

Implementation of Convolutional Neural Network for Soil Type Category Detection in a Web-Based Plant Recommendation System

Implementasi Convolutional Neural Network untuk Deteksi Kategori Jenis Tanah pada Sistem Rekomendasi Jenis Tanaman Berbasis Website

Imam Sanjaya¹⁾; Yulinar Sri Wahyuni²⁾; Lusiana Sani Parwati³⁾

^{1),2),3)} Program Studi Teknik Informatika, Fakultas Teknik, Komputer Dan Desain, Universitas Nusa Putra
Email: ¹⁾ imam.sanjaya@nusaputra.ac.id ; ²⁾ yulinar.sri_ti21@nusaputra.ac.id ; ³⁾ lusiana.sani@nusaputra.ac.id

How to Cite :

Sanjaya, I., Wahyuni, Y. S., Parwati, L. S. (2025). Implementation of Convolutional Neural Network for Soil Type Category Detection in a Web-Based Plant Recommendation System. Jurnal Media Computer Science, 4(2) Doi: <https://doi.org/10.37676/jmcs.v4i2>

ARTICLE HISTORY

Received [27 Mei 2025]

Revised [29 Juni 2025]

Accepted [06 Juli 2025]

KEYWORDS

Convolutional Neural Network, Soil Classification, Content Based Filtering, Crop Recommendation

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Pertumbuhan sektor pertanian di Indonesia sangat bergantung pada kesuburan tanah, tanah merupakan faktor penting dalam sektor pertanian. Namun, identifikasi jenis tanah ini secara konvensional seringkali memerlukan waktu yang lama dan memerlukan biaya yang tinggi. Untuk mengatasi masalah ini, penelitian ini mengembangkan sistem klasifikasi tanah menggunakan model *Convolutional Neural Network (CNN)* yang optimal untuk meningkatkan akurasi klasifikasi tanah. Hasil klasifikasi ini menjadi dasar bagi sistem rekomendasi berbasis *Content- Based Filtering (CBF)*, guna memberikan saran jenis tanaman yang sesuai dengan jenis tanah. Penelitian ini dilakukan melalui beberapa tahapan utama, yaitu pengumpulan data citra tanah, *preprocessing* data, pelatihan model *CNN* serta implementasi sistem rekomendasi berbasis *CBF*. Model *CNN* digunakan untuk mengenali pola tekstur dan warna tanah, sementara *CBF* digunakan untuk mencocokkan karakteristik tanah dengan jenis tanaman yang sesuai. Evaluasi sistem dilakukan menggunakan confusion matrix untuk menilai akurasi model klasifikasi serta efektivitas sistem rekomendasi. Proses klasifikasi jenis tanah menggunakan *CNN* dengan arsitektur *MobileNetV2* berhasil mencapai tingkat akurasi sebesar 96%. Hasil ini menunjukkan bahwa arsitektur tersebut efektif dalam mengenali jenis tanah secara tepat dan dapat digunakan untuk memberikan rekomendasi tanaman yang sesuai. Dengan demikian, sistem ini memiliki potensi untuk mendukung peningkatan produktivitas pertanian, baik dalam skala kecil maupun besar.

ABSTRACT

The growth of the agricultural sector in Indonesia is highly dependent on soil fertility, as soil is an important factor in the agricultural sector. However, conventional identification of soil types often takes a long time and requires high costs. To overcome this problem, this research develops a soil classification system using an optimized *Convolutional Neural Network (CNN)* model to improve soil classification accuracy. The results of this classification become the basis for a *Content-Based Filtering (CBF)* based recommendation system, in order to provide suggestions for crop types that are suitable for soil types. This research was conducted through several main stages, namely soil image data collection, data preprocessing, *CNN* model training and *CBF*-based recommendation system implementation. The *CNN* model is used to recognize soil texture and color patterns, while *CBF* is used to match soil characteristics with suitable plant species. System evaluation is conducted using confusion matrix to assess the accuracy of the classification model as well as the effectiveness of the recommendation system. The soil type classification process using *CNN* with *MobileNetV2* architecture achieved an accuracy rate of 96%. This result shows that the architecture is effective in recognizing soil types precisely and can be used to provide appropriate crop recommendations. Thus, this system has the potential to support increased agricultural productivity, both on a small and large scale.

PENDAHULUAN

Negara Indonesia merupakan negara agraris dengan kekayaan sumber daya alam yang melimpah, khususnya dalam bidang pertanian. Kesuburan tanah di Indonesia didukung oleh berbagai faktor, salah satunya adalah keberadaan jalur gunung berapi aktif yang dikenal sebagai *Ring of Fire*, yang membentang dari Sumatra hingga Maluku (Aditya & Wijayanti, 2023). Kondisi geografis ini menjadikan

banyak masyarakat Indonesia menggantungkan hidupnya sebagai petani. Menurut data Badan Pusat Statistik (BPS), pada tahun 2023 terdapat 29.360.833 unit usaha pertanian, meskipun jumlah ini mengalami penurunan sebesar 7,42% dibandingkan tahun 2013 (Bps.go.id, 2023). Pada kenyataannya sektor pertanian ini sangat bergantung pada kualitas tanah sebagai media utama produksi tanaman.

Tanah merupakan bagian dari kerak bumi yang tersusun atas mineral dan bahan organik, yang berfungsi sebagai media tumbuhnya tanaman dengan sifat-sifat tertentu (Bps.go.id, 2023). Di Indonesia tersebar beragam jenis tanah dengan karakteristik yang berbeda, tentu hal ini berpengaruh pada kesesuaian lahan terhadap jenis tanaman tertentu. Di Indonesia terdapat jenis tanah yang umum ditemukan dan dimanfaatkan salah satunya diantaranya seperti Andosol, Inceptisol, Entisol, Aluvial, Humus, Tanah Berpasir, Laterit dan Latosol (Ilmugeografi, 2015). Delapan jenis tanah dalam penelitian ini dipilih sebagai fokus penelitian karena masing-masing jenis tanah menunjukkan warna yang khas dan kontras berbeda secara visual antara satu sama lain, sehingga memungkinkan dibedakan secara visual yang khas (Gayo dkk., 2022). Oleh sebab itu, perbedaan visual dari segi warna dapat dijadikan dasar klasifikasi jenis tanah. Berdasarkan studi morfologi tanah oleh Ayu Ara Putri Gayo dkk (2022) menunjukkan bahwa warna tanah merupakan salah satu indikator utama untuk klasifikasi awal jenis tanah berdasarkan genesis dan kandungan bahan organik (Gayo dkk., 2022). Oleh karena itu, klasifikasi jenis tanah berdasarkan warna memperkuat pendekatan morfologi visual yang relevan dan efektif untuk sistem klasifikasi berbasis Convolutional Neural Network (CNN). Perbedaan warna visual antar jenis tanah ini dapat diidentifikasi oleh CNN melalui ekstraksi fitur spasial dan warna yang terdapat dalam citra digital tanah.

Warna tanah merupakan karakteristik tanah yang paling mudah dikenali secara visual di lapangan. Dengan hanya mengamati warna tanah, kita dapat memperoleh petunjuk mengenai sifat-sifat tanah lainnya (Fitriani dkk., 2022). Meskipun warna tidak memberikan pengaruh besar dalam menentukan fungsi tanah, namun warna dapat menjadi indikator keberadaan karakteristik khusus tanah tertentu. Sebagai contoh, tanah berwarna gelap mengindikasikan tingginya kandungan bahan organik, yang dikenal dengan istilah tanah humus (Fitriani dkk., 2022). Oleh karena itu, klasifikasi jenis tanah berdasarkan warna sangat relevan untuk dikembangkan, terutama dengan pendekatan berbasis citra digital. Serta pemilihan jenis tanah ini dipilih karena pola penggunaan pertanian pada masing-masing jenis tanah telah terdokumentasi dengan baik sehingga dapat digunakan sebagai dasar dalam sistem rekomendasi tanaman.

