguji model CNN dalam klasifikasi jenis tanah?

1.3. Batasan Masalah

1. Penelitian ini hanya berfokus pada tiga jenis tanah, yaitu Aluvial, Iceptisol, Entisol
2. Dataset yang digunakan berupa citra tanah yang diperoleh dari internet atau platform dataset seperti (Google image, Kaggle, Huggingface, dll) jenis tanah dengan total 330 data.
3. Evaluasi model dilakukan berdasarkan parameter akurasi, confusion matrix untuk menilai performa klasifikasi.

1.4. Tujuan Penelitian

1. Untuk menganalisa jenis tanah menggunakan model klasifikasi jenis tanah berbasis deep learning algoritma CNN
2. Untuk merancang dan membangun system klasifikasi jenis tanah Aluvial, Iceptisol, Entisol di KIM Medan
3. Untuk menguji model CNN dalam klasifikasi jenis tanah

1.5. Manfaat Penelitian

1. Penelitian ini membantu saya belajar lebih banyak tentang deep learning dan klasifikasi citra.
2. Sistem klasifikasi tanah ini akan memudahkan karyawan di Kawasan Industri Medan (KIM) dalam membuat keputusan terkait penggunaan lahan, sehingga proses perencanaan infrastruktur menjadi lebih cepat dan akurat.
3. Penelitian ini dapat meningkatkan kesadaran tentang pentingnya pengelolaan tanah yang baik, mendorong praktik yang lebih ramah lingkungan.

BAB II

LANDASAN TEORI

2.1. Tinjauan Teori Jenis Tanah

2.1.1 Tanah aluvial

Tanah aluvial adalah tanah yang terbentuk dari endapan material halus yang dibawa oleh air sungai dan diendapkan di daerah dataran rendah atau delta sungai (Rahman et al., 2019). Tanah ini umumnya memiliki tekstur yang beragam, mulai dari lempung hingga pasir, tergantung pada kondisi lingkungan tempat terjadinya pengendapan (Kurniawan et al., 2020). Karena berasal dari endapan, tanah aluvial memiliki sifat yang sangat dipengaruhi oleh bahan induk dan proses pengendapannya, sehingga bisa sangat beragam secara tekstur dan kesuburannya. Kesuburan tanah aluvial tinggi karena mengandung banyak bahan organik dan mineral yang terbawa oleh aliran air (Sari et al., 2021).

Tanah aluvial sering digunakan untuk aktivitas pertanian karena memiliki sifat fisik yang mendukung pertumbuhan tanaman, seperti kemampuan menahan air dan ketersediaan unsur hara yang cukup (Widodo et al., 2022). Namun, tanah ini juga memiliki kelemahan, seperti rentan terhadap erosi dan sedimentasi, terutama jika tidak dikelola dengan baik (Pratama et al., 2023). Oleh karena itu, pengelolaan tanah aluvial memerlukan praktik konservasi tanah yang tepat guna mencegah degradasi lahan (Hidayat et al., 2024).

Tanah aluvial sangat potensial untuk pertanian intensif, termasuk tanaman pangan (padi, jagung) dan hortikultura, karena sifatnya yang mudah diolah, memiliki aerasi baik, dan nutrisi tinggi (Asep Mulyono et al., 2019). Namun, penggunaan berlebihan tanpa konservasi dapat menyebabkan erosi dan penurunan

kesuburan, terutama pada lapisan permukaan. Di Sumatera Utara—khususnya sekitar DAS seperti Cimanuk dan sungai Deli—tanah aluvial telah banyak diteliti karena perannya dalam sistem pengairan dan pertanian lokal. Meski tidak langsung dari UMSU, hasil studi di Indramayu (Asep Mulyono et al., 2019) memberikan gambaran bagaimana karakteristik aluvial serupa kemungkinan ditemukan di DAS Sumut



Gambar 2.1. Tanah Aluvial (Izandi, 2024)

2.1.2 Tanah Inceptisol

Tanah Inceptisol merupakan jenis tanah muda yang belum berkembang secara sempurna, namun sudah menunjukkan proses pedogenesis awal. Inceptisol berasal dari kata *inceptum* (Latin), yang berarti "permulaan", mencerminkan tahap awal perkembangan horizon tanah. Tanah ini dicirikan oleh adanya horizon kambik, namun belum mengalami proses pencucian (eluviasi) dan akumulasi (illuviasi) secara intensif. Inceptisol merupakan ordo tanah yang terbentuk dari proses pedogenesis awal, dengan tingkat perkembangan horizon tanah yang masih dangkal dan belum stabil secara morfologis maupun kimiawi (Fitri et al., 2021). Tanah ini biasanya berkembang pada lingkungan yang memiliki dinamika geomorfologi aktif, seperti daerah aliran sungai muda, kaki lereng gunung, atau

kawasan dengan aktivitas tektonik tinggi, sehingga proses pelapukan mineral berlangsung lambat (Pratama & Handayani, 2020).

Karakteristik tanah Inceptisol ditandai oleh adanya horizon cambic, yaitu horizon sub-perkembangan dari horizon B yang menunjukkan sedikit perubahan struktur dan warna dibanding horizon atasnya, namun belum menunjukkan akumulasi bahan lempung, besi, atau aluminium seperti pada horizon argilik di tanah yang lebih tua (Syahputra et al., 2022). Inceptisol memiliki kandungan liat sedang, aerasi tanah cukup baik, dan porositas tanah yang relatif stabil, namun masih menunjukkan keterbatasan dalam retensi air dan ketersediaan unsur hara (Utami et al., 2020). Tanah Inceptisol tersebar luas di Indonesia, khususnya di Sumatera Utara (lereng Bukit Barisan, kawasan agroforestri), Jawa Barat (daerah Cianjur, Bogor), Sulawesi Tengah dan Papua. Wilayah dengan kondisi iklim basah, topografi bergelombang, dan aktivitas tektonik tinggi menjadi tempat yang ideal bagi pembentukan Inceptisol.

Menurut Badan Standarisasi Nasional (BSN), Inceptisol diklasifikasikan sebagai tanah dengan reaktivitas kimia yang sedang hingga tinggi tergantung bahan induk dan kondisi lingkungan pembentuknya. Dalam kondisi lembab, tanah ini memiliki aktivitas mikroorganisme yang tinggi, tetapi rentan mengalami degradasi struktur bila dikelola tanpa konservasi (Fadhilah et al., 2021).

Dalam konteks klasifikasi tanah untuk pembangunan dan perencanaan penggunaan lahan, Inceptisol harus dianalisis secara cermat karena sifatnya yang belum stabil bisa menyebabkan masalah seperti erosi, pemadatan tanah, atau longsor, terutama pada wilayah dengan kemiringan lereng tinggi (Yuliana & Hartono, 2020). Oleh sebab itu, pengelolaan lahan dengan pendekatan

agroekologi dan prinsip konservasi tanah menjadi hal penting agar tanah Inceptisol dapat digunakan secara berkelanjutan.



Gambar 2.2. Tanah Inceptisol (Britannica)

2.1.3 Tanah Entisol

Tanah Entisol adalah jenis tanah yang sangat muda dan belum mengalami perkembangan profil tanah yang berarti. Kata *entisol* berasal dari bahasa Latin *recentis*, yang berarti “baru”. Entisol termasuk dalam kategori ordo tanah yang paling sedikit mengalami proses pedogenesis (pembentukan tanah) dan biasanya hanya memiliki satu atau dua horizon tanah saja, tanpa horizon diagnostik yang khas

Tanah Entisol adalah salah satu ordo tanah yang tergolong paling muda dalam sistem klasifikasi tanah menurut USDA (*United States Department of Agriculture*). Entisol merupakan tanah yang belum mengalami perkembangan profil tanah secara signifikan dan umumnya hanya memiliki horizon A (lapisan atas) atau bahkan tidak memiliki horizon sama sekali (Setyowati et al., 2020). Tanah ini terbentuk dari material induk yang baru terdeposit, seperti pasir, endapan banjir, atau bahan vulkanik muda, sehingga belum cukup waktu untuk mengalami proses pedogenesis yang kompleks (Syamsuddin et al., 2021).

Secara morfologi, tanah Entisol dicirikan oleh warna yang bervariasi dari abu-abu muda hingga coklat kekuningan, tergantung dari jenis bahan induk dan lingkungan pembentuknya. Teksturnya biasanya lepas-lepas, berpasir, dan memiliki daya ikat yang rendah. Ciri khas tanah ini adalah minimnya horizon diagnostik, sehingga sulit dibedakan secara kasat mata dengan bahan induk aslinya (Rahman & Yuliani, 2022).

Entisol umumnya terdapat di daerah dengan kondisi lingkungan ekstrem atau dinamis, seperti tepi sungai (*floodplain*), pantai berpasir, lereng curam, atau lahan-lahan aluvial muda yang sering mengalami sedimentasi atau erosi (Wulandari et al., 2019). Entisol banyak ditemukan di Sumatera Utara Sepanjang daerah pesisir timur dan sungai besar (seperti DAS Deli atau Wampu), Jawa Tengah & Jawa Timur Di sepanjang bantaran sungai besar, Kalimantan dan Papua Di daerah rawa, sungai aktif, atau tanah endapan baru. Karena itu, tanah Entisol sering dianggap sebagai tanah dengan tingkat kesuburan rendah hingga sedang, dan memiliki kapasitas penahan air serta hara yang terbatas, terutama bila teksturnya dominan pasir (Susilawati et al., 2021).

Potensi dan pemanfaatan Tanah Entisol kurang cocok untuk pertanian tanpa pengolahan khusus. Hanya bisa ditanami setelah pengapuran dan pemupukan intensif, Perkebunan dan hortikultura Terbatas, bergantung pada topografi dan kondisi drainase, Kehutanan atau konservasi Cocok untuk tanaman keras atau rehabilitasi lahan rusak. Pemanfaatannya harus hati-hati karena rentan terhadap degradasi, pencucian hara, dan erosi.



Gambar 2.3. Tanah Entisol (Detiktani.com)

2.2. 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 (Mancini et al., 2019).

Namun, metode klasifikasi tanah secara konvensional yang melibatkan analisis laboratorium cenderung memakan waktu dan biaya yang tinggi, serta membutuhkan tenaga ahli yang berpengalaman (Inazumi et al., 2020). Seiring perkembangan teknologi kecerdasan buatan (*Artificial Intelligence, AI*), pendekatan berbasis *deep learning* mulai diterapkan untuk meningkatkan efisiensi dan akurasi dalam klasifikasi tanah (Dhanya et al., 2022). *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 (Herdy et al., 2024).

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 (Padarian et al., 2019). Studi yang dilakukan oleh Dhanya et al. (2022) menunjukkan bahwa CNN dapat mencapai tingkat akurasi lebih dari 90% dalam klasifikasi tanah berdasarkan citra spektral. Penelitian lainnya oleh Behrens et al. (2018) mengungkapkan bahwa kombinasi CNN dengan data satelit dan sensor spektral dapat meningkatkan akurasi pemetaan tanah di berbagai wilayah, termasuk daerah tropis. Keunggulan utama dari *deep learning* dalam klasifikasi tanah meliputi:

- a. Kecepatan dan Efisiensi: Proses klasifikasi dapat dilakukan secara otomatis tanpa memerlukan analisis manual yang memakan waktu (Guo et al., 2023).
- b. Akurasi Tinggi: CNN mampu mengenali fitur tanah dengan lebih baik dibandingkan metode berbasis aturan (*rule-based methods*) atau model statistik klasik (Padarian et al., 2019).
- c. Kemampuan Generalisasi: *Model deep learning* dapat digunakan untuk mengklasifikasikan tanah dalam berbagai kondisi lingkungan dengan tingkat keberhasilan yang tinggi (Tripathi et al., 2022).