Keragaman jenis tanah di Indonesia yang kompleks ini menyebabkan pentingnya pemahaman mendalam tentang jenis lahan pertanian untuk mengoptimalkan produktivitas tanaman. Seiring perkembangan teknologi, metode konvensional seperti uji laboratorium dinilai kurang efisien karena membutuhkan waktu dan biaya besar. Kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), memungkinkan proses klasifikasi visual menjadi lebih cepat, akurat, dan otomatis. CNN mampu mengenali perbedaan pola warna dari citra tanah digital (Yani Parti Astuti, Indah Wardatunizza, Egia Rosi Subhiyakto, 2023). CNN menjadi alat yang potensial untuk digunakan dalam mengklasifikasi jenis tanah.

Tanah memiliki tingkat ketahanan yang berbeda-beda terhadap pertumbuhan dan kesuburan tanaman. Kesuburan tanah ditentukan oleh karakteristik tanah yang meliputi sifat fisik, kimia, dan biologi tanah (Rumfot dkk., 2024). Penelitian sebelumnya oleh Yani Parti Astuti dkk (2023) telah menggunakan CNN untuk klasifikasi jenis tanah dan menunjukkan akurasi yang tinggi dan berhasil mengklasifikasi jenis tanah. Namun, penelitian tersebut umumnya hanya fokus pada klasifikasi tanpa memberikan rekomendasi jenis tanaman yang sesuai dengan jenis tanahnya (Yani Parti Astuti, Indah Wardatunizza, Egia Rosi Subhiyakto, 2023). Di sisi lain, sistem rekomendasi tanaman sangat dibutuhkan, terutama di tengah perubahan iklim, keterbatasan lahan, dan minimnya pengetahuan petani tentang kesesuaian tanaman dengan jenis tanah. Setiap tanah mempunyai sifat dan ciri yang berbeda serta memiliki potensi yang berbeda dalam kegunaannya sebagai media tanam untuk suatu jenis tanaman. Maka, rekomendasi tanaman yang tepat tentunya dibutuhkan di tengah tantangan perubahan iklim, keterbatasan lahan pertanian dan keterbatasan pengetahuan petani maupun pemilik lahan yang masih menggunakan metode tradisional atau menduga-duga tentu hal ini dinilai kurang efektif.

Oleh karena itu, Untuk menjawab tantangan tersebut, penelitian ini mengusulkan pengembangan sistem klasifikasi jenis tanah berbasis CNN yang diintegrasikan dengan sistem rekomendasi tanaman berbasis *Content-Based-Filtering* sederhana berdasarkan aturan. Data citra tanah akan dikumpulkan dari berbagai sumber yang kemudian diolah dan di uji menggunakan confusion matrix untuk mengukur akurasi, precision, recall dan f1 score. Pendekatan ini akan memanfaatkan citra tanah digital dan algoritma *deep learning CNN* untuk menghasilkan klasifikasi yang lebih akurat dan cepat dibandingkan metode tradisional. Hasil klasifikasi ini kemudian digunakan sebagai dasar dalam sistem rekomendasi untuk memberikan saran jenis tanaman musiman dan tahunan yang sesuai. Rekomendasi jenis tanaman yang diberikan disesuaikan berdasarkan jenis tanahnya yang cocok untuk tanaman tersebut.

Sebagai hasil akhir, sistem ini akan dikembangkan dalam bentuk website agar dapat di akses oleh petani dan masyarakat luas. Dengan adanya informasi ini diharapkan dapat membantu pengambilan keputusan dalam pemanfaatan lahan yang ada secara efektif dan efisien dan dapat meningkatkan efisiensi produktivitas lahan pertanian. Dan diharapkan dapat membantu para petani muda maupun masyarakat yang ingin memulai bertani atau memanfaatkan lahan yang dimilikinya.

LANDASAN TEORI

Tanah

Tanah merupakan material yang terdiri dari gabungan mineral padat yang tidak terikat secara kimia antar satu sama lain dan dari bahan-bahan organik yang telah melapuk disertai dengan zat cair dan gas serta partikel padat (Ummah, 2024). Proses pembentukan tanah dimulai dari hasil pelapukan bahan-bahan organik yang berupa sisa-sisa tumbuhan yang membusuk, akibat adanya aktivitas mikroorganisme yang bercampur dengan bahan mineral di permukaan tanah sehingga membentuk lapisan tanah. Tanah berfungsi sebagai media tanam tumbuhan dan sebagai tempat tumbuh berkembangnya tanaman. Secara kimiawi tanah berfungsi sebagai gudang penyuplai unsur hara dan nutrisi, secara biologis tanah berfungsi sebagai habitat biota (organisme) yang ikut berpartisipasi dalam penyediaan hara dan zat-zat aditif pemacu tumbuhnya tanaman. Dan secara integral tanah berfungsi sebagai penunjang produktivitas untuk menghasilkan biomas dan sebagai tempat produktivitas baik itu tanaman pangan, industri perkebunan maupun kehutanan (ANANDA MUHAMAD TRI UTAMA, 2022).

Deep Learning


Deep learning merupakan metode dalam kecerdasan buatan (AI) yang melatih komputer untuk memproses sebuah data dengan cara yang mirip dengan manusia saat memproses sebuah informasi. Deep learning terinspirasi dari otak manusia dalam mengenali gambar, teks, suara serta pola data lain untuk menghasilkan informasi, wawasan dan prediksi yang kuat (Amazon, t.t.). terdapat dua jenis utama dalam sistem deep learning dengan arsitektur yang berbeda, yaitu jaringan neural konvolusional (CNN) dan jaringan neurak berulangi (RNN) (Web, 2024). Algoritma deep learning dilatih mengidentifikasi pola dan mengklasifikasi informasi untuk memberikan output yang diinginkan pada saat menerima input baru. Deep learning secara otomatis mengekstrak features untuk klasifikasi, membutuhkan sejumlah data besar untuk melatih algoritmanya (Winnarto, 2024).

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan jenis arsitektur jaringan saraf tiruan yang dirancang secara khusus untuk memproses dan menganalisis data spasial, seperti citra. *CNN* terinspirasi dari cara manusia menginterpretasikan sebuah informasi visual (Syahrul & Putra, 2024). Dalam konteks klasifikasi jenis tanah, *CNN* dapat mengidentifikasi karakteristik visual dari tanah seperti tekstur, warna, dan pola yang dapat membedakan berbagai jenis tanah. *CNN* banyak digunakan dalam pengenalan pola, pengolahan citra, dan klasifikasi data karena kemampuannya dalam menangkap fitur penting dari data input. Salah satu keunggulan *CNN* yaitu mempunyai kemampuan untuk belajar secara otomatis dalam mengekstraksi fitur dari data gambar tanpa harus memerlukan proses manual yang kompleks (Setia Budi dkk., 2024). *CNN* pertama kali dikembangkan oleh Kunihiko Fukushima, seorang peneliti dari *NHK Broadcasting Science Research Laboratories* Tokyo, Jepang pada tahun 1980 dengan nama *NeoCognitron*. Arsitektur ini kemudian banyak mengalami perkembangan signifikan dengan pencapaian penting pada tahun 2012 ketika Alex Krizhevsky dengan penerapan *CNN* miliknya berhasil memenangkan kompetisi *ImageNet Large Scale Visual Recognition Challenge* 2012. Keberhasilan ini menjadi bukti bahwa metode *CNN* efektif dalam mengklasifikasi objek pada citra (Suartika E. P, I Wayan, Wijaya Arya Yudhi, 2016).

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen. Pendekatan kuantitatif dipilih karena fokus penelitian ini pada pengumpulan dan analisis data numerik yang memungkinkan pengolahan data secara objektif dan terukur. Meskipun output dari model *CNN* ini berupa kategori jenis tanah, akan tetapi hasil klasifikasi tersebut dapat dievaluasi menggunakan metrik numerik seperti akurasi, precision, recall, dan F1-score yang berupa data numerik. Penelitian ini dilakukan melalui serangkaian tahapan sistematis untuk mengembangkan sistem klasifikasi jenis tanah berbasis *Convolutional Neural Network (CNN)* dan sistem rekomendasi tanaman berbasis *Content-Based Filtering* sederhana



Gambar 1. Tahapan Penelitian

Perumusan masalah

Penelitian dimulai dengan identifikasi permasalahan utama, yaitu bagaimana membangun sistem klasifikasi jenis tanah menggunakan CNN dari citra digital tanah, serta bagaimana menghubungkan hasil klasifikasi tersebut dengan sistem rekomendasi tanaman secara otomatis berdasarkan hasil klasifikasi jenis tanah yang terdeteksi.


Pengumpulan Data

Data yang diperoleh berasal dari platform kaggle dan Robbiflow, platform ini menyediakan dataset citra tanah dengan berbagai jenis tanah yang sudah diklasifikasi (KurniaAisyah, 2024)(Roboflow, 2024). Dataset citra tanah yang dipakai berjumlah 1.200 gambar yang telah diklasifikasikan ke dalam delapan kelas diantaranya aluvial, andosol, entisol, humus, inceptisol, laterit, pasir, dan latosol. Berdasarkan skala pengukuran data kuantitatif, data yang digunakan ini termasuk kedalam kategori data kuantitatif diskrit, Karena data yang dipakai merupakan data yang terpisah satu sama lain. Jumlah gambar dalam dataset dihitung berdasarkan jumlah citra per kelas sesuai dengan skala pengukuran data kuantitatif menurut Sugiyono (2023) (PROF. DR. SUGIYONO, 2023). Setiap gambar menggunakan format JPG dan telah diberi label sesuai dengan jenis tanahnya. Penggunaan dataset ini memungkinkan pemanfaatan dataset dengan data yang sudah dikategorikan dengan baik, sehingga dapat langsung digunakan untuk pelatihan model CNN. Meskipun demikian, dilakukan seleksi dataset untuk memastikan kesesuaian data dengan tujuan penelitian. Selain itu dilakukan juga studi literatur dengan kajian terhadap berbagai penelitian sebelumnya yang berkaitan dengan klasifikasi jenis data, implementasi CNN, serta sistem rekomendasi berbasis *content based filtering*. Studi literatur dilakukan dengan tujuan untuk memahami pendekatan yang sudah digunakan pada penelitian sebelumnya, dengan begitu hal itu dapat membantu dalam menentukan metode apa yang akan efektif digunakan. Dan studi literatur ini juga dilakukan untuk mengidentifikasi Teknik terbaik untuk memperoleh klasifikasi terbaik.

Preprocessing Data

Sebelum digunakan dalam pelatihan model, Data yang telah dikumpulkan kemudian diproses melalui tahap preprocessing untuk memastikan kualitas dan keseragaman data sebelum pelatihan model data citra tanah mengalami serangkaian proses preprocessing, antara lain:

1. Resizing gambar menjadi 224x224 piksel.
2. Normalisasi piksel dengan rescale agar setiap nilai piksel berada dalam rentang 0–1. Tujuan proses ini adalah untuk meningkatkan generalisasi model dan mengurangi risiko overfitting.
3. Membagi data, dataset jenis tanah yang diambil dari kaggle dan Roboflow akan digunakan untuk pembuatan model. Dataset tersebut dibagi menjadi data training 70%, data validation 15% dan data testing 15%.
4. Augmentasi data menggunakan rotasi, pergeseran, zoom, dan pembalikan horizontal.



Gambar 2. Alur Teknik Analisis Data (Rumfot dkk., 2024)

Gambar 3.2 merupakan alur teknik analisis data yang dilakukan dalam penelitian ini, prosesnya dimulai dengan mengumpulkan dataset yang diambil dari platform kaggle dan robolow. Tahap selanjutnya diubah ukurannya, kemudian dilakukan normalisasi data, membagi data dan tahap terakhir adalah augmentasi gambar.

Penerapan model CNN



Gambar 3. Implementasi Model CNN

Dalam tahap ini, dilakukan eksperimen dengan berbagai kombinasi hyperparameter seperti jumlah layer, ukuran kernel, dan fungsi aktivasi guna mendapatkan model yang paling optimal. Dalam penerapan model Convolutional Neural Network (CNN) Arsitektur CNN yang digunakan dalam penelitian ini adalah MobileNetV2 dengan pendekatan transfer learning. Tahapannya dijelaskan sebagai berikut:


- Input Layer: menerima citra 224x224 piksel dalam format RGB.
- Convolutional Base: menggunakan MobileNetV2 pretrained pada ImageNet sebagai feature extractor.
- Fine-Tuning Layers: ditambahkan layer GlobalAveragePooling2D, Dense (128 unit, ReLU), dan output layer (8 neuron, softmax) untuk klasifikasi ke dalam 8 jenis tanah.
- Training: dilakukan dengan Adam optimizer dan fungsi loss categorical crossentropy.
- Evaluasi: hasil model dievaluasi menggunakan metrik akurasi, precision, recall, dan F1-score.

Pelatihan Model dan Evaluasi

Model CNN dilatih menggunakan dataset yang telah diproses sebelumnya. Dataset dibagi menjadi 3 bagian untuk memastikan generalisasi model dapat mengenali pola dari data baru dan untuk menilai sejauh mana model mampu mengklasifikasikan jenis tanah secara akurat dan konsisten terhadap data yang belum pernah dilihat. Evaluasi performa model dilakukan dengan menggunakan metrik evaluasi seperti akurasi (untuk mengukur sejauh mana model dapat mengklasifikasi jenis tanah dengan benar),

presisi dan recall (untuk mengevaluasi keseimbangan antar deteksi), dan F1-score (mengukur kinerja model).

Implementasi Sistem Rekomendasi



Gambar 4. Implementasi Sistem Rekomendasi

Setelah model *CNN* berhasil dikembangkan dan diuji, hasil klasifikasi tanah diintegrasikan dengan sistem rekomendasi tanaman berbasis *Content-Based Filtering* sederhana. Proses ini mencakup penggunaan algoritma *Content Based Filtering* Sistem rekomendasi untuk membandingkan jenis tanah yang di klasifikasi dengan data jenis tanaman. Kemudian jenis tanah yang telah diklasifikasi oleh *CNN* dicocokkan dengan karakteristik tanaman yang sesuai, sehingga sistem dapat merekomendasikan tanaman dengan optimal.

HASIL DAN PEMBAHASAN

Dataset

Dataset berupa gambar tanah yang digunakan dalam penelitian ini diperoleh dari platform Kaggle dan Roboflow. Dataset berjumlah 1.200 citra tanah yang telah diklasifikasikan ke dalam delapan kelas yaitu : humus, aluvial, andosol, laterit, entisol, inceptisol, pasir dan latosol. Setiap kelas memiliki data yang relatif seimbang, masing-masing sekitar 150 citra. Dataset ini digunakan untuk melatih dan menguji model klasifikasi jenis tanah berbasis *Convolutional Neural Network (CNN)*.