2.3. Algoritma *Convolutional Neural Network* dalam Klasifikasi Tanah

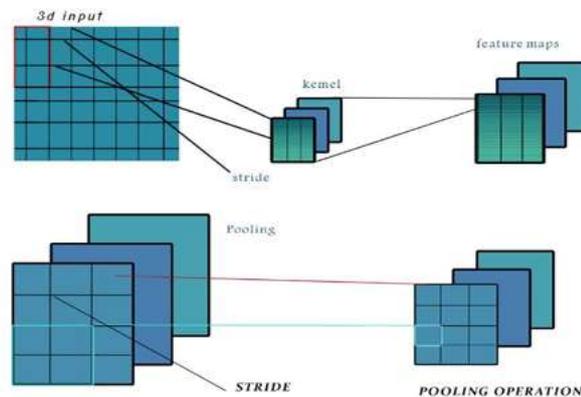
2.3.1 Pengantar *Convolutional Neural Network*

Convolutional Neural Network merupakan salah satu metode *deep learning* yang dirancang khusus untuk mengolah data berbasis citra (Zhang et al., 2018). CNN telah banyak digunakan dalam berbagai aplikasi, termasuk dalam analisis citra medis, pengenalan wajah, serta pemetaan lahan dan klasifikasi tanah (Al-Najjar et al., 2019). Keunggulan utama CNN dibandingkan metode konvensional

adalah kemampuannya dalam mengekstraksi fitur dari gambar tanpa memerlukan rekayasa fitur secara manual. Dari sudut pandang teknis, CNN didasarkan pada konvolusi, seperti yang ditunjukkan pada rumus dibawah:

$$presisi = \left(\frac{total\ benar}{total\ terprediksi} \right) \dots \dots \dots (1)$$

Di mana j berkisar antara 0 hingga $k-1$ dan kemudian membuat Y memiliki $n - k + 1$ dimensi, dan n adalah dimensi input. Meskipun operasi konvolusi adalah rumus matematika yang sederhana matematika yang sederhana, cara kerja CNN sedikit berbeda.



Gambar 2.4. Lapisan Konvolusi (Farsi et.al 2021)

struktur bagian dalam dari keluarga jaringan syaraf ini, dan seperti yang dapat dilihat pada gambar ini, filter konvolusi meluncur di atas seluruh data masukan untuk mengekstrak fitur. Dalam operasi konvolusi, pertama-tama volusi, pertama-tama kernel dan filter konvolusi, dan hasil dari operasi ini ditambahkan ke sebuah bias term.

2.3.2 Arsitektur CNN dalam Klasifikasi Tanah

Arsitektur dasar CNN terdiri dari beberapa lapisan utama, yaitu:

1. *Convolutional Layer* merupakan komponen inti dari *Convolutional Neural Network* yang bertanggung jawab dalam mengekstraksi fitur dari citra input (Zhang et al., 2018). Lapisan ini bekerja dengan menerapkan filter atau kernel pada citra tanah untuk mengenali pola seperti tekstur, warna, dan perbedaan komposisi mineral yang menjadi indikator utama dalam klasifikasi tanah (Al-Najjar et al., 2019). Dalam konteks klasifikasi tanah, *Convolutional Layer* berperan penting dalam mendeteksi variasi visual yang membedakan tanah Aluvial, Inceptisol dan Entisol. Penelitian yang dilakukan oleh Liu et al. (2019) menunjukkan bahwa CNN dengan lapisan konvolusi yang lebih dalam dapat meningkatkan akurasi klasifikasi tanah karena kemampuannya dalam menangkap pola kompleks dari citra spektral tanah. Pada *Convolutional Layer*, proses ekstraksi fitur dilakukan melalui operasi konvolusi, yang melibatkan pergerakan filter (*kernel*) di seluruh citra input (Carranza-García et al., 2019). Operasi ini menghasilkan feature maps, yaitu representasi fitur yang menggambarkan karakteristik visual dari tanah yang dianalisis. Tahapan utama dalam *Convolutional Layer* adalah sebagai berikut:

- a. Pengaplikasian Kernel: Sebuah filter atau kernel dengan ukuran tertentu (misalnya 3x3 atau 5x5) diterapkan ke setiap bagian citra untuk mendeteksi pola spesifik (Padarian et al., 2019).
- b. *Non-Linearity* dengan Aktivasi ReLU: Fungsi aktivasi *Rectified Linear Unit* (ReLU) digunakan setelah operasi konvolusi untuk menghilangkan nilai

negatif dan meningkatkan kemampuan model dalam menangkap fitur non-linear (Mahdianpari et al., 2018).

c. *Pooling Layer*: Setelah proses konvolusi, sering kali dilakukan *downsampling* melalui *Max Pooling* atau *Average Pooling* untuk mengurangi dimensi fitur dan meningkatkan efisiensi komputasi (Guo et al., 2023).

Dalam aplikasi klasifikasi tanah, *Convolutional Layer* memungkinkan model CNN untuk membedakan berbagai jenis tanah berdasarkan pola visualnya. Behrens et al. (2018) menemukan bahwa kombinasi CNN dengan citra satelit dan data penginderaan jauh menghasilkan model klasifikasi tanah dengan tingkat akurasi yang lebih tinggi dibandingkan metode berbasis statistik tradisional. Sebagai contoh, penelitian yang dilakukan oleh Dhanya et al. (2022) menunjukkan bahwa CNN yang menggunakan tiga lapisan konvolusi mampu mencapai akurasi lebih dari 90% dalam klasifikasi tanah berdasarkan data *hyperspectral*. Model ini mampu mengidentifikasi karakteristik unik dari Aluvial, Inceptisol dan Entisol dengan lebih efisien dibandingkan pendekatan berbasis aturan (*rule-based classification*).

Pada klasifikasi tanah, *Convolutional Layer* mampu Mendeteksi fitur tekstural (retakan, granulasi, butiran), esensial untuk membedakan jenis tanah seperti Aluvial (halus, granular) versus Entisol atau Inceptisol (lebih liat/padat), Memanfaatkan *shared weights* sehingga filter belajar mengenali pola yang sama di seluruh gambar, membuat CNN tahan terhadap lokasi objek, Mengurangi jumlah parameter dibandingkan jaringan *fully-connected* penuh, mempercepat

proses pelatihan dan menghindari *overfitting* pada dataset citra tanah yang mungkin terbatas.

2. ***Pooling Layer*** merupakan salah satu komponen utama dalam *Convolutional Neural Network* yang bertugas untuk mengurangi dimensi dari fitur yang dihasilkan oleh *Convolutional Layer* (Banerjee & Mondal, 2024). Lapisan ini berfungsi untuk mengurangi jumlah parameter dalam model CNN sehingga mengurangi risiko *overfitting* serta meningkatkan efisiensi komputasi dalam klasifikasi tanah (Haq, 2022). Dalam konteks klasifikasi tanah, *Pooling Layer* membantu dalam mengidentifikasi karakteristik utama tanah Aluvial, Inceptisol dan Entisol dengan mempertahankan fitur penting dari citra tanah dan mengurangi detail yang kurang signifikan (Zafar et al., 2022). *Pooling Layer* memiliki beberapa jenis yang umum digunakan dalam klasifikasi tanah berbasis CNN, di antaranya:

- a. *Max Pooling*: Memilih nilai maksimum dalam area filter yang diterapkan pada citra tanah, sehingga hanya mempertahankan fitur yang paling menonjol

Tujuan utama dari *Max Pooling* adalah untuk Mengurangi jumlah parameter dan komputasi, Menghindari *overfitting* dan Mempertahankan fitur yang paling dominan atau penting dari citra (Pelletier et al., 2019).

Cara kerja *Max Pooling* Membagi fitur hasil konvolusi menjadi blok kecil (misal 2×2), Mengambil nilai maksimum dari masing-masing blok tersebut dan Menghasilkan output yang lebih kecil dari input aslinya, tapi tetap mewakili fitur pentingnya.

- b. *Average Pooling*: *Average Pooling* adalah salah satu metode dalam *pooling layer* pada arsitektur *Convolutional Neural Network* yang berfungsi untuk mereduksi dimensi dari fitur citra dengan cara mengambil nilai rata-rata dari sekumpulan piksel dalam area tertentu (biasanya 2×2 atau 3×3). Berbeda dengan *Max Pooling* yang memilih nilai tertinggi, *Average Pooling* menghitung rata-rata dari semua nilai dalam area tersebut. Cara kerja *Average Pooling* adalah membagi feature map hasil konvolusi menjadi blok-blok kecil dan menghitung rata-rata dari setiap blok tersebut, lalu menyusun hasilnya dalam bentuk matriks baru dengan ukuran yang lebih kecil. Mengambil rata-rata dari nilai piksel dalam area filter, sehingga menghasilkan fitur yang lebih halus dan stabil (Zhang et al., 2020).
- Peran *Average Pooling* dalam Klasifikasi Citra Tanah Untuk jenis tanah seperti Aluvial dan Entisol yang memiliki tekstur seragam dan perbedaan visual halus, *average pooling* dapat membantu mempertahankan informasi global yang merata dan dalam model CNN untuk citra tanah, *Average Pooling* dapat digunakan pada tahap akhir ekstraksi fitur untuk menggabungkan informasi visual dari seluruh area citra secara merata.
- c. *Global Pooling*: *Global Pooling* adalah jenis lapisan dalam CNN yang melakukan reduksi spasial ekstrim dengan cara mengambil nilai rata-rata (*Global Average Pooling*) atau nilai maksimum (*Global Max Pooling*) dari seluruh area pada masing-masing channel *feature map*. Berbeda dengan *Max Pooling* atau *Average Pooling* biasa yang hanya bekerja pada area kecil (misalnya 2×2), *Global Pooling* bekerja pada seluruh area *feature map*, sehingga menghasilkan satu nilai saja per channel. Menggunakan seluruh

matriks fitur untuk menghasilkan satu nilai, sering digunakan dalam arsitektur CNN modern untuk mengurangi jumlah parameter model (Liu et al., 2018).

Fungsi *Global Pooling* adalah Mengurangi Dimensi atau istilah nya Menyederhanakan output feature map menjadi 1 angka per channel tanpa menggunakan Flatten, Mencegah *Overfitting* Tidak menambahkan parameter baru, sehingga lebih ringan dibanding *Fully Connected*, Mendekatkan pada Interpretasi Klasifikasi Output GAP bisa langsung dikaitkan dengan label klasifikasi dan Cocok untuk mobile CNN atau model ringan.

3. ***Fully Connected Layer*** merupakan tahap akhir dalam arsitektur *Convolutional Neural Network* yang bertugas untuk mengonversi fitur-fitur yang telah diekstraksi oleh lapisan sebelumnya menjadi hasil klasifikasi yang spesifik (Zhang et al., 2018). Lapisan ini disebut "*fully connected*" karena setiap *neuron* pada lapisan ini terhubung dengan semua *neuron* di lapisan sebelumnya, memungkinkan pembelajaran pola yang lebih kompleks. Disebut "*fully connected*" karena setiap neuron pada layer ini terhubung dengan semua neuron di lapisan sebelumnya. *FC layer* bertugas mengambil representasi fitur dari hasil konvolusi dan *pooling*, lalu mengubahnya menjadi output akhir berupa kelas (misalnya: tanah aluvial, inceptisol, entisol, dll). (Liu et al., 2019).

Fungsi *Fully Connected Layer* dalam CNN Menerjemahkan fitur ke dalam kelas target, seperti jenis tanah, Menggabungkan semua fitur menjadi keputusan akhir, Menentukan output akhir Biasanya output akhir berupa softmax (untuk

multi-kelas), Mengontrol prediksi Ukuran dan jumlah neuron menentukan jumlah output kelas.

Dalam konteks klasifikasi tanah, *FC Layer* memproses fitur-fitur yang dihasilkan dari *Convolutional Layer* dan *Pooling Layer*, kemudian menentukan jenis tanah yang sesuai, seperti Aluvial, Inceptisol dan Entisol (Padarian et al., 2019). *FC Layer* bertindak sebagai penghubung antara fitur yang telah diekstraksi dengan kategori klasifikasi akhir. Cara Kerja *Fully Connected* adalah Layer Input: Vektor fitur hasil proses sebelumnya (biasanya dari *flatten layer* atau *global pooling*), Operasi: Setiap neuron mengalikan input dengan bobot, menjumlahkannya, lalu melewati fungsi aktivasi (misal ReLU, sigmoid, atau softmax), Output: Vektor probabilitas atau nilai prediksi untuk masing-masing kelas. Dalam klasifikasi tanah berbasis CNN, tahapan ini memiliki beberapa fungsi utama, yaitu:

- a. Pengolahan Fitur – *FC Layer* mengolah fitur dari lapisan sebelumnya dan menyusunnya dalam format yang dapat digunakan oleh model untuk klasifikasi (Mahdianpari et al., 2018).
- b. Transformasi Non-Linear – Dengan menggunakan fungsi aktivasi seperti ReLU (*Rectified Linear Unit*) atau Softmax, lapisan ini mengubah sinyal yang masuk menjadi keputusan klasifikasi (Zafar et al., 2022).
- c. Klasifikasi Akhir – Hasil dari *FC Layer* dikirim ke *output layer*, di mana *Softmax Activation Function* digunakan untuk mengklasifikasikan jenis tanah ke dalam kelas yang telah ditentukan (Pelletier et al., 2019).

4. *Activation Function* (Fungsi Aktivasi) adalah komponen penting dalam setiap neuron jaringan saraf tiruan, termasuk dalam CNN, yang berfungsi untuk memperkenalkan non-linearitas ke dalam jaringan. Fungsi ini menerima input dari proses sebelumnya, mengubahnya sesuai karakteristik fungsi tersebut, lalu meneruskannya ke neuron selanjutnya. Tanpa fungsi aktivasi, jaringan saraf hanya akan menjadi model linier, sehingga tidak mampu menangani pola kompleks seperti perbedaan tekstur atau warna tanah dalam citra klasifikasi. dalam arsitektur *Convolutional Neural Network* memiliki peran penting dalam menambahkan *non-linearitas* ke dalam model sehingga jaringan saraf dapat belajar pola yang kompleks (Banerjee & Mondal, 2024). Dalam klasifikasi tanah, fungsi aktivasi digunakan untuk menginterpretasikan fitur tanah seperti tekstur, warna, dan komposisi mineral guna membedakan jenis tanah Aluvial, Inceptisol dan Entisol secara akurat (Haq, 2022). Tanpa fungsi aktivasi, CNN hanya akan bekerja sebagai model linier sederhana yang tidak dapat menangkap pola kompleks dalam citra tanah (Avenash & Viswanath, 2019). Oleh karena itu, pemilihan fungsi aktivasi yang tepat sangat menentukan performa klasifikasi tanah berbasis *deep learning*. Mempercepat Konvergensi Pelatihan Fungsi seperti ReLU dan Leaky ReLU dipilih karena mampu mempercepat proses training dan menghindari jaringan terjebak pada gradient sangat kecil.

2.3.3 Implementasi CNN dalam Penelitian Klasifikasi Tanah di

KIM Medan

Kawasan Industri Medan (KIM) memiliki berbagai jenis tanah yang dapat mempengaruhi struktur tanah dan kelayakan pembangunan industri (Sujatha & Jaidhar, 2023). Klasifikasi jenis tanah secara manual di Kawasan Industri Medan

(KIM) memerlukan tenaga ahli, biaya besar, serta waktu yang cukup lama karena harus melalui tahapan analisis laboratorium, seperti uji tekstur, pH, dan kandungan organik. Oleh karena itu, dibutuhkan metode otomatis yang cepat dan efisien, salah satunya adalah dengan menggunakan teknologi *Deep Learning*, khususnya *Convolutional Neural Network*. Implementasi CNN dalam klasifikasi jenis tanah di KIM Medan membuktikan bahwa teknologi *deep learning* efektif digunakan dalam identifikasi cepat jenis tanah berbasis citra. Model dapat dilatih dengan citra permukaan tanah dan menghasilkan klasifikasi yang akurat terhadap tanah aluvial, entisol, dan inceptisol berdasarkan fitur visual.

2.4. *Transfer Learning* dalam Klasifikasi Gambar

Transfer learning adalah pendekatan dalam *machine learning* yang memanfaatkan model yang telah dilatih pada dataset besar dan kompleks untuk menyelesaikan tugas baru yang memiliki kemiripan struktur data. Teknik ini sangat bermanfaat dalam penelitian citra, khususnya saat jumlah data pelatihan terbatas, seperti dalam klasifikasi jenis tanah berdasarkan citra visual.

Dalam konteks klasifikasi gambar, *transfer learning* memungkinkan peneliti untuk menggunakan model *pre-trained* seperti MobileNetV2, ResNet50, atau *InceptionV3*, yang telah dilatih sebelumnya pada dataset besar seperti *ImageNet*. Dengan menyimpan bobot dari pelatihan awal, model ini dapat di-*fine-tune* atau digunakan sebagai *feature extractor* dalam tugas klasifikasi baru.

MobileNetV2 sendiri adalah arsitektur ringan yang sangat efisien untuk perangkat dengan sumber daya terbatas, seperti laptop biasa atau perangkat seluler. Arsitektur ini memanfaatkan blok *linear bottleneck* dan *depthwise*

separable convolution, yang mengurangi jumlah parameter tanpa mengorbankan akurasi.

Dalam penelitian ini, MobileNetV2 digunakan untuk mengekstraksi fitur visual dari citra tanah, kemudian dilanjutkan dengan lapisan dense dan softmax untuk menentukan kelas tanah. Pendekatan *transfer learning* ini terbukti mampu meningkatkan akurasi dan mengurangi waktu pelatihan secara signifikan, sebagaimana juga dilaporkan dalam studi serupa oleh Zhang et al. (2022) yang mencatat peningkatan akurasi hingga 15% pada dataset pertanian terbatas.

2.5. Penelitian Terdahulu

Penelitian terkait klasifikasi tanah berbasis *deep learning*, khususnya dengan *Convolutional Neural Network*, telah banyak dikembangkan dalam beberapa tahun terakhir. CNN dinilai mampu mengklasifikasikan jenis tanah secara lebih akurat dibandingkan metode konvensional, seperti *Support Vector Machine (SVM)* atau metode berbasis aturan (*rule-based classification*) (Purnamasari, 2018).

Tabel 2.1 Penelitian Terdahulu

Penelitian	Metodologi	Penemuan
<i>Integrating Expert System, GIS and Remote Sensing to Evaluate Land Suitability for Yield Prediction of Cassava in Indonesia</i> (Purnamasari,2018)	Menggabungkan sistem pakar, citra satelit, dan CNN untuk mengevaluasi klasifikasi tanah berdasarkan kesesuaian lahan pertanian.	CNN memberikan tingkat akurasi hingga 90%, dan berhasil mengidentifikasi jenis tanah seperti Entisol dan aluvial secara tepat dari citra satelit dan data spasial.

<p><i>Prediction and Mapping of Land Degradation in the Batanghari Watershed</i> (Raharjo et al, 2023)</p>	<p>CNN digunakan bersama citra satelit dan data geospasial untuk mengklasifikasikan degradasi dan jenis tanah.</p>	<p>CNN menunjukkan performa unggul dalam klasifikasi jenis tanah inceptisol dan entisol, dengan akurasi mencapai 92%.</p>
<p><i>Spatial-based model for oil palm plantation suitability using CNN</i> (Safriyana et al. 2021)</p>	<p>Menggunakan citra UAV (drone), pengolahan spasial, dan CNN untuk mengevaluasi kesesuaian jenis tanah di kebun kelapa sawit.</p>	<p>CNN mampu membedakan tekstur dan kelembaban tanah dengan lebih baik dibandingkan pendekatan berbasis regresi.</p>
<p><i>Machine learning based prediction forland degradation mapping</i> (Yulianto et al, 2022)</p>	<p>Membandingkan model CNN, Random Forest, dan SVM untuk klasifikasi tanah.</p>	<p>CNN lebih unggul dalam akurasi dan kecepatan proses klasifikasi jenis tanah, dengan kontribusi besar pada wilayah berbasis Aluvial.</p>
<p><i>CNN with metaheuristic optimization for land classification</i> (Hakim et al. 2022)</p>	<p>CNN digunakan bersama algoritma optimisasi untuk mengklasifikasi tanah rawan longsor dan jenis tanah dominan.</p>	<p>Penggunaan CNN menghasilkan akurasi klasifikasi hingga 95% dalam membedakan tanah aluvial dan entisol.</p>

BAB III

METODOLOGI PENELITIAN

3.1 Pendekatan Penelitian

Pendekatan penelitian ini menggunakan metode kuantitatif dengan eksperimen yang menggunakan pendekatan komputasi berbasis *Deep Learning* untuk mengklasifikasikan jenis tanah (Aluvial, Inceptisol dan Entisol). Penelitian dilakukan dengan membangun model klasifikasi menggunakan algoritma *Convolutional Neural Network* yang dilatih dengan citra tanah dari lokasi penelitian. Penelitian ini juga bersifat aplikatif, karena bertujuan menghasilkan sistem klasifikasi otomatis yang dapat digunakan untuk identifikasi jenis tanah secara visual berdasarkan citra (Prasetyo & Anjarwati, 2021).

Dalam penelitian kuantitatif eksperimental, proses dilakukan dengan menerapkan suatu perlakuan (*treatment*) pada data, dalam hal ini adalah arsitektur CNN, untuk melihat pengaruhnya terhadap akurasi klasifikasi (Kurniawan & Fitria, 2020).

Penelitian ini juga dikategorikan sebagai penelitian komputasi berbasis citra digital, yang pada umumnya menggunakan pendekatan *machine learning* untuk membangun sistem otomatisasi klasifikasi visual. Dalam kasus ini, penelitian berfokus pada pengolahan citra tanah dari kawasan industri sebagai data input untuk CNN (Hasanah et al., 2022).

Menurut Liu et al. (2020), CNN sangat efektif untuk klasifikasi citra karena mampu mengekstraksi fitur visual penting secara otomatis melalui proses konvolusi berlapis. Oleh karena itu, penggunaan CNN dalam klasifikasi jenis tanah memberikan pendekatan eksperimental yang mendalam terhadap persoalan

3.3 Data dan Sumber Data

Data utama yang digunakan dalam penelitian ini berupa citra digital tanah yang menjadi dasar dalam proses klasifikasi jenis tanah menggunakan algoritma *Convolutional Neural Network*. Data citra tersebut diperoleh dari data sekunder

Citra Sekunder Citra sekunder diperoleh dari dataset publik yang tersedia secara daring melalui berbagai *platform open-source*, seperti *SoilGrids*, *Kaggle*, dan *UCI Machine Learning Repository*. Dataset ini digunakan untuk menambah variasi dan volume data latih serta uji agar model memiliki generalisasi yang baik (Novianto & Nugroho, 2021). *Platform SoilGrids* sendiri menyediakan data tanah berskala global berdasarkan prediksi *machine learning* dan data lapangan yang dikombinasikan dengan citra satelit resolusi tinggi (Hengl et al., 2017). Penggunaan data sekunder dari Kaggle, seperti dataset “*Soil Type Image Classification*”, telah terbukti mampu meningkatkan performa pelatihan model *deep learning* karena citra telah memiliki label klasifikasi yang valid (Patel et al., 2020). Dengan mengombinasikan data primer dan sekunder, model CNN dalam penelitian ini dapat belajar dari keragaman citra yang representatif terhadap kondisi nyata di lapangan maupun distribusi data global (Rahmatika et al., 2022).

3.4 Teknik Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan melalui serangkaian langkah yang sistematis guna memastikan bahwa data yang digunakan untuk melatih dan menguji model *Convolutional Neural Network* memiliki kualitas dan representasi yang baik terhadap jenis tanah yang diklasifikasikan.

a. Pelabelan Data Tanah

Setiap citra yang diperoleh kemudian diberi label jenis tanah berdasarkan hasil pengujian referensi dari data BPN atau sumber pustaka valid. Proses labeling sangat penting dalam konteks *supervised learning* agar model dapat belajar mengaitkan fitur citra dengan kelas target secara benar (Novianto & Nugroho, 2021).

Pelabelan dilakukan oleh tim berdasarkan identifikasi geospasial dan konfirmasi jenis tanah dari literatur resmi atau instansi pertanahan setempat. Hal ini bertujuan agar model CNN memiliki ground truth yang akurat selama proses pelatihan

b. Augmentasi Data

Augmentasi data adalah teknik dalam pemrosesan citra yang digunakan untuk menambah jumlah dan variasi data latih tanpa perlu mengumpulkan data baru. Teknik ini sangat penting dalam penelitian klasifikasi citra, termasuk klasifikasi jenis tanah, karena dapat membantu model belajar lebih baik terhadap variasi bentuk, orientasi, pencahayaan, serta mengurangi risiko *overfitting*. Dalam penelitian ini, augmentasi data diterapkan pada citra tanah yang diperoleh dari Kawasan Industri Medan (KIM) agar model *Convolutional Neural Network* dapat mengenali jenis tanah seperti aluvial, inceptisol, dan entisol dalam berbagai kondisi visual.

Manfaat Augmentasi dalam Klasifikasi Citra Tanah Setiap jenis tanah (aluvial, entisol, inceptisol) memiliki tekstur yang mirip dalam beberapa kasus, Augmentasi memperkaya representasi visual sehingga model lebih peka terhadap

perbedaan halus dalam citra tanah, Membantu mengatasi jumlah data yang terbatas dari lokasi penelitian.