Pembagian data dilakukan dengan proporsi sebagai berikut:

```
# Path folder asal
source_dir = "D:/Skripsiww/Dataset_Jenis_Tanah"
# Path folder tujuan
target_base_dir = "D:/Skripsiww/Dataset_Jenis_Tanah_Split"

# Rasio split
train_ratio = 0.7
val_ratio = 0.15
test_ratio = 0.15

# Membuat folder target
for split in ['train', 'val', 'test']:
    os.makedirs(os.path.join(target_base_dir, split), exist_ok=True)
```

Gambar 5. Potongan Code untuk Pembagian Data

70% untuk data training
Jumlah gambar : 840 (8 kelas)

15% untuk data validasi
Jumlah gambar :176 (8 kelas)

15 % untuk data testing
Jumlah gambar : 184 (8 kelas)

Berikut merupakan jumlah data pada setiap kelas :

Tabel 1. Data Citra Pada Setiap Kelas

No	Jenis Tanah	Jumlah citra	Gambar salah satu Dataset
1.	Tanah Aluvial	150 citra Training :105 Testing : 23 Validation : 22	
2.	Tanah Andosol	150 citra Training :105 Testing : 23 Validation : 22	
3.	Tanah Entisol	150 citra Training :105 Testing : 23 Validation : 22	
4.	Tanah Humus	150 citra Training :105 Testing : 23 Validation : 22	
5.	Tanah Inceptisol	150 citra Training :105 Testing : 23 Validation : 22	
6.	Tanah Laterit	150 citra Training :105 Testing : 23 Validation : 22	
7.	Tanah Latosol	150 citra Training :105 Testing : 23 Validation : 22	

8.	Tanah Pasir	150 citra Training :105 Testing : 23 Validation : 22	
----	-------------	---	--

Sumber : Kaggle dan Roboflow (KurniaAisyah, 2024)(Roboflow, 2024)

Untuk memastikan kualitas dataset yang digunakan, dilakukan kurasi manual pada citra yang sebelumnya dikumpulkan. Gambar yang memiliki kualitas buruk seperti terlalu gelap atau tidak sesuai dihilangkan dari dataset. Hal ini bertujuan agar model dapat belajar dari data yang baik. Pada tahap ini diterapkan proses *processing* menggunakan fungsi ImageDataGenerator yang meliputi proses normalisasi pixel (rescale=1./255) serta augmentasi dengan tujuan untuk meningkatkan keragaman data pelatihan serta membantu model menjadi lebih kuat terhadap noise minor yang mungkin masih terdapat pada citra, seperti perbedaan pencahayaan atau sudut pengambilan gambar.

Preprocessing dan Augmentasi Data


```
img_size = (224, 224)
batch_size = 16

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=30,
    zoom_range=0.2,
    horizontal_flip=True,
    width_shift_range=0.1,
    height_shift_range=0.1
)
```

Gambar 6. Potongan Code Preprocessing dan Augmentasi

Data preprocessing pada penelitian ini adalah mengubah ukuran citra menjadi ukuran 224 x 224. Preprocessing data dilakukan sebelum digunakan dalam pelatihan model, tujuan digunakannya preprocessing data agar seluruh dataset citra tanah diproses terlebih dahulu melalui serangkaian tahapan sehingga sesuai dengan format input yang dibutuhkan oleh arsitektur CNN dan agar meningkatnya kinerja model. Pembagian ini dilakukan secara sistematis untuk memastikan proses pelatihan dan evaluasi berjalan objektif dan tidak bias. Seluruh proses preprocessing dilakukan menggunakan pustaka TensorFlow dan Keras, dengan memanfaatkan class ImageDataGenerator. Fungsi ini memungkinkan penerapan otomatis untuk tahapan seperti resizing, rescaling, serta augmentasi data secara langsung dari direktori dataset berdasarkan label folder yang tersedia. Proses ini dijalankan di platform Google Colab yang mendukung akselerasi pelatihan model menggunakan CPU.

Pembuatan Model



Gambar 7. arsitektur MobileNetV2

Setelah tahap preprocessing dan augmentasi data selesai, langkah berikutnya adalah membangun model CNN untuk klasifikasi citra dengan menggunakan arsitektur MobileNetV2 melalui teknik transfer learning. Teknik transfer learning diimplementasikan untuk mengatasi masalah keterbatasan data dengan memanfaatkan model yang telah dilatih sebelumnya (pre-trained) dalam melatih model pada dataset yang terbatas atau berukuran kecil. Pada tahap ini, dilakukan proses ekstraksi fitur menggunakan MobileNetV2 yang sebelumnya telah dilatih dengan dataset ImageNet. MobileNetV2 telah melalui pelatihan pada koleksi data ImageNet yang merupakan dataset berukuran besar berisi 1,4 juta gambar

dari 1.000 kategori gambar web. Untuk tahap klasifikasi, digunakan layer Global Average Pooling dan Dense dengan fungsi aktivasi Softmax yang menghasilkan 8 neuron output sesuai dengan jumlah kategori jenis tanah yang akan diklasifikasikan. Parameter Fully Connected Layer dapat memperlambat proses pelatihan dan berpotensi menyebabkan overfitting, sehingga Global Average Pooling digunakan untuk menghasilkan satu feature map untuk setiap kategori klasifikasi yang langsung terhubung ke lapisan softmax. Fungsi aktivasi softmax digunakan untuk melakukan klasifikasi terhadap 8 kategori jenis tanah, yaitu tanah Andosol, Inceptisol, Entisol, Aluvial, Humus, Tanah Berpasir, Laterit, dan Latosol.

Tabel 2. Model Summary MobileNetV2

NO	Nama Layer	Tipe Layer	Output Shape	Jumlah Parameter
1	input_layer	Output Layer	(None, 224, 224, 3)	0
2	Conv1	Conv2D	(None, 112, 112, 32)	864
3	bn_Conv1	BatchNormalization	(None, 112, 112, 32)	128
4	expanded_conv_depthwise	DepthwiseConv2D	(None, 112, 112, 32)	288
5	block_1_expand	Conv2D	(None, 112, 112, 96)	1,536
6	block_1_depthwise	DepthwiseConv2D	(None, 112, 112, 96)	864
7	block_1_project	Conv2D	(None, 56, 56, 24)	2,304
8	block_3_add	Add	(None, 56, 56, 24)	0
9	block_6_project	Conv2D	(None, 14, 14, 64)	24,576
10	block_13_project	Conv2D	(None, 7, 7, 160)	92,16
11	Conv_1	Conv2D	(None, 7, 7, 1280)	409,6
12	global_avg_pool	GlobalAveragePooling2D	(None, 1280)	0
13	Dense_1	Dense	(None, 128)	169,968
14	Output Layer	Dense (Softmax)	(None, 8)	1,032

Penjelasan Arsitektur:

1. Input Layer

Pada bagian ini input layer menerima citra dengan ukuran 224x224 piksel dengan 3 chanel (RGB) yang merupakan standar input untuk *MobileNetV2*.

2. Conv2D dan BatchNormalization

Pada proses bagian awal berfungsi untuk menormalisasi dan mengekstrak fitur dasar dari citra.

3. Block Expansion, Depthwise, dan Projection merupakan bagian inti dari Linear Bottleneck di *MobileNetV2*.

- Expansion Layer: memperluas jumlah channel menggunakan Conv2D 1x1.
- DepthwiseConv2D: melakukan filterisasi per channel secara efisien.
- Projection Layer: menurunkan dimensi kembali agar efisien.

4. GlobalAveragePooling2D menggantikan flatten untuk mereduksi dimensi fitur dari 7x7 menjadi 1x1, sehingga menghindari overfitting dan mengurangi jumlah parameter.