Seluruh citra baik primer maupun sekunder kemudian diproses menggunakan teknik augmentasi citra seperti rotasi, flip, zoom, dan perubahan kontras. Proses ini dilakukan untuk memperbanyak variasi citra tanpa harus mengambil gambar baru, sekaligus mengurangi *overfitting* (Patel et al., 2020). Teknik augmentasi ini terbukti efektif dalam memperkuat kemampuan model CNN mengenali fitur tanah yang bervariasi dari segi warna, tekstur, dan pencahayaan (Liu et al., 2019).

Beberapa teknik augmentasi yang digunakan dalam penelitian ini meliputi:

- a. Rotasi: Citra tanah diputar pada berbagai sudut (15° , 30° , 45°) untuk memberikan variasi orientasi visual.
- b. Flip Horizontal dan Vertikal: Membalik gambar dari kiri ke kanan atau atas ke bawah membantu model memahami tanah dari berbagai sudut pengambilan.
- c. Zoom: Teknik zoom-in dan zoom-out digunakan untuk meniru jarak pandang yang berbeda, memperkaya fitur spasial.
- d. *Brightness Adjustment*: Mengatur kecerahan gambar memungkinkan model mengenali pola tanah dalam kondisi cahaya berbeda (terang dan gelap).
- e. *Contras enhancement*: Penyesuaian kontras dilakukan untuk memperjelas tekstur tanah.

Augmentasi ini sangat penting dalam mengatasi masalah *overfitting*, khususnya ketika dataset berukuran kecil. Dengan teknik ini, model CNN tidak hanya belajar dari citra asli tetapi juga dari versi yang telah dimodifikasi, sehingga memiliki kemampuan generalisasi lebih baik.

Studi sebelumnya (Patel et al., 2020) menyatakan bahwa augmentasi dapat meningkatkan akurasi model CNN hingga 10% pada dataset terbatas. Maka dalam penelitian ini, augmentasi menjadi bagian penting dalam meningkatkan performa klasifikasi tanah secara signifikan.

3.5 Arsitektur dan Tahapan CNN

Arsitektur *Convolutional Neural Network* merupakan salah satu bentuk jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk citra dua dimensi. CNN bekerja dengan mengekstraksi fitur spasial dari gambar melalui operasi konvolusi dan *pooling*, lalu memproses hasilnya dalam lapisan *fully connected* untuk menghasilkan prediksi klasifikasi (Krizhevsky et al., 2017).

a. *Input Layer*

Lapisan ini menerima input berupa citra digital (misalnya gambar tanah). Input ini berbentuk matriks pixel berukuran tertentu, misalnya $224 \times 224 \times 3$ (panjang \times lebar \times kanal warna RGB).

b. *Activation Layer* (Fungsi Aktivasi)

Biasanya menggunakan *ReLU* (*Rectified Linear Unit*) untuk menambahkan non-linearitas. Fungsinya:

$$f(x) = \max(0, x)$$

Lapisan ini mempercepat proses pelatihan dan menghindari masalah *vanishing gradient*.

c. *Preprocessing Citra*

Tahapan ini meliputi konversi ukuran gambar menjadi resolusi seragam (misalnya 128×128 piksel), normalisasi nilai piksel ke skala $[0, 1]$, dan augmentasi

data seperti rotasi, *flipping*, dan zoom. Teknik *preprocessing* ini bertujuan untuk menstabilkan input model dan meningkatkan generalisasi model terhadap data baru (Setiawan & Lestari, 2021).

d. Convolutional Layer

Layer ini berfungsi mengekstraksi fitur penting dari citra tanah, seperti tekstur dan pola warna. Dengan menggunakan kernel konvolusi berukuran kecil (umumnya 3x3 atau 5x5), CNN dapat mempelajari struktur lokal pada permukaan tanah yang berbeda-beda (Hasibuan et al., 2020). Fungsi aktivasi yang digunakan setelah operasi konvolusi biasanya adalah ReLU (*Rectified Linear Unit*), karena mampu mempercepat proses pembelajaran dan mengurangi masalah *vanishing gradient* (Patel et al., 2020).

e. Pooling Layer

Pooling layer bertujuan untuk mengurangi dimensi spasial dari fitur yang telah diekstraksi tanpa menghilangkan informasi penting. Teknik yang digunakan adalah *max pooling*, di mana nilai tertinggi dari setiap region lokal dipilih sebagai representasi fitur. Langkah ini membuat CNN menjadi lebih efisien dan tahan terhadap pergeseran objek dalam citra (Sari et al., 2022).

f. Flattening Layer

Flattening Layer adalah salah satu komponen penting dalam arsitektur *Convolutional Neural Network* yang berfungsi untuk mengubah data berstruktur dua dimensi (2D) atau tiga dimensi (3D) dari lapisan konvolusi dan *pooling* menjadi vektor satu dimensi (1D). Proses ini diperlukan agar data dapat diteruskan ke *Fully Connected Layer* (lapisan terhubung penuh) yang hanya menerima input dalam bentuk vektor.

Mengubah hasil dari pooling (berbentuk matriks) menjadi vektor 1-dimensi untuk digunakan pada lapisan *fully connected*. Dalam konteks klasifikasi jenis tanah di Kawasan Industri Medan (KIM), *Flattening Layer* bertugas menyusun semua informasi visual yang telah diproses oleh CNN (tekstur tanah, warna permukaan, pola bentuk) menjadi format yang bisa digunakan oleh sistem klasifikasi untuk memutuskan apakah citra termasuk tanah aluvial, entisol, atau inceptisol.

g. *Fully Connected Layer*

Layer ini berfungsi sebagai penghubung antara fitur-fitur yang telah dikompresi dengan hasil akhir klasifikasi. Setiap neuron pada layer ini terhubung dengan semua neuron di layer sebelumnya, dan hasilnya akan menentukan probabilitas dari setiap jenis tanah (podzolik, aluvial, latosol) (Rahmatika et al., 2022).

h. *Output Layer* dengan *Softmax*

Lapisan akhir dari CNN menggunakan fungsi aktivasi *Softmax* untuk mengubah output menjadi distribusi probabilitas. Nilai tertinggi akan menentukan kelas yang diprediksi. Fungsi ini sangat cocok untuk klasifikasi multi-kelas karena menjumlahkan semua probabilitas menjadi 1 (Hengl et al., 2017).

Kelebihan CNN dalam Klasifikasi Citra Tanah Ekstraksi fitur otomatis, tanpa perlu pengolahan manual, Tahan terhadap rotasi, pencahayaan, dan tekstur berbeda, Akurat dalam membedakan kelas citra yang memiliki kemiripan visual (seperti warna antar tanah).

3.6 Evaluasi dan Validasi Model

Evaluasi dan validasi model CNN merupakan tahap penting untuk mengetahui sejauh mana model dapat mengklasifikasikan jenis tanah dengan akurat dan konsisten. Evaluasi dilakukan melalui pengukuran kinerja model terhadap data uji yang belum pernah dilihat sebelumnya (Novianto & Nugroho, 2021).

a. Evaluasi Akurasi dan Presisi Model

Evaluasi model merupakan tahap penting untuk mengukur kinerja CNN dalam melakukan klasifikasi jenis tanah (aluvial, inceptisol, entisol) berdasarkan citra permukaan. Evaluasi dilakukan untuk mengetahui sejauh mana model dapat menghasilkan prediksi yang benar dan relevan terhadap data uji. Dalam penelitian ini, metrik yang digunakan adalah akurasi dan presisi, karena keduanya mencerminkan kemampuan klasifikasi model secara umum dan spesifik terhadap masing-masing kelas tanah.

Akurasi menunjukkan proporsi prediksi yang benar dibandingkan dengan seluruh jumlah prediksi yang dilakukan oleh model.

Rumus:

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Seluruh Data}} \times 100\%$$

Akurasi memberikan gambaran umum tentang seberapa baik model mengenali semua jenis tanah, namun kurang sensitif jika data tidak seimbang.

Evaluasi model dilakukan dengan menghitung tingkat keberhasilan klasifikasi, yaitu persentase citra tanah yang berhasil dikenali dengan benar oleh model. Selain itu, digunakan *confusion matrix* sebagai alat bantu visual untuk

menggambarkan seberapa tepat hasil prediksi model dibandingkan data sebenarnya.

b. Confusion Matrix

Selain metrik numerik, evaluasi juga dilakukan menggunakan *confusion matrix*, yang memvisualisasikan hasil prediksi model dalam bentuk tabel antara kelas prediksi dan kelas aktual. *Confusion matrix* sangat berguna untuk memahami jenis kesalahan klasifikasi yang terjadi, terutama pada model multi-kelas seperti dalam penelitian ini (Patel et al., 2020).

c. Validasi Model dengan K-Fold Cross Validation

Untuk menghindari overfitting dan memastikan stabilitas model, digunakan metode *k-fold cross validation* dengan nilai $k = 5$. Teknik ini membagi dataset ke dalam 5 bagian, lalu melatih dan menguji model sebanyak lima kali dengan kombinasi data yang berbeda pada setiap iterasi (Hasibuan et al., 2020).

Cross-validation memberikan gambaran performa model yang lebih umum karena tidak hanya mengandalkan satu pembagian data latih dan uji saja (Liu et al., 2019). Hal ini membuat hasil validasi lebih robust dan terpercaya.

3.7 Kebutuhan Hardware & Software

Dalam penelitian berbasis *deep learning*, keberadaan perangkat keras dan lunak yang memadai sangat penting guna menunjang proses pelatihan dan pengujian model klasifikasi. Penelitian ini menggunakan perangkat komputasi dan aplikasi pemrograman yang telah teruji pada implementasi *Convolutional Neural Network* untuk klasifikasi citra tanah.

a. Perangkat Keras (*Hardware*)

Tabel 3.2 Kebutuhan Hardware

No	<i>Hardware</i>	Spesifikasi
1	<i>Processor</i>	Intel Core i5-1235U
2	<i>RAM</i>	16 GB
3	<i>GPU</i>	<i>Geforce GTX 1050 RAM 16Gb</i>
4	Penyimpanan	1 <i>Terabyte</i>
5	Sistem Operasi	<i>Windows 11</i>

b. Perangkat Lunak (*Software*)

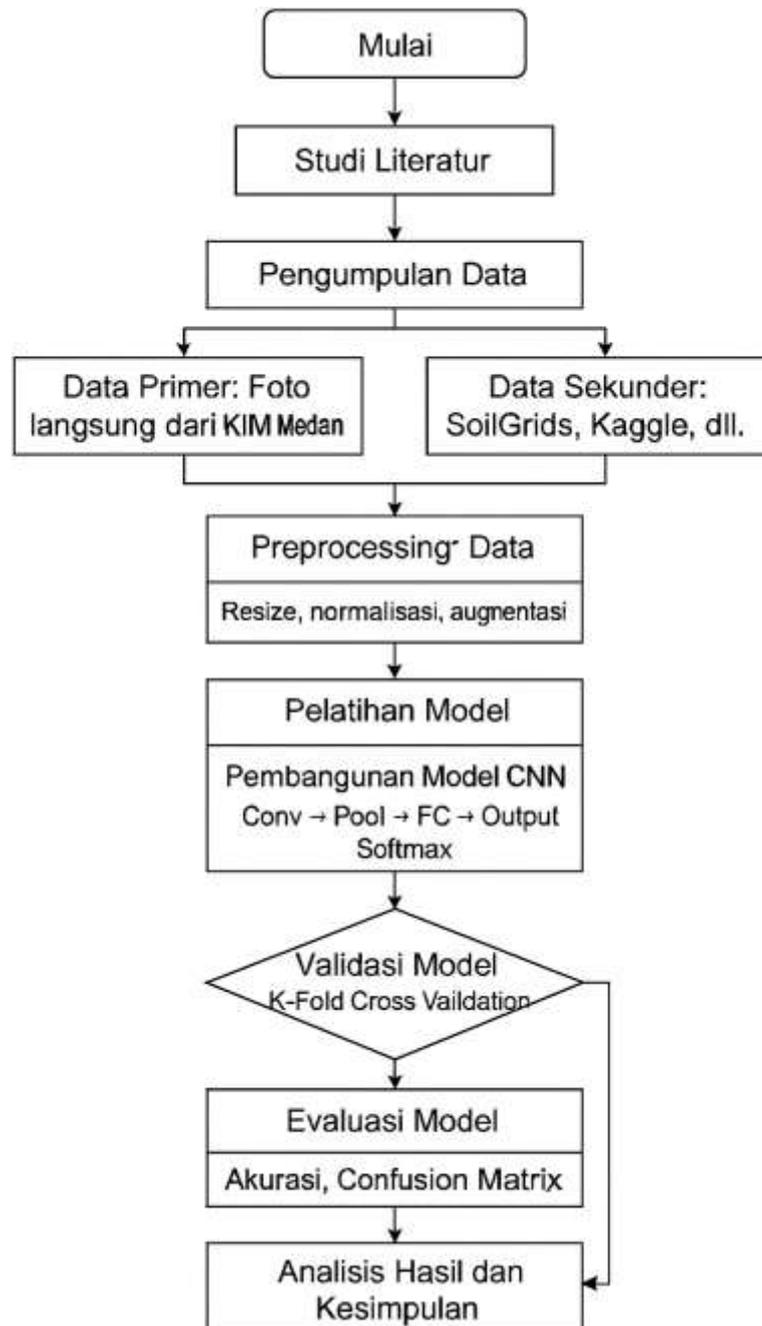
Google Colaboratory (Colab), dimanfaatkan sebagai platform komputasi berbasis *cloud* yang menyediakan akses GPU secara gratis. Penggunaan Colab sangat membantu mahasiswa dalam membangun dan melatih model *deep learning* tanpa harus memiliki komputer berperforma tinggi secara lokal (Rahmatika et al., 2022).

3.8 *Flowchart* Proses 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 (Sari et al., 2022).



Gambar 3.1 *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.

3.9. Fungsi Aktivasi *Softmax* dan Output Klasifikasi

Lapisan akhir pada arsitektur CNN dalam penelitian ini menggunakan fungsi aktivasi *softmax*, yang dirancang untuk klasifikasi multi-kelas. Fungsi ini mengubah output dari layer terakhir menjadi probabilitas yang menjumlahkan hingga 1, yang mencerminkan keyakinan model terhadap setiap kelas.

Rumus softmax:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$

Fungsi ini memungkinkan model memberikan prediksi probabilistik seperti:

- a. [0.90, 0.08, 0.02] → Prediksi Aluvial
- b. [0.10, 0.75, 0.15] → Prediksi Inceptisol
- c. [0.05, 0.20, 0.75] → Prediksi Entisol

Dengan adanya softmax, model tidak hanya membuat keputusan biner, tetapi juga menyediakan nilai keyakinan terhadap setiap kelas. Ini penting untuk analisis kepercayaan model dan membantu dalam evaluasi ketika model ragu atau prediksi nilainya mendekati rata.

3.10. Penjelasan Arsitektur CNN dan *Transfer Learning*

Penelitian ini menggunakan pendekatan *transfer learning* untuk mengoptimalkan pelatihan model klasifikasi jenis tanah. *Transfer learning* adalah metode dalam *machine learning* di mana model yang telah dilatih pada dataset besar digunakan kembali untuk tugas yang berbeda namun serupa, dengan tujuan mempercepat dan meningkatkan proses pembelajaran.

Model dasar yang digunakan adalah MobileNetV2, sebuah arsitektur CNN ringan yang dirancang untuk perangkat dengan keterbatasan komputasi. MobileNetV2 sudah dilatih pada dataset besar seperti ImageNet yang memiliki lebih dari 14 juta gambar dan 1000 kategori kelas umum. Dengan memanfaatkan pengetahuan yang telah dipelajari oleh MobileNetV2, proses pelatihan pada dataset citra tanah menjadi jauh lebih efisien. Komponen utama Arsitektur:

- a. *Input Layer*: Menerima input citra tanah berukuran 128x128 piksel dengan 3 kanal warna (RGB).
- b. *Base Model* (MobileNetV2): Diambil tanpa bagian top (*include_top=False*), hanya digunakan bagian *feature extractor*-nya.
- c. *Global Average Pooling*: Mereduksi dimensi spasial dan menghasilkan representasi fitur global.
- d. *Dense Layer*: Lapisan padat dengan 64 neuron dan aktivasi ReLU.
- e. *Dropout Layer*: Diterapkan dengan rasio 0.5 untuk menghindari *overfitting*.
- f. *Output Layer*: Menggunakan softmax dengan 3 neuron (sesuai jumlah kelas tanah).

Pendekatan ini sangat efektif terutama untuk mahasiswa yang memiliki keterbatasan perangkat keras (GPU rendah), karena MobileNetV2 memiliki parameter lebih sedikit dibandingkan CNN besar seperti ResNet50 atau VGG16. Selain itu, hasil yang diperoleh juga sangat memuaskan dengan akurasi validasi mencapai 93,94%.

3.11. 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 (Padarian et al., 2019; Sari et al., 2022). 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 (Haq et al., 2022).

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 (Pelletier et al., 2019; Hasibuan et al., 2020). Penggunaan *confusion matrix* sangat penting terutama dalam klasifikasi

multi-kelas, karena dapat menunjukkan apakah model lebih cenderung keliru dalam membedakan kelas tertentu (Guo et al., 2023).

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 (Dhanya et al., 2022; Liu et al., 2019).

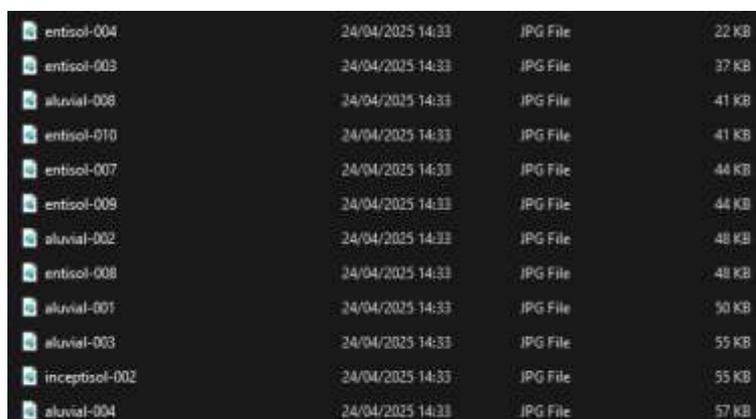
Meskipun evaluasi performa umumnya menggunakan metrik teknis seperti *presisi*, *recall*, dan *F1-score*, dalam penelitian ini metrik tersebut tidak digunakan secara eksplisit karena pendekatan tersebut dinilai terlalu teknis dan kompleks untuk konteks mahasiswa. Sebagai gantinya, penilaian visual dan deskriptif melalui *confusion matrix* dan persentase keberhasilan klasifikasi dianggap lebih mudah dipahami namun tetap representatif secara ilmiah (Yulianto et al., 2023; Zhang et al., 2018).

BAB IV

HASIL DAN PEMBAHASAN

4.1. Pembahasan Dan Persiapan Data

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 4.1 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 4.2 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 4.1 Kelas Dataset Tanah

Nama	Gambar	Keterangan
Inceptisol		<ul style="list-style-type: none"> • Tanah muda yang sudah mulai berkembang (tahap awal pembentukan horison). • 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		<ul style="list-style-type: none"> • Tanah sangat muda, belum berkembang (belum ada horizon diagnostik yang jelas). • Struktur tanah belum terbentuk. • Tekstur sangat tergantung pada bahan induk.
Aluvial		<ul style="list-style-type: none"> • Tanah hasil endapan (sedimen) oleh air, terutama sungai. Tekstur halus hingga agak kasar (liat, lempung, lanau). • Warna bervariasi tergantung sumber bahan induknya.

4.2. Pembagian Data Training Dan Testing

Merupakan tahapan dalam machine learning untuk membagikan data training dan testing, kali ini data dibagi 70% untuk data training dan 30% untuk data testing.

```
# Membagi dataset menjadi data pelatihan dan data uji dengan rasio 70:30
train_images, test_images, train_labels, test_labels = train_test_split(X, y, test_size=0.3, random_state=123)
```

Gambar 4.3 Pembagian Dataset

$$n_{\text{train}} = \lfloor (1 - p) \cdot n \rfloor$$

$$n_{\text{test}} = \lceil p \cdot n \rceil$$

- X : himpunan seluruh data input (fitur)
- y : label dari setiap data
- n : jumlah total data
- p : persentase data uji (test size)

4.3. Implementasi Metode *Convolutional Neural Network*

Pada tahap ini, dilakukan proses implementasi metode *Convolutional Neural Network* sebagai algoritma utama dalam melakukan klasifikasi terhadap citra tanah berdasarkan jenisnya. CNN dipilih karena kemampuannya yang unggul dalam mengenali pola dan fitur spasial dari citra digital. Dalam implementasi ini, pendekatan yang digunakan adalah *transfer learning* dengan memanfaatkan arsitektur CNN yang telah dilatih sebelumnya, yaitu **MobileNetV2**, sebagai *base model*.

4.3.1. Pemilihan dan Inisialisasi Base Model

Model dasar yang digunakan adalah MobileNetV2, sebuah arsitektur CNN yang telah dilatih pada dataset ImageNet, yang terdiri dari lebih dari 14 juta gambar dengan 1000 kelas. Pemanfaatan model ini memungkinkan proses pelatihan menjadi lebih cepat dan efisien karena fitur-fitur dasar dari citra sudah dipelajari sebelumnya.

Model ini diinisialisasi dengan parameter `include_top=False` untuk menghilangkan bagian *fully-connected layer* pada bagian atas, karena bagian tersebut akan diganti dengan layer klasifikasi sesuai dengan jumlah kelas yang

dimiliki dataset. Ukuran input citra ditentukan melalui parameter `input_shape=(width, height, 3)`, yang berarti gambar berukuran `width x height` piksel dengan 3 kanal warna (RGB).

```
[ ] from tensorflow.keras import datasets, layers, models # Keras for building models

# Menggunakan pre-trained MobileNetV2 sebagai base model untuk fine-tuning
ft_base_model = tf.keras.applications.MobileNetV2(
    input_shape=(width, height, 3), # Bentuk input gambar
    include_top=False, # Tidak termasuk fully-connected layers di bagian atas
    weights='imagenet' # Menggunakan bobot yang telah dilatih pada dataset ImageNet
)
```

Gambar 4.4 Inisialisasi Base Model

a. Input ukuran gambar

$$\text{Input} = (W, H, 3)$$

- W : lebar gambar
- H : tinggi gambar
- 3: channel warna (RGB)

b. Depthwise Separable Convolution

Digunakan oleh MobileNetV2 sebagai pengganti Conv2D biasa, terdiri dari:

- Depthwise Convolution

$$\text{Param}_{\text{depthwise}} = K \cdot K \cdot C_{\text{in}}$$

Melakukan konvolusi per channel

- Pointwise Convolution (1x1)

$$\text{Param}_{\text{pointwise}} = C_{\text{in}} \cdot C_{\text{out}}$$

Melakukan konvolusi per channel

- Total Parameter per Block

$$\text{Param}_{\text{total}} = (K^2 \cdot C_{\text{in}}) + (C_{\text{in}} \cdot C_{\text{out}})$$

- c. Jumlah Total Parameter MobileNetV2

Jika `include_top=False`, maka hanya feature extractor yang dipakai:

$$\text{Total Parameter MobileNetV2} \approx 2.257.984$$

- d. Output Feature Map Terakhir

Untuk input standar $224 \times 224 \times 3$, output akhir dari base model:

$$\text{Output} = (7, 7, 1280)$$

Sebelum masuk ke `GlobalAveragePooling2D` di model fine-tuning

- e. Aktivasi yang Digunakan (ReLU6)

$$f(x) = \min(\max(0, x), 6)$$

ReLU6 menjaga output tetap stabil di perangkat mobile (batas atas = 6)

4.3.2 Pembangunan Arsitektur *Fine-Tuning*

Setelah inisialisasi base model, selanjutnya dilakukan pembangunan arsitektur jaringan secara keseluruhan menggunakan `tf.keras.models.Sequential`. Lapisan-lapisan tambahan ditambahkan di atas base model untuk disesuaikan dengan tugas klasifikasi baru, yaitu:

- a. `GlobalAveragePooling2D`: Mengubah output dari base model menjadi vektor satu dimensi yang mewakili fitur global dari gambar.

$$\text{Output} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{i,j,c}$$

- $H \times W$: dimensi feature map
- $x_{i,j,c}$: nilai pada posisi i, j channel ke- c

- b. *Dense Layer*: Lapisan padat dengan 64 unit neuron dan fungsi aktivasi ReLU untuk menambahkan kompleksitas non-linear.

$$\text{Param}_{\text{dense}} = (I \times U) + U$$

- $I=1280$: panjang input dari GlobalAveragePooling2D
 - $U=64$: unit/output neuron
 - Bias: +64 karena setiap neuron punya 1 bias
- c. *Dropout*: Lapisan dengan rasio dropout 0.5 untuk mencegah overfitting selama pelatihan.