5. Dropout digunakan untuk regularisasi dengan membuang sebagian neuron secara acak saat training.

6. Dense (Softmax) berfungsi sebagai layer klasifikasi akhir yang menghasilkan 8 output, sesuai jumlah kelas citra tanah

```
base_model = MobileNetV2(input_shape=(224, 224, 3), include_top=False, weights='imagenet')
base_model.trainable = False # freeze pretrained layer

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dropout(0.3)(x)
x = Dense(128, activation='relu')(x)
output = Dense(train_gen.num_classes, activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=output)

model.compile(
    optimizer=Adam(learning_rate=2e-4),
    loss='categorical_crossentropy',
    metrics=['accuracy']
)

model.summary()
```

Gambar 8. Pembuatan Model

Eksperimen Hyperparameter

Pada proses klasifikasinya penelitian ini menggunakan arsitektur *MobileNetV2* untuk mengklasifikasikan jenis tanah. Optimizer yang digunakan pada proses klasifikasi adalah "adam". Selanjutnya untuk menghasilkan akurasi yang optimal pada penelitian ini dilakukan beberapa eksperimen terhadap implementasi data dan hyperparameter yang digunakan. Pada tahap awal penelitian, dilakukan eksperimen untuk menguji implementasi data. Eksperimen yang dijalankan meliputi pengujian metode dengan menerapkan augmentasi data dan metode tanpa menggunakan augmentasi data. Berikut ini

adalah hasil eksperimen yang telah dilaksanakan dengan membandingkan penggunaan augmentasi data dan tanpa penerapan augmentasi data.

Tabel 3. Penentuan Penggunaan Augmentasi dan Tanpa Augmentasi

Data	Split Data			Optimazer	Batch Size	Epoch	Akurasi
	Train	Validasi	Test				
Tanpa Augmentasi	70%	15%	15%	Adam	16	30	0.9364
Augmentasi	70%	15%	15%	Adam	16	50	0.9519

Berdasarkan hasil eksperimen pada implementasi data, pemilihan metode akan ditentukan berdasarkan nilai akurasi yang diperoleh, dimana perbandingan tersebut dipilih berdasarkan parameter akurasi tertinggi. Dalam konteks ini, metode augmentasi data terpilih karena menghasilkan nilai akurasi yang lebih tinggi dibandingkan metode tanpa augmentasi, yaitu mencapai 95%. Selanjutnya, parameter tersebut akan digunakan untuk eksperimen berikutnya, yaitu penentuan batch size. Nilai batch size yang akan diuji adalah 16 dan 32. Pemilihan nilai ini didasarkan pada popularitas ukuran batch size tersebut dan kesesuaiannya untuk dataset berukuran kecil. Berikut Tabel 4.4 menampilkan hasil percobaan yang telah dilakukan dalam penentuan nilai *batch size*.

Tabel 4. Penentuan Nilai Batch Size

Data	Split Data			Optimazer	Batch Size	Epoch	Akurasi
	Train	Validasi	Test				
Augmentasi	70%	15%	15%	Adam	16	30	0.9384
Augmentasi	70%	15%	15%	Adam	32	30	0.9103

Berdasarkan eksperimen terhadap nilai batch size, pemilihan ditentukan berdasarkan nilai akurasi tertinggi yang diperoleh. Dalam penelitian ini, batch size 16 menghasilkan akurasi yang lebih tinggi dibandingkan batch size 32, yaitu sebesar 94%. Parameter hasil eksperimen ini akan digunakan untuk percobaan berikutnya dalam menentukan jumlah epoch yang optimal. Tabel 4.5 berikut ini menampilkan hasil eksperimen yang telah dilakukan untuk menentukan jumlah epoch yang tepat.

Tabel 5. Penentuan Jumlah Epoch

Data	Split Data			Optimazer	Batch Size	Epoch	Akurasi
	Train	Validasi	Test				
Augmentasi	70%	15%	15%	Adam	16	30	0.9304
Augmentasi	70%	15%	15%	Adam	16	50	0.9649

Penentuan jumlah epoch didasarkan pada nilai akurasi tertinggi yang diperoleh. Berdasarkan hasil eksperimen dalam penelitian ini, akurasi terbaik dihasilkan oleh penggunaan 30 epoch dengan perolehan akurasi sebesar 96%. Dari keseluruhan percobaan yang dilakukan, konfigurasi terbaik dalam penelitian ini adalah menggunakan arsitektur MobileNetV2 dengan penerapan augmentasi data, pembagian dataset terdiri dari 75% untuk training, 15% untuk validasi, dan 15% untuk testing, menggunakan optimizer "adam" dengan batch size 16 dan jumlah epoch 50 yang mampu menghasilkan akurasi tertinggi mencapai 96,49%.

Tabel 6. Penentuan Penggunaan Fine-Tuning

Data	Split Data			Optimazer	Batch Size	Epoch	Akurasi
	Train	Validasi	Test				
Tanpa Fine-Tuning	70%	15%	15%	Adam	16	50	0.9649
Fine-Tuning	70%	15%	15%	Adam	16	50	0.9734

Meskipun tahap fine-tuning dapat meningkatkan akurasi training secara numerik, namun berdasarkan hasil evaluasi confusion matrix menunjukkan bahwa proses fine-tuning justru menyebabkan penurunan akurasi klasifikasi antar kelas. Oleh karena itu, pada penelitian ini diputuskan untuk hanya menggunakan tahap feature extraction (tanpa fine-tuning) karena menghasilkan performa yang lebih stabil dan akurat.

Hasil Pemodelan dan Eksperimen

```
plt.plot(history.history['accuracy'], label='Train Acc')
plt.plot(history.history['val_accuracy'], label='Val Acc')
plt.xlabel('Epoch')
plt.ylabel('Accuracy')
plt.legend()
plt.title('Akurasi Training vs Validation')
plt.show()
```

Gambar 9. Menampilkan Grafik Akurasi dan Training

```
plt.figure(figsize=(8, 5))
plt.plot(history.history['loss'], label='Train Loss', color='blue')
plt.plot(history.history['val_loss'], label='Val Loss', color='orange')
plt.xlabel('Epoch')
plt.ylabel('Loss')
plt.title('Loss Training vs Validation')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
```

Gambar 10. Menampilkan Grafik Training vs Validasi


Berikut Tabel 7 yang merupakan hasil pemodelan dan eksperimen :

Tabel 7 Perbandingan Akurasi dan Loss

Data	Akurasi	Nilai Loss
Data Train	0,9649	0,1983
Data Validasi	0,9432	0,1978

Berdasarkan hasil pelatihan pada epoch 50, model menghasilkan akurasi sebesar 96,49% pada data train dan 94,32% pada data validasi. Nilai loss yang relatif rendah menunjukkan model mampu belajar dengan baik tanpa adanya indikasi overfitting yang signifikan.

Selanjutnya akan ditampilkan grafik akurasi dan nilai loss antara data train dan validasi untuk mengetahui model mengalami overfitting, underfitting atau good fit. Berikut adalah grafik akurasi dan nilai loss pada data train dan data validasi.




Gambar 11. Grafik Akurasi Training dan Validasi



Gambar 12. Grafik akurasi Loss dan Training

Gambar 11 menampilkan grafik perkembangan nilai akurasi pada data training dan validation, sedangkan Gambar 12 menunjukkan grafik nilai loss dari proses pelatihan model. Garis berwarna biru menggambarkan performa pada data training, sementara garis berwarna oranye menggambarkan performa pada data validation. Berdasarkan grafik akurasi, terlihat bahwa nilai akurasi pada data training maupun validation mengalami peningkatan secara bertahap dan konsisten seiring bertambahnya epoch. Pada akhir pelatihan, model berhasil mencapai akurasi training sebesar 96.49% dan akurasi validation sebesar 94.32%, yang menunjukkan bahwa model mampu mengenali pola dari data pelatihan dan melakukan generalisasi yang baik terhadap data validasi. Pada grafik loss, nilai loss pada data training dan validation juga menunjukkan tren penurunan yang stabil. Di akhir pelatihan, nilai loss pada data training tercatat sebesar 0.1383, sedangkan loss pada data validation sebesar 0.1978. Nilai loss yang rendah dan mendekati antara kedua data tersebut mengindikasikan bahwa model tidak mengalami kesalahan yang besar dalam melakukan prediksi.

Secara keseluruhan, grafik akurasi dan loss ini menunjukkan bahwa model memiliki performa pelatihan yang baik atau good fit. Tidak terdapat tanda-tanda overfitting (performa bagus di data latih tetapi buruk di validasi) maupun underfitting (model gagal belajar dari data). Hal ini menandakan bahwa strategi pelatihan dan arsitektur model yang digunakan sudah sesuai dan efektif untuk tugas klasifikasi citra jenis tanah. Berikut hasil klasifikasi jenis tanah menggunakan *CNN* dengan arsitektur *MobileNetV2* :





Gambar 13. Hasil Klasifikasi Jenis Tanah

Dari 1.200 citra dataset jenis tanah ditampilkan 8 sample hasil klasifikasi jenis tanah. Dengan adanya hasil ini menjadi bukti bahwa model berjalan dengan baik dan berhasil mengidentifikasi jenis tanah, serta menunjukkan semua sample data yang diuji terklasifikasi dengan benar.


Evaluasi

```
# Prediksi data validasi
val_gen.reset()
y_true = val_gen.classes
y_pred = model.predict(val_gen)
y_pred_classes = np.argmax(y_pred, axis=1)

# Report
print(classification_report(y_true, y_pred_classes, target_names=list(val_gen.class_indices.keys())))

# Confusion Matrix
cm = confusion_matrix(y_true, y_pred_classes)
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', xticklabels=val_gen.class_indices.keys(), yticklabels=val_gen.class_indices.keys(), cmap='Blues')
plt.xlabel("Predicted")
plt.ylabel("True")
plt.title("Confusion Matrix")
plt.show()
```

Gambar 14. Menampilkn Confusion Matrix



Gambar 15. Hasil Evaluasi Menggunakan Confusion Matrix

Proses evaluasi model dilakukan menggunakan confusion matrix dan classification report untuk mengukur kinerja klasifikasi pada data uji. Confusion matrix menampilkan performa model dengan memperlihatkan jumlah prediksi benar dan salah berdasarkan kelas yang sebenarnya. Beberapa komponen penting pada confusion matrix yaitu:

True Positive (TP): Prediksi benar terhadap kelas yang sesuai.

True Negative (TN): Prediksi benar terhadap kelas lain.

False Positive (FP): Prediksi salah terhadap kelas target, padahal bukan.

False Negative (FN): Prediksi salah terhadap kelas lain, padahal seharusnya kelas target.

Berdasarkan Gambar 4.5 yang menampilkan hasil confusion matrix, model menunjukkan performa klasifikasi yang sangat baik terhadap 176 citra uji dari delapan kelas jenis tanah. Berikut adalah hasil evaluasi tiap kelas:

1. Aluvial: Sebanyak 21 dari 22 citra diklasifikasikan dengan benar sebagai Aluvial, dan 1 citra salah diklasifikasikan sebagai Inceptisol.
2. Andosol: Seluruh 22 citra Andosol berhasil diklasifikasikan dengan benar (akurasi 100%).
3. Entisol: Dari total 22 citra, sebanyak 20 citra diklasifikasikan dengan benar, sedangkan 1 citra salah sebagai Andosol dan 1 citra salah sebagai Laterit.
4. Humus: Dari 22 citra, 20 terklasifikasi dengan benar, dan 2 citra salah sebagai Laterit.
5. Inceptisol: Seluruh 22 citra berhasil diklasifikasikan dengan benar (akurasi 100%).
6. Laterit: Dari 22 data, 20 terklasifikasi dengan benar, dan 2 citra salah diklasifikasikan sebagai Andosol.
7. Latosol: Semua 22 citra berhasil diklasifikasikan dengan benar (akurasi 100%).
8. Pasir: Sebanyak 22 citra Pasir juga diklasifikasikan seluruhnya dengan benar (akurasi 100%).

Secara keseluruhan, hasil confusion matrix menunjukkan bahwa sebagian besar kelas memiliki performa klasifikasi yang sangat tinggi, dengan hanya beberapa kesalahan minor yang terjadi terutama pada kelas Humus, Entisol, dan Laterit.

Berikut Gambar 16 menampilkan classification report yang menunjukkan hasil akurasi, precision dan recall.

	precision	recall	f1-score	support
Aluvial	1.00	0.95	0.98	22
Andosol	0.88	1.00	0.94	22
Entisol	1.00	0.91	0.95	22
Humus	1.00	0.91	0.95	22
Inceptisol	0.96	1.00	0.98	22
Laterit	0.87	0.91	0.89	22
Latosol	1.00	1.00	1.00	22
Pasir	1.00	1.00	1.00	22
accuracy			0.96	176
macro avg	0.96	0.96	0.96	176
weighted avg	0.96	0.96	0.96	176

Gambar 16. Classification Report

Classification report di atas menunjukkan model menghasilkan akurasi sebesar 96% dengan nilai *precision*, *recall* dan *f1-score* rata rata mencapai 96 % hal ini menunjukkan performa model konsisten di seluruh kelas. Dari hasil *classification report* dan *confusion matrix* dapat disimpulkan bahwa model MobileNetV2 mampu mengklasifikasi jenis tanah dengan baik. Dari tabel 4.9 terlihat classification report dari setiap kelas, setiap hasil dari setiap kelas bisa dihitung melalui rumus berikut berdasarkan evaluasi yang di hasilkan oleh matrix evaluasi. Berikut salah satu contoh perhitungan untuk kelas tanah aluvial :


$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} = \frac{21+22+20+20+22+20+22+22}{176} = 0.96$$

$$Precision = \frac{TP}{TP+FP} = \frac{21}{21+0} = 1.00$$

$$Recall = \frac{TP}{TP+FN} = \frac{21}{21+1} = 0.95$$

$$F1\text{- Score} = 2 \times \frac{Precision \times recall}{Precision + recall} = 2 \times \frac{1.00 \times 0.95}{1.00 + 0.95} = 0,98$$

Integrasi Hasil Klasifikasi ke dalam Sistem Rekomendasi Jenis Tanaman Menggunakan *Content-Based-Filtering*



```

# === Klasifikasi dengan CNN ===
prediksi = model.predict(img_array)
kelas_index = np.argmax(prediksi)

# === Ambil nama label (misal: pasir, humus, dst.)
class_indices_inv = {v: k for k, v in train_gen.class_indices.items()}
jenis_tanah_prediksi = class_indices_inv[kelas_index]

# === Sistem rekomendasi ===
kategori_tanaman_per_tanah = {
    'humus': ['musiman', 'tahunan'],
    'andosol': ['musiman', 'tahunan'],
    'inceptisol': ['musiman'],
    'entisol': ['musiman'],
    'aluvisol': ['musiman'],
    'pasir': ['musiman'],
    'laterit': ['tahunan'],
    'latosol': ['tahunan']
}

tanaman_per_kategori = {
    'musiman': ['Padi', 'Jagung', 'Kedelai', 'Tebu', 'Sayuran', 'Umbi-umbian'],
    'tahunan': ['Kopi', 'Cokelat', 'Karet', 'Teh', 'Buah-buahan', ]
}

def rekomendasi_tanaman_dengan_kategori(jenis_tanah):
    kategori = kategori_tanaman_per_tanah.get(jenis_tanah.lower(), set())
    tanaman = []
    for k in kategori:
        tanaman.extend(tanaman_per_kategori.get(k, []))
    return kategori, tanaman

kategori_cocok, tanaman_rekomendasi = rekomendasi_tanaman_dengan_kategori(jenis_tanah_prediksi)

# === Tampilkan hasil ===
print(f"🟢 Jenis Tanah (hasil klasifikasi CNN): {jenis_tanah_prediksi.capitalize()}")
print(f"🟡 Cocok untuk kategori tanaman: {' '.join(kategori_cocok)}")
print(f"🟠 Rekomendasi tanaman: {' '.join(tanaman_rekomendasi)}")