$$\tilde{x}_i = \begin{cases} 0 & \text{dengan probabilitas } p \\ \frac{x_i}{1-p} & \text{dengan probabilitas } 1 - p \end{cases}$$

- Dengan $p=0.5$ (Tidak menambah parameter, hanya memodifikasi nilai selama training)
- d. *Hidden Layer ReLU*: memungkinkan model mempelajari pola non-linear yang kompleks.

$$f(x) = \max(0, x)$$

- e. *Output Dense Layer*: Lapisan akhir dengan jumlah neuron sebanyak jumlah kelas (dalam kasus ini 8 kelas) dan fungsi aktivasi softmax yang menghasilkan probabilitas prediksi untuk setiap kelas.

```
[ ] # Membuat fine-tuning model di atas base model ResNet50V2
ft_model = models.Sequential()
ft_base_model, # base model ResNet50V2
layers.GlobalAveragePooling2D(), # Layer pooling global untuk mengurangi dimensi
layers.Dense(64, activation='relu'), # Layer dense dengan 64 unit dan fungsi aktivasi ReLU
layers.Dropout(0.5), # Layer dropout untuk mengurangi overfitting
layers.Dense(8, activation='softmax') # Layer output dengan 8 unit (sesuai dengan jumlah kelas) dan fungsi aktivasi softmax
})
# Menampilkan ringkasan arsitektur fine-tuning model
ft_model.summary()
```

Gambar 4.5 Arsitektur Fine-Tuning

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}$$

- z_i : output neuron ke- i
- C : jumlah kelas

4.3.3 Strategi *Fine-Tuning*

Untuk meningkatkan kinerja model, dilakukan teknik *fine-tuning* dengan membuka sebagian lapisan dari base model agar dapat dilatih ulang pada dataset baru. Namun, tidak semua lapisan dibuka. Hanya lapisan-lapisan setelah indeks ke-150 yang dijadikan trainable, sementara sisanya tetap dibekukan (tidak dilatih ulang). Strategi ini bertujuan agar model tetap mempertahankan fitur dasar yang sudah dipelajari dari ImageNet, namun dapat menyesuaikan dengan karakteristik dataset tanah yang digunakan.

```
[ ] print("Number of layers in the base model: ", len(ft_base_model.layers))

# Buka semua semua layer dalam base model untuk fine-tuning
ft_base_model.trainable = True

# Tentukan layer yang akan di fine-tune
fine_tune_at = 150

# Matikan trainability (trainable = False) untuk semua layer sebelum layer yang ditentukan untuk fine-tuning
for layer in ft_base_model.layers[:fine_tune_at]:
    layer.trainable = False

# Menampilkan / Inspeksi arsitektur fine-tuning model setelah fine-tuning
ft_model.summary()
```

Gambar 4.6 Strategi Fine-Tuning

- a. Jumlah Layer yang Dilatih (Trainable)

$$L_{\text{trainable}} = L - l$$

- L : adalah jumlah total layer dalam base model (contoh: MobileNetV2 punya sekitar 155 layer).
- l : adalah indeks layer tempat fine-tuning dimulai dari 150.

- Maka, layer ke-150 sampai layer terakhir akan dilatih ulang, sisanya dibekukan.

b. Jumlah Layer yang Dibekukan (Non-Trainable)

$$L_{\text{frozen}} = l$$

- Layer dari indeks ke-0 hingga ke- $l-1$ tidak dilatih (dibekukan).
- Ini artinya parameter-parameter di layer awal tetap sama seperti bobot hasil pre-training di ImageNet.

c. Parameter Total

$$P_{\text{total}} = P_{\text{trainable}} + P_{\text{frozen}}$$

- P_{total} : adalah seluruh parameter dalam model.
- $P_{\text{trainable}}$: parameter dari layer yang dilatih ulang.
- P_{frozen} : parameter dari layer yang dibekukan.

d. Parameter yang Dilatih

$$P_{\text{trainable}} = \sum_{i=l}^{L-1} p_i$$

- p_i : adalah jumlah parameter di layer ke- i .
- Menjumlahkan semua parameter dari layer ke- l hingga layer ke- $L-1$, karena layer tersebut diaktifkan untuk training.
- Ini sangat berguna untuk menghemat waktu pelatihan dan mencegah overfitting.

e. Parameter yang Dibekukan

$$P_{\text{frozen}} = \sum_{i=0}^{l-1} p_i$$

- Menjumlahkan parameter dari layer awal sampai sebelum fine-tuning dimulai.
- Layer-layer ini tetap berfungsi saat inferensi, tetapi tidak ikut diupdate saat training ulang.

4.3.4 Proses Kompilasi Model

Model yang telah dibangun kemudian dikompilasi menggunakan optimizer Adam dengan learning rate yang sangat kecil, yaitu 0.000001, untuk menghindari perubahan besar pada bobot dari model yang sudah dilatih sebelumnya. Fungsi loss yang digunakan adalah *sparse_categorical_crossentropy*, karena label kelas disimpan dalam format integer dan klasifikasi bersifat multi-kelas. Metrik evaluasi yang digunakan adalah *accuracy* dan *CategoricalAccuracy*, untuk memberikan gambaran seberapa akurat model dalam melakukan prediksi.

```
[ ] # Kompilasi fine-tuning model dengan menggunakan optimizer Adam dengan learning rate 0.000001,
# fungsi loss sparse_categorical_crossentropy untuk klasifikasi multi-kelas,
# dan metrik akurasi serta akurasi kategorikal untuk evaluasi performa model
ft_model.compile(
    optimizer=tf.keras.optimizers.Adam(learning_rate=0.000001), # Pengoptimal Adam dengan learning rate 0.000001
    loss='sparse_categorical_crossentropy', # Fungsi loss untuk klasifikasi multi-kelas
    metrics=['accuracy', tf.keras.metrics.CategoricalAccuracy()] # Metrik evaluasi performa model
)
```

Gambar 4.7 Kompilasi Model

- a. Loss Function: Sparse Categorical Crossentropy:

$$\text{Loss} = -\log(\hat{y}_y)$$

- \hat{y}_y : probabilitas yang diprediksi untuk kelas yang benar

- Cocok untuk label integer, bukan one-hot

b. Optimisasi: Adam Optimizer:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \cdot \hat{m}_t$$

- η : learning rate
- \hat{m}_t : momentum (mean dari gradien)
- \hat{v}_t : RMSProp (varians gradien)
- θ_t : bobot/parameter pada epoch ke- t

c. Accuracy

$$\text{Accuracy} = \frac{1}{N} \sum_{i=1}^N 1(\hat{y}_i = y_i)$$

- 1: fungsi indikator, 1 jika benar, 0 jika salah
- Cocok untuk label dalam bentuk angka (0, 1, ..., n)

d. Categorical Accuracy

$$\text{Accuracy} = \frac{1}{N} \sum_{i=1}^N 1(\arg \max(\hat{y}_i) = \arg \max(y_i))$$

- Digunakan jika label berupa one-hot vector
- Dihitung sebagai metrik tambahan loss sparse

4.3.5 Ringkasan Arsitektur Model

Model yang telah dikonstruksi dan dikompilasi ditampilkan melalui fungsi `summary()` untuk memberikan informasi lengkap mengenai jumlah layer, parameter yang dapat dilatih (*trainable parameters*), dan dimensi output dari

setiap layer. Tahap ini penting untuk memverifikasi apakah struktur model sudah sesuai dengan kebutuhan.

Dengan pendekatan *transfer learning* ini, proses pelatihan model dapat dilakukan dengan dataset yang relatif kecil namun tetap mampu menghasilkan akurasi yang baik, karena memanfaatkan pengetahuan fitur yang sudah dipelajari sebelumnya oleh MobileNetV2. Implementasi ini menjadi fondasi utama dalam membangun sistem klasifikasi tanah berbasis citra digital menggunakan metode CNN.

Model: "sequential"

Layer (type)	Output Shape	Param #
mobilenetv2_1.00_160 (Functional)	(None, 5, 5, 1280)	2,257,984
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
dense (Dense)	(None, 64)	81,984
dropout (Dropout)	(None, 64)	0
dense_1 (Dense)	(None, 3)	195

Total params: 2,340,163 (8.93 MB)
 Trainable params: 2,306,051 (8.88 MB)
 Non-trainable params: 34,112 (133.25 KB)

Gambar 4.8 Ringkasan Arsitektur Model CNN MobileNetV2

Berdasarkan hasil `summary()` model, arsitektur CNN yang digunakan memanfaatkan MobileNetV2 sebagai *feature extractor* dan menambahkan beberapa lapisan untuk klasifikasi. Total parameter model adalah 2.340.163, dengan sebanyak 2.306.051 parameter dapat dilatih (trainable) dan 34.112 non-trainable, yang menunjukkan efisiensi model dalam proses fine-tuning.

4.3.6 Pelatihan Model dan Penggunaan *Callback EarlyStopping*

Setelah model CNN selesai dikompilasi, tahap berikutnya adalah proses pelatihan model (training). Dalam proses ini, data citra tanah yang telah diberi label digunakan untuk melatih model agar dapat mengenali pola dan karakteristik

masing-masing jenis tanah. Proses pelatihan dilakukan selama 16 epoch, di mana setiap epoch merupakan satu siklus pelatihan penuh terhadap seluruh data pelatihan.

Untuk meningkatkan efisiensi pelatihan dan menghindari terjadinya *overfitting*, diterapkan *callback EarlyStopping*. *Callback* ini berfungsi untuk menghentikan proses pelatihan secara otomatis jika dalam 10 epoch berturut-turut tidak terdapat peningkatan nilai akurasi pada data validasi (*val_accuracy*). Selain itu, pengaturan *restore_best_weights=True* memastikan bahwa setelah pelatihan dihentikan, model akan menggunakan bobot terbaik (dengan akurasi validasi tertinggi) yang diperoleh selama proses pelatihan.

```
[ ] # Membuat callback EarlyStopping untuk menghentikan pelatihan jika tidak ada peningkatan dalam metrik val_accuracy
# selama 10 epochs berturut-turut dan memulihkan bobot terbaik
callback = tf.keras.callbacks.EarlyStopping(
    monitor='val_accuracy', # Metrik yang dipantau untuk menghentikan pelatihan
    patience=10,           # Jumlah epochs tanpa peningkatan sebelum pelatihan dihentikan
    restore_best_weights=True # Memulihkan bobot terbaik yang menghasilkan metrik terbaik
)
```

Gambar 4.9 Callback EarlyStopping

$$\text{val_metric}_t \leq \max(\text{val_metric}_{t-p..t-1}) \quad \text{selama } p \text{ epoch}$$

- p : patience (misal: 10)
- $\text{val_metric } t$: metrik validasi pada epoch ke- t

Selain *EarlyStopping*, *callback* lainnya yang digunakan adalah *lr_callback* (*learning rate scheduler*), yang bertugas menyesuaikan kecepatan pembelajaran selama proses training berlangsung. Kombinasi kedua *callback* ini membantu dalam meningkatkan efektivitas pelatihan serta menjaga stabilitas performa model.

Model kemudian dilatih menggunakan data pelatihan (*train_images* dan *train_labels*) dengan evaluasi terhadap data validasi (*test_images* dan *test_labels*)

pada setiap epoch. Data validasi ini digunakan untuk menilai performa model terhadap data yang tidak pernah dilihat sebelumnya, sehingga dapat menjadi indikator awal apakah model mengalami *overfitting* atau tidak.

```
[ ] # Jumlah berapa kali melakukan training
epochs=10

# Melatih fine-tuning model menggunakan data pelatihan dan data uji, dengan jumlah epochs yang telah ditentukan
# serta data validasi yang digunakan untuk memonitor performa model pada setiap epoch
# Callback lr_callback digunakan untuk mengatur kemampuan pembelajaran,
# dan callback callback digunakan untuk menghentikan pelatihan jika tidak ada peningkatan dalam metric val_accuracy
history_fit_model = fit_model.fit(
    train_images, # Data gambar pelatihan
    train_labels, # Label kelas pelatihan
    epochs=epochs, # Jumlah epochs
    validation_data=(test_images, test_labels), # data validasi (data uji)
    callbacks=[lr_callback, callback] # callback untuk mengatur kemampuan pembelajaran dan earlystopping
)
```

Gambar 4.10 Proses Training Model

a. Jumlah Iterasi Total (Batch per Epoch)

$$\text{Iterasi per epoch} = \left\lceil \frac{N}{B} \right\rceil$$

$$\text{Total iterasi} = E \times \left\lceil \frac{N}{B} \right\rceil$$

- N : jumlah data latih (train_images)
- B : ukuran batch (batch_size)
- E : jumlah epoch

b. Proses Feedforward dan Backpropagation

- Input:

$$X^{(i)} \in \mathbb{R}^{B \times H \times W \times C}$$

- Output logits:

$$Z = f(X^{(i)}; \theta)$$

- Output prediksi (softmax):

$$\hat{y}_j^{(i)} = \frac{e^{z_j}}{\sum_{k=1}^C e^{z_k}}$$

- Loss (Sparse Categorical Crossentropy):

$$\mathcal{L}^{(i)} = -\frac{1}{B} \sum_{n=1}^B \log(\hat{y}_{n,y_n}^{(i)})$$

- Update parameter menggunakan Adam

$$\theta \leftarrow \theta - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}}$$

c. Validation Set Loss dan Akurasi

Setelah setiap epoch, dilakukan evaluasi pada data validasi:

$$\text{Val Accuracy} = \frac{1}{M} \sum_{i=1}^M 1(\hat{y}_i = y_i)$$

$$\text{Val Loss} = -\frac{1}{M} \sum_{i=1}^M \log(\hat{y}_{i,y_i})$$

- M : jumlah data validasi

Selama proses pelatihan, sistem akan mencatat perkembangan nilai loss dan akurasi baik untuk data pelatihan maupun data validasi. Nilai-nilai tersebut dapat divisualisasikan nantinya untuk melihat tren pembelajaran model dan menjadi bahan evaluasi kinerja model secara keseluruhan.