```

Gambar 17. Diagram Alur Integrasi Klasifikasi dan Sistem Rekomendasi
Gambar 18. Sistem Rekomendasi Jenis Tanaman

Setelah proses klasifikasi jenis tanah berhasil dilakukan menggunakan arsitektur MobileNetV2, hasil klasifikasi kemudian diintegrasikan ke dalam sistem rekomendasi jenis tanaman menggunakan pendekatan content-based filtering. Proses ini dimulai dari input citra tanah yang diproses oleh model klasifikasi CNN, di mana output klasifikasi berupa label jenis tanah menjadi dasar pengambilan keputusan dalam sistem rekomendasi.

Sistem rekomendasi ini dikembangkan dengan pendekatan *content-based filtering* sederhana yang diimplementasikan menggunakan metode *rule-based*, yaitu dengan mencocokkan hasil klasifikasi jenis tanah dengan kategori tanaman yang telah dipetakan secara manual berdasarkan literatur. Pemetaan ini mengelompokkan tanaman ke dalam kategori tertentu (seperti musiman atau tahunan), dan setiap jenis tanah dipetakan ke satu atau lebih kategori tersebut. Gambar 4.8 menampilkan cuplikan hasil prediksi dan daftar tanaman yang direkomendasikan oleh sistem berdasarkan jenis tanah yang dikenali.

```

1/1 ————— 0s 88ms/step
🟢 Jenis Tanah (hasil klasifikasi CNN): Humus
🟡 Cocok untuk kategori tanaman: musiman, tahunan
🟠 Rekomendasi tanaman: Padi, Jagung, Kedelai, Tebu, Sayuran, Umbi-umbian, Kopi, Cokelat, Karet, Teh, Buah-buahan


```

Gambar 19. Output Sistem Rekomendasi

Dengan pendekatan ini, sistem tidak memerlukan proses pembelajaran ulang untuk merekomendasikan tanaman. Proses inferensi langsung dilakukan berdasarkan hasil klasifikasi yang dipetakan ke basis data aturan tanaman. Hal ini menjadikan sistem efisien, mudah diperbarui, dan fleksibel untuk diterapkan di berbagai jenis lahan atau kebutuhan pengguna.

Implementasi Sistem Berbasis Website

Hasil dari sistem klasifikasi tanah menggunakan CNN dan sistem rekomendasi menggunakan Content-Based-Filtering diimplementasikan dengan membuat website. Website ini dikembangkan sebagai media untuk memudahkan pengguna dalam mengidentifikasi jenis tanah berdasarkan citra tanah, serta memberikan rekomendasi jenis tanaman yang cocok untuk ditanami di tanah tersebut. Pengembangan sistem ini mengintegrasikan model CNN dengan sistem rekomendasi tanaman berbasis Content-Based-Filtering ke dalam platform website yang mudah diakses oleh siapa saja yang memerlukan. Flask merupakan Framework yang digunakan untuk mengembangkan website, flask dipilih karena ringan dan fleksibel. Berikut diagram alir dari perancangan website ini :



Gambar 20. Diagram Alur Website


Terdapat beberapa fitur utama dalam perancangan website ini, diantaranya :

1. Upload gambar : Pengguna dapat mengunggah foto tanah yang ingin diidentifikasi.
2. Hasil prediksi jenis tanah : Sistem akan memproses gambar menggunakan model klasifikasi CNN dan menampilkan jenis tanahnya.
3. Pemberian rekomendasi jenis tanaman : Setelah jenis tanah diketahui, sistem akan menampilkan daftar tanaman yang sesuai berdasarkan pemetaan kategori menggunakan pendekatan content-based filtering berbasis rule-based.

Alur sistem ini dimulai dari pengguna mengunggah citra tanah, kemudian model klasifikasi CNN memproses gambar tersebut untuk menentukan jenis tanah. Hasil klasifikasi ini menjadi input bagi sistem rekomendasi yang mencocokkan jenis tanah tersebut dengan kategori tanaman yang sesuai. Sistem akan menampilkan jenis tanah beserta rekomendasi jenis tanaman berupa tahunan atau musiman dan pemberian beberapa rekomendasi tanamannya. Implementasi ini bersifat dinamis, sehingga memungkinkan pengembangan lebih lanjut seperti penambahan data citra, peningkatan akurasi model, maupun fitur informasi tambahan tentang tanaman.


Berikut website klasifikasi jenis tanah dan sistem rekomendasi jenis tanaman

Halaman "Home" merupakan halaman utama yang digunakan untuk upload gambar dan proses prediksi.




Gambar 21. Halaman Home Website

Halaman hasil Prediksi yang menampilkan hasil prediksi jenis tanah dan rekomendasi jenis tanaman.



Gambar 22. Halaman Prediksi

Halaman About



Gambar 23. Halaman About

KESIMPULAN DAN SARAN

Kesimpulan

Dari hasil penelitian yang dilakukan diperoleh kesimpulan sebagai berikut :

1. Implementasi *CNN* dengan penerapan arsitektur *MobileNetV2* menggunakan teknik transfer learning dan ekstraksi fitur yang telah dilatih sebelumnya menggunakan *ImageNet*. Pada proses klasifikasinya digunakan lapisan konvolusi *Global Average Pooling* dan lapisan Dense dengan aktivasi Softmax untuk klasifikasi jenis tanah, serta dilakukannya pengujian berbagai hyperparameter pada prosesnya. Dan penggunaan sistem rekomendasi *Content-Based-Filtering* sederhana secara *rule-based* yang diimplementasikan menggunakan metode rule-based untuk pemberian rekomendasi jenis tanaman.
2. Klasifikasi jenis tanah menggunakan *CNN* dan arsitektur *MobileNetV2* menghasilkan nilai akurasi sebesar 96 %. Nilai yang dihasilkan membuktikan bahwa arsitektur ini terbukti mampu digunakan untuk mengklasifikasi jenis tanah.
3. Sistem klasifikasi jenis tanah diimplementasi menjadi website dan di uji menggunakan citra baru dan hasilnya menunjukkan bahwa model yang sudah di implementasikan menjadi website dapat melakukan klasifikasi dengan baik.

Saran

Meskipun arsitektur *MobileNetV2* yang digunakan sudah memberikan hal yang cukup baik, namun ada beberapa hal yang perlu ditambahkan untuk penelitian selanjutnya, adapun saran-saran yang diusulkan :

1. Adanya penelitian lebih lanjut dengan data yang lebih banyak dan jenis tanah yang lebih banyak lagi.
2. Penggunaan teori tanah tambahan seperti menjelaskan sifat-sifat tanah dan kandungan tanah.
3. Pemetaan sistem rekomendasi tidak hanya menggunakan rule-based berdasarkan literatur tapi ditambahkan dengan ph tanah dan sifat lainnya sehingga akan lebih akurat.