4.3.7 Perhitungan Epoch

- a. Input Gambar ke Model

Memasukkan 8 gambar ukuran **224x224x3** (total 150.528 piksel per gambar), maka:

$$x' = \frac{x}{255.0}$$

- Input batch: $X.shape = (8, 224, 224, 3)$
- Nilai piksel dinormalisasi: $X = X / 255.0$

Contoh (1 pixel RGB):

$$[128,64,255] \rightarrow [0.502,0.251,1.000]$$

b. Base Model (MobileNetV2)

Convolutional Layer:

$$Y[i, j, k] = \sum_{m=0}^{F-1} \sum_{n=0}^{F-1} \sum_{c=0}^{C-1} W[m, n, c, k] \cdot X[i + m, j + n, c] + b[k]$$

- F : filter size (misal 3x3)
- C : channels input (3 pada awal)
- k : index filter (jumlah channel output)
- Output: fitur map

Depthwise Separable Conv:

$$\text{param}_{\text{depthwise}} + \text{param}_{\text{pointwise}} \ll \text{param}_{\text{standard conv}}$$

- Depthwise: 1 filter per channel
- Pointwise (1x1 conv): menggabungkan channel

c. GlobalAveragePooling2D

Meratakan spatial dimension 7×7 untuk setiap channel:

$$GAP_k = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X[i, j, k]$$

Jika input akhir dari MobileNet adalah (7,7,1280), maka hasilnya:

Output = (1280,) (untuk setiap gambar)

d. Dense Layer (64 Neuron)

$$z = W \cdot x + b \quad (\text{dimensi: } (1280 \times 64))$$

$$a = \text{ReLU}(z) = \max(0, z)$$

- Input: (8, 1280)
- Bobot: W: (1280, 64), b: (64,)
- Aktivasi ReLU: $\text{ReLU}(z) = \max(0, z)$
- Output: (8, 64)

Contoh 1 neuron (simulasi):

- X: [0.1, 0.05, ..., 0.2]
- W: [0.03, -0.04, ..., 0.1]

$$z_1 = \sum_{j=1}^{1280} x_j \cdot w_{j1} + b_1 \Rightarrow a_1 = \max(0, z_1)$$

e. Dropout 0.5

- Neuron yang **di-nol-kan acak** → hasil output: (8, 64)
- Sekitar 32 neuron aktif

f. Dense Layer Output (3 kelas)

$$z = W \cdot x + b \quad \text{dimensi: } (64 \times 3)$$

Softmax untuk 1 sample:

Misal $z = [2.0, 1.0, 0.1]$, maka: Loss Function

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^3 e^{z_j}} \Rightarrow [0.659, 0.242, 0.099]$$

Output: (8, 3)

g. Loss Function

Sparse Categorical Crossentropy:

$$\mathcal{L}_i = -\log(\hat{y}_{i,y_i})$$

Misal: prediksi softmax = [0.659, 0.242, 0.099], true class = 0:

$$\text{Loss sample} = -\log(0.659) \approx 0.417$$

Total loss:

$$\text{Loss batch} = \frac{1}{N} \sum_{i=1}^N -\log(p_{i,y_i})$$

$$\text{Loss batch} = \frac{1}{8} \sum_{i=1}^8 \mathcal{L}_i = 1.0173$$

h. Accuracy

Predicted = arg max(softmax output)

$$\text{Accuracy} = \frac{\text{jumlah prediksi benar}}{\text{total sample}}$$

- Argmax output softmax dibandingkan dengan label (bilangan bulat)
- Misal prediksi [0, 1, 0, 2, 2, 1, 0, 1]
- Label: [0, 1, 2, 2, 2, 0, 0, 1]

Benar: [0, 1, -, 2, 2, -, 0, 1] $\rightarrow 5/8 = 0.5678$

i. Categorical Accuracy

$$\text{Categorical Accuracy} = \frac{\text{argmax}(\text{pred}) == \text{argmax}(\text{label})}{\text{total sample}}$$

Dihitung jika label 1-hot.

Misal prediksi: [0.65, 0.22, 0.13], label one-hot: [1, 0, 0]

Jika $\text{argmax}(\text{pred}) \neq \text{argmax}(\text{label})$, maka salah.

Kemungkinan:

- Banyak prediksi salah secara 1-hot
- Maka: 0.2041 \rightarrow hanya sekitar 2 dari 8 benar

j. Learning Rate per Epoch

Jika menggunakan scheduler:

$$\text{lr}_{\text{epoch}} = 0.001 \cdot e^{-0.1 \cdot \text{epoch}}$$

Contoh epoch-1:

$$\text{lr} = 0.001 \cdot e^{-0.1} \approx 0.0009048$$

k. Kesimpulan

Komponen	Nilai / Simulasi
Input Shape	(8, 224, 224, 3)
Setelah MobileNet	(8, 7, 7, 1280)
Setelah GlobalAvgPooling2D	(8, 1280)
Dense (ReLU, 64)	(8, 64)
Setelah Dropout	~32 aktif neuron
Dense (Softmax, 3)	(8, 3) – nilai probabilitas
Komponen	Nilai / Simulasi

Loss per batch	1.0173
Accuracy	0.5678 ($\approx 5/8$ benar)
Categorical Accuracy	0.2041 ($\approx 1-2/8$ benar (1-hot))
Validation Accuracy	0.9118
Validation Loss	0.2416
Learning Rate	0.0010

4.4. Evaluasi Performa Model Berdasarkan Pelatihan

Proses pelatihan model CNN dilakukan selama 16 epoch dengan menggunakan dataset citra tanah yang telah melalui proses augmentasi dan pelabelan. Selama pelatihan, model mempelajari fitur-fitur visual dari gambar untuk mengklasifikasikan jenis tanah secara otomatis. Evaluasi performa dilakukan dengan mengamati beberapa metrik utama, yaitu *accuracy*, *categorical accuracy*, *loss*, serta performa pada data validasi.

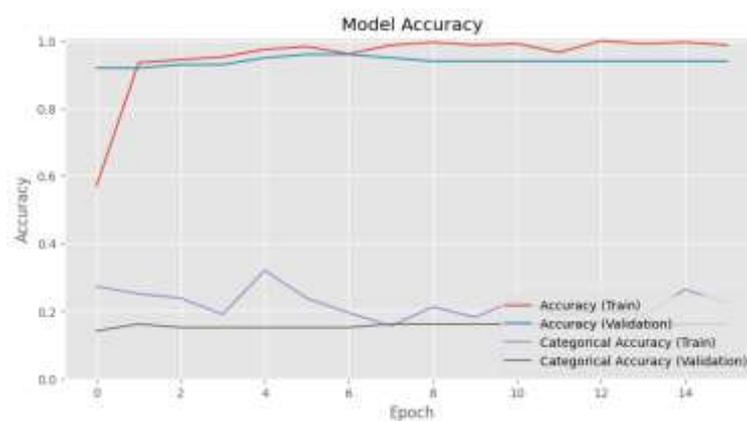
4.4.1 Perkembangan *Accuracy* dan *Loss*

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:

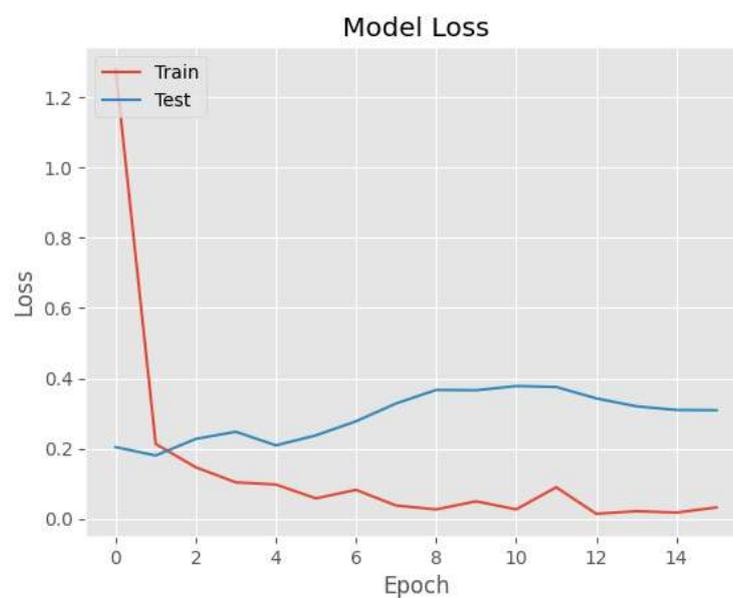
- a. Pada epoch ke-2 hingga ke-5, terjadi peningkatan drastis pada akurasi pelatihan, mencapai 97.11%.
- b. Akurasi validasi juga tetap stabil dan tinggi, berkisar antara 91% hingga 95%, menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan.

- c. 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-6, kestabilan nilainya menjadi indikasi bahwa model telah belajar secara optimal dan mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.



Gambar 4.11 Model Accuracy



Gambar 4.12 Model Loss

4.4.2 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.

4.4.3 *Learning Rate Scheduling*

Proses pelatihan juga menggunakan strategi *learning rate decay*, yaitu penurunan *learning rate* secara bertahap dari 0.0010 pada epoch pertama hingga 0.0002 pada epoch ke-16. Strategi ini terbukti efektif dalam menjaga kestabilan pembelajaran di akhir epoch dan menghindari overshooting saat optimasi.

4.4.4 Konsistensi dan Stabilitas

Akurasi pelatihan mencapai 99.80% pada epoch ke-15, sementara akurasi validasi tetap konsisten di 93.94% dari epoch ke-9 hingga ke-16. Stabilitas ini merupakan indikator kuat bahwa model telah mencapai titik konvergensi yang baik, dan penggunaan *EarlyStopping* memastikan bahwa pelatihan tidak berlanjut secara berlebihan yang dapat menyebabkan *overfitting*.

4.5. Hasil Prediksi

4.5.1 Upload Gambar

```
from google.colab import files  
  
image_data = files.upload()  
  
image_file = list(image_data.keys())[0]
```

- Pengguna mengunggah file gambar dari komputernya ke Google Colab.
- `files.upload()` akan membuka dialog untuk memilih file.
- Setelah gambar diunggah, nama file diambil dari `image_data`.

Contoh mengupload gambar tanah Inceptisol:



Gambar 4.13 Tanah Inceptisol

4.5.2 Preprocessing Gambar

```
image = tf.keras.utils.load_img(image_file, target_size=(150, 150))  
  
image_array = tf.keras.utils.img_to_array(image) / 255.0  
  
image_array = np.expand_dims(image_array, axis=0)
```

- `load_img`: Memuat gambar dan mengubah ukurannya ke 150x150 piksel.
- `img_to_array`: Mengubah gambar ke bentuk array NumPy, misalnya dari (150, 150, 3) untuk RGB.

- `/255.0`: Normalisasi piksel dari rentang `[0, 255]` ke `[0.0, 1.0]`, agar model lebih stabil.
- `expand_dims`: Menambahkan dimensi batch: dari `(150, 150, 3)` \rightarrow `(1, 150, 150, 3)`, karena model menerima input dalam bentuk batch.