DAFTAR PUSTAKA

- Dan Jenis Tanah Berbasis Iot [Other, Universitas Komputer Indonesia].
https://doi.org/10/UNIKOM_IKHSAN%20ABDILLAH_BAB%205.pdf
- Allaam, M. R. R., & Wibowo, A. T. (2021). Klasifikasi Genus Tanaman Anggrek Menggunakan Metode Convolutional Neural Network (CNN). *e-Proceeding of Engineering*, 8(2), 3150–3179.
- Arnie, R., & Septiyani, W. (2019). Sistem Rekomendasi Jenis Lahan Untuk Tanaman Hortikultura Menggunakan Metode Fuzzy Tahani. *Progresif: Jurnal Ilmiah Komputer*, 14(2), Article 2.
<https://doi.org/10.35889/progresif.v14i2.318>
- As-Siddiqi, M. H., Auliasari, K., & Prasetya, R. P. (2022). Pembangunan Sistem Rekomendasi Jenis Pupuk Pada Tanaman Sawit Menggunakan Metode Ahp (Analytical Hierarchy Process). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 6(2), Article 2. <https://doi.org/10.36040/jati.v6i2.5407>
- Burhan, M. (2015). Sistem Rekomendasi Penanaman Jenis Tanaman Pangan Berdasarkan Kondisi Lahan Menggunakan Metode Simple Additive Weighting (Sa [Sarjana, Universitas Brawijaya].
<https://repository.ub.ac.id/id/eprint/146177/>
- Fhonna, R. P., Afrillia, Y., Zulfan, Aqmal, J., & Abadi, S. (2023). Klasifikasi Penentuan Jenis Tanah yang Sesuai Terhadap Tanaman Pangan Sebagai Solusi Ketahanan Pangan di Kabupaten Pidie Jaya Menggunakan Metode Random Forest. *Jurnal Informasi Dan Teknologi*, 12–18.
<https://doi.org/10.60083/jidt.v5i4.402>
- Gayo, A. A. P., Zainabun, Z., & Arabia, T. (2022). Karakterisasi Morfologi dan Klasifikasi Tanah Aluvial Menurut Sistem Soil Taxonomy di Kabupaten Aceh Besar. *Jurnal Ilmiah Mahasiswa Pertanian*, 7(3), 503–508.
- Kurdi, A. (2024). Aplikasi Deteksi Penyakit Pada Daun Bawang Merah Menggunakan Metode Deep Learning Berbasis Website [Diploma, Politeknik Harapan Bersama].
<http://eprints.poltektegal.ac.id/3993/>
- Laan, M. A. S., & Malahina, E. A. U. (2025). Penerapan Machine Learning Menggunakan Teachable Machine Untuk Mendeteksi Jenis Tanah Berbasis Citra Digital. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), Article 3. <https://doi.org/10.36040/jati.v9i3.13732>
- Liu, Y., Kelen, Y. P. K., & Risald, R. (2025). Sistem Pendukung Keputusan Penentuan Jenis Tanaman Produksi Unggulan Berbasis Web Menggunakan Algoritma Fuzzy Topsis. *ZONasi: Jurnal Sistem Informasi*. <https://journal.unilak.ac.id/index.php/zn/article/view/23499>
- M. Halim, A.-S. (2022). Pembangunan Sistem Rekomendasi Jenis Pupuk Pada Tanaman Sawit Menggunakan Metode AHP (Analytical Hierarchy Process) [Skripsi, ITN MALANG].
<https://eprints.itn.ac.id/8877/>
- Mukhlis, M., Dewi, I. K., Rhaizy, M. R., Fauzi, R. N., & Iqbal, M. (2024). Sistem Rekomendasi Penentuan Masa Tanam Padi Berbasis Website Di Desa Dawuan Kaler Subang. *SISTEMATIK*, 1(1), Article 1.
<https://journal.publinesia.com/index.php/sistematik/article/view/29>
- Mulyanto, B. S. (2013). Kajian Rekomendasi Pemupukan Berbagai Jenis Tanah Pada Tanaman Jagung, Padi Dan Ketela Pohon Di Kabupaten Wonogiri. <https://digilib.uns.ac.id/dokumen/29589/Kajian-Rekomendasi-Pemupukan-Berbagai-Jenis-Tanah-Pada-Tanaman-Jagung-Padi-Dan-Ketela-Pohon-Di-Kabupaten-Wonogiri>
- Naisali, A., Kelen, Y. P. K., Syarifuddin, R., & Ludji, D. G. (2025). Sistem pendukung keputusan pemilihan tanaman pangan berbasis web dengan Fuzzy Weighted Product. *Jurnal Simantec*, 14(1), Article 1.
<https://doi.org/10.21107/simantec.v14i1.29958>
- Putra, A. P., Bachtiar, E. A., Hidayatulloh, R., Ramadhani, A. S., Ummah, K., & Sholihah, W. (2024). Perancangan Sistem Rekomendasi Komoditas Pertanian Berdasarkan Lokasi Geografis Untuk Meningkatkan Produktivitas Petani. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(1), Article 1.
<https://doi.org/10.23960/jitet.v12i1.3936>
- Putri, N. A. (2024). Implementasi Algoritma Convolutional Neural Network (Cnn) Untuk Sistem Klasifikasi Penyakit Daun Cabai Berbasis Website [Diploma, Politeknik Harapan Bersama].
<http://eprints.poltektegal.ac.id/4161/>
- Rahmawati, R. P., Priyono, S., Akbar, S., & Rahman, Y. A. (2023). Sifat Fisik Tanah Dan Pertumbuhan Tanaman Padi (Oryza Sativa L.) Sebagai Dampak Pengaplikasian Dekomposer Pada Sistem Rekomendasi Pemupukan Berbasis Citra Kamera Multispektral Di Sukamandijaya, Jawa Barat.

- Jurnal Tanah Dan Sumberdaya Lahan, 10(2), 483–489.
<https://doi.org/10.21776/ub.jtsl.2023.010.2.31>
- Ramadhan, J., Hermadi, I., & Sitanggang, I. S. (2024). Sistem Pendukung Keputusan Cerdas untuk Pemilihan Jenis Tanaman Pertanian Kota. *Edumatic: Jurnal Pendidikan Informatika*, 8(1), Article 1. <https://doi.org/10.29408/edumatic.v8i1.25982>
- Rohmansyah, R., & Susanti, W. (2021). Penerapan Fuzzy AHP Untuk Pemilihan Jenis Lahan Tanaman Pangan. *Jurnal Mahasiswa Aplikasi Teknologi Komputer dan Informasi (JMApTeKsi)*, 3(1), 39–46.
- Subhiyakto, E. R., Astuti, Y. P., & Umaroh, L. (2021). Perancangan User Interface Aplikasi Pemodelan Perangkat Lunak Menggunakan Metode User Centered Design. *KONSTELASI: Konvergensi Teknologi dan Sistem Informasi*, 1(1), 145–154. <https://doi.org/10.24002/konstelasi.v1i1.4266>
- Suwanti, S. (2022). Penerapan Analytical Hierarchy Process Untuk Sistem Pendukung Keputusan Penentuan Jenis Tanah Terbaik Bagi Tanaman Porang (*Amorphophallus Muelleri*) [Skripsi, Universitas Muhammadiyah Ponorogo]. <https://eprints.umpo.ac.id/8643/>
- Wibowo, D., Alam, S., & Hazriani, H. (2019). Sistem Pendukung Keputusan Penentuan Jenis Tanaman Pangan Berbasis Web Menggunakan Algoritma Topsis. *JURNAL IT*, 10(2), Article 2. <https://doi.org/10.37639/jti.v10i2.160>
- Yahyan, W., & Siregar, M. I. A. (2020). Pemilihan Pupuk Pada Tanaman Padi Berbasis Web Untuk Meningkatkan Hasil Panen Dengan Menggunakan Metode Analitical Hierarchy Proses. *Rang Teknik Journal*, 3(2), Article 2. <https://doi.org/10.31869/rtj.v3i2.1706>.