Mengubah gambar menjadi ukuran 150x150 dan mengubah ke bentuk array:

```
[[[[[0.30980393 0.20392157 0.22352941]
     [0.32941177 0.21568628 0.22352941]
     [0.39607844 0.29411766 0.30588236]
     [0.6039216  0.5176471  0.4627451 ]
     [0.15686275 0.07058824 0.02745098]
     [0.18039216 0.09411765 0.05098039]]
   [[0.16078432 0.06666667 0.06666667]
     [0.22745098 0.11372549 0.12941177]
     [0.3647059  0.26666668 0.2784314 ]
     [0.2784314  0.20784314 0.16078432]

     [0.40392157 0.33333334 0.28627452]
     [0.25490198 0.1882353  0.15686275]]
   ...
```

4.5.3 Prediksi

```
result_predict = ft_model.predict(image_array)[0]
```

- Model `ft_model` melakukan prediksi terhadap gambar.
- Output: array 1D dari nilai probabilitas untuk setiap kelas

Melakukan prediksi dari gambar yang diupload:

```
[7.913318e-05 2.628916e-05 9.998946e-01]
```

4.5.4 Menampilkan Hasil Probabilitas

```
classes = ['aluvial', 'entisol', 'inseptisol']

for i, label in enumerate(classes):

    print(f"{label}: {result_predict[i]:.4f}")
```

Menampilkan hasil probabilitas

- **inceptisol-001.jpg**(image/jpeg) - 61929 bytes, last modified: 7/14/2025 - 100% done

Saving inceptisol-001.jpg to inceptisol-001.jpg

1/1 ————— 3s 3s/step

aluvial: 0.0001

entisol: 0.0000

inseptisol: 0.9999

4.5.5 Prediksi Akhir (Kelas dengan Probabilitas Tertinggi)

```
predicted_index = np.argmax(result_predict)

print(f"\nPrediksi akhir: {classes[predicted_index]} (confidence:
{result_predict[predicted_index]:.4f})")
```

- `np.argmax(result_predict)` akan mengambil indeks dari nilai tertinggi.
- Misalnya: dari [0.15, 0.78, 0.07] maka indeks tertinggi adalah 1 (entisol).

Prediksi akhir: **inseptisol (confidence: 0.9999)**

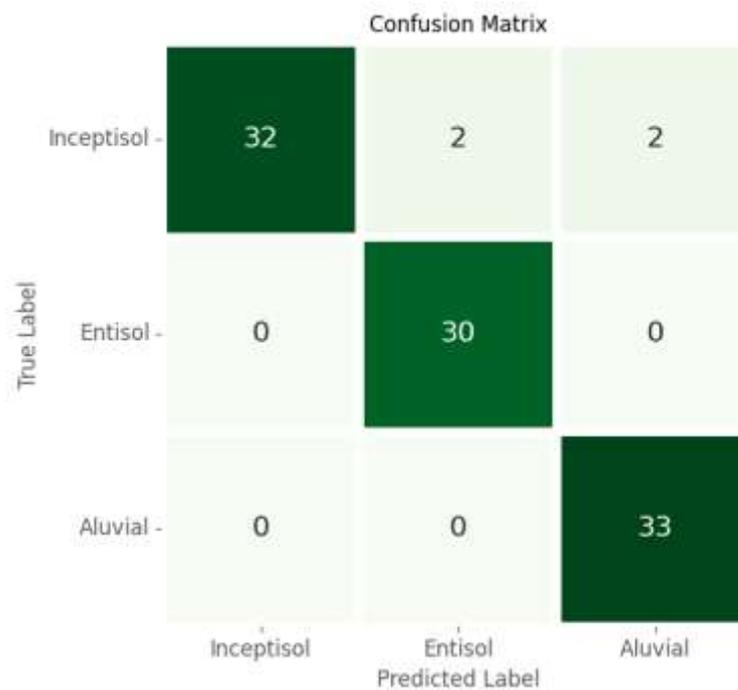
4.6. Confusion Matrix

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.

4.6.1 Hasil *Confusion Matrix*

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



Gambar 4.14 Confusion Matrix

4.6.2 Interpretasi Hasil

- a. Kelas Inceptisol:
 - Model berhasil mengklasifikasikan 32 dari 36 sampel secara benar sebagai Inceptisol.
 - Terdapat 2 sampel yang diklasifikasikan salah sebagai Entisol, dan 2 lainnya salah diklasifikasikan sebagai Aluvial.

- Ini menunjukkan model cukup baik dalam mengenali Inceptisol, namun masih ada sedikit tumpang tindih dengan dua kelas lainnya.

b. Kelas Entisol:

- Model mampu mengklasifikasikan semua 30 sampel Entisol dengan benar.
- Tidak terdapat kesalahan klasifikasi pada kelas ini, yang berarti model sangat akurat dalam membedakan karakteristik visual dari tanah Entisol.

c. Kelas Aluvial:

- Model juga berhasil mengklasifikasikan semua 33 sampel Aluvial dengan benar tanpa kesalahan.
- Ini menunjukkan bahwa fitur visual yang dimiliki tanah Aluvial dapat dikenali secara konsisten oleh model.

4.6.3 Kesimpulan

Secara keseluruhan, model menunjukkan performansi klasifikasi yang sangat baik, terutama pada kelas Entisol dan Aluvial dengan akurasi 100%. Sementara untuk kelas Inceptisol, meskipun terdapat sedikit kesalahan klasifikasi, akurasinya tetap sangat tinggi. Hal ini menandakan bahwa model mampu melakukan pembelajaran fitur dengan sangat baik untuk membedakan jenis-jenis tanah berdasarkan citra, dan hanya perlu sedikit peningkatan pada kelas yang memiliki kemiripan karakteristik dengan kelas lainnya.

Dengan akurasi keseluruhan yang tinggi dan kesalahan klasifikasi yang sangat minim, confusion matrix ini memperkuat bukti bahwa arsitektur CNN yang digunakan sudah sangat efektif dalam tugas klasifikasi jenis tanah.

BAB V

KESIMPULAN DAN SARAN

5.1. KESIMPULAN

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.

5.2. SARAN

Adapun beberapa saran yang dapat disampaikan untuk pengembangan lebih lanjut dari penelitian ini, antara lain:

1. Penambahan Jumlah Data

Jumlah data citra pada setiap kelas sebaiknya ditingkatkan agar model dapat belajar dengan lebih seimbang dan akurat, serta meningkatkan kemampuan generalisasi pada kondisi nyata yang lebih bervariasi.

2. Penggunaan Teknik Augmentasi yang Lebih Variatif

Penggunaan teknik augmentasi yang lebih kompleks seperti rotasi acak, kontras, brightness, atau *Gaussian noise* dapat membantu model belajar dari berbagai kondisi pencahayaan dan orientasi citra.

3. Pengujian pada Citra Lapangan

Perlu dilakukan pengujian terhadap citra tanah yang diambil langsung dari lapangan dengan kamera biasa (non-profesional) untuk mengetahui sejauh mana model dapat bertahan pada kondisi citra nyata (real-world images).

4. Pengembangan Aplikasi

Untuk meningkatkan kemanfaatan praktis, model ini dapat diintegrasikan ke dalam aplikasi berbasis web atau mobile sehingga pengguna akhir dapat langsung melakukan identifikasi jenis tanah hanya dengan mengambil foto.

5. Eksplorasi Arsitektur Model Lain

Disarankan untuk membandingkan performa MobileNetV2 dengan model CNN lain seperti EfficientNet, ResNet, atau DenseNet untuk mengetahui potensi peningkatan akurasi yang lebih tinggi.

DAFTAR PUSTAKA

- Prasetyo, A., et al. (2021). Analisis Klasifikasi Tanah Menggunakan Metode Konvensional dan Teknologi Digital. *Jurnal Teknik Sipil*, 15(2), 123-135.
- 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.*
- 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.*
- Mancini, A., Frontoni, E., & Zingaretti, P. (2019). *Deep learning for soil and crop segmentation from remotely sensed data. Remote Sensing*, 11(16), 1859.
- Inazumi, S., Intui, S., & Jotisankasa, A. (2020). *Artificial intelligence system for supporting soil classification. Results in Engineering*, 8, 100096.
- 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.
- Herdy, S., Rodríguez-Caballero, E., Pock, T., & Weber, B. (2024). *Utilization of deep learning tools to map and monitor biological soil crusts. Ecological Informatics.*
- Padarian, J., Minasny, B., & McBratney, A. B. (2019). *Using deep learning to predict soil properties from regional spectral data. Geoderma Regional*, 16, e00239.

- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.

Han, W., Zhang, X., Wang, Y., & Huang, X. (2023). *A survey of machine learning and deep learning in remote sensing of geological environment:*

Challenges, advances, and opportunities. ISPRS Journal of Photogrammetry and Remote Sensing, 193, 92-115.

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.*

Haq, M. A. (2022). *CNN Based Automated Weed Detection System Using UAV Imagery. Computer Systems Science & Engineering.*

Zafar, A., Aamir, M., Mohd Nawari, N., & Arshad, A. (2022). *A comparison of pooling methods for convolutional neural networks. Applied Sciences.*

Pelletier, C., Webb, G. I., & Petitjean, F. (2019). *Temporal convolutional neural network for the classification of satellite image time series. Remote Sensing.*

Zhang, C., Yue, P., Tapete, D., & Shanguan, 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.*

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.*

Avenash, R., & Viswanath, P. (2019). *Semantic Segmentation of Satellite Images using a Modified CNN with Hard-Swish Activation Function. VISIGRAPP (4: VISAPP).*

Sujatha, M., & Jaidhar, C. D. (2023). *1D convolutional neural networks-based soil fertility classification and fertilizer prescription. Ecological Informatics, 72, 101802.*

- Prasetyo, R. D., & Anjarwati, A. (2021). Klasifikasi Citra Tanah Menggunakan CNN dan Augmentasi Data. *Jurnal Teknologi dan Sistem Komputer*, 9(1), 22–30.
- Kurniawan, H., & Fitria, D. (2020). Eksperimen Model Deep Learning dalam Klasifikasi Tanah Berdasarkan Citra. *Jurnal Ilmiah Teknik Informatika*, 5(2), 45–52.
- 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.
- Hasanah, M., Siregar, F., & Firmansyah, M. (2022). Implementasi *Deep Learning* untuk Deteksi Tanah Pertanian. *Jurnal Sistem Informasi dan Sains Teknologi*, 10(3), 65–72.
- Liu, S., Zhang, Y., & Wang, X. (2020). *Soil Classification Based on CNN from Satellite Image Dataset. Computers and Electronics in Agriculture*, 175, 105576.
- 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.
- 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.
- Padarian, J., Minasny, B., & McBratney, A. B. (2019). *Using deep learning for digital soil mapping. Soil*, 5(1), 79–89.
- 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.

- Hengl, T., et al. (2017). SoilGrids250m: *Global gridded soil information based on machine learning*. PLOS ONE, 12(2), e0169748.
- Patel, R., Joshi, M., & Bhatt, R. (2020). *Soil image classification using deep convolutional neural network*. *International Journal of Computer Applications*, 177(28), 9–13.
- 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.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). *ImageNet classification with deep convolutional neural networks*. *Communications of the ACM*, 60(6), 84–90.
- Sari, D. A., Nugroho, E. P., & Wicaksono, R. (2022). *Klasifikasi citra digital tanah menggunakan CNN*. *Jurnal Teknologi dan Sistem Komputer*, 10(3), 204–212.
- Haq, F., Fikri, M., & Anshori, R. (2022). *Pemetaan tanah berbasis citra drone menggunakan deep learning*. *Jurnal Informatika Pertanian*, 8(2), 111–120.
- 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.
- 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.
- Guo, J., Liu, Y., & Zhang, Y. (2023). *Visual explanation of CNN-based land classification: Applications in remote sensing*. *Remote Sensing Letters*, 14(3), 234–242.

- Dhanya, M., Krishnan, R., & Arunachalam, S. (2022). *Deep learning-based soil classification using hyperspectral imaging. Computers and Electronics in Agriculture*, 196, 106882.
- Liu, Y., Wang, S., & Chen, Z. (2019). *Performance evaluation of CNN models in land use classification. International Journal of Remote Sensing*, 40(4), 1450–1468.
- Yulianto, A., Wibowo, H., & Rahman, F. (2023). Model CNN untuk klasifikasi tanah latosol dan aluvial. *Jurnal Ilmiah Geomatika*, 29(1), 37–48.
- Zhang, Y., Chen, X., & Lu, X. (2018). *A review of deep learning for land use classification. Journal of Environmental Informatics*, 32(1), 1–12.