

Analysis of Soil Quality and Classification Based on Image Processing: Image Sharpening Technique and CNN ResNet for Coastal Area Utilization Mapping

Analisis Kualitas dan Klasifikasi Jenis Tanah Berbasis Pengolahan Citra: Teknik Image Sharpening dan CNN ResNet untuk pemetaan pemanfaatan Daerah Pesisir

Harnelia¹, Fabelina Agsaria², Septiyani Bayu Saudi³, Rizal Adi Saputra⁴

^{1,2,3} Jurusan Teknik Informatika, Universitas Halu Oleo, Indonesia

¹harnelia134@gmail.com, ²fagsaria@gmail.com, ³septiyanibayusaudi@gmail.com,

^{4*}rizaladisaputra@uho.ac.id

Informasi Artikel

Received: January 2025

Revised: March 2025

Accepted: May 2025

Published: June 2025

Abstract

Purpose: This research aims to analyze the quality and classification of soil types in the Kendari Bay coastal area using image sharpening techniques and ResNet152V2 Convolutional Neural Network (CNN), to support sustainable coastal area resource management.

Design/methodology/approach: The research adopts a digital image processing approach with stages including dataset collection from Kaggle and fieldwork, image preprocessing, image sharpening, and classification using the CNN ResNet152V2 model. The dataset comprises 880 images from Kaggle and 110 images from the Teluk Kendari area, divided into training (80%), testing (10%), and validation (10%) datasets.

Findings/result: The CNN ResNet152V2 model achieved a classification accuracy of 90.91% in identifying eight soil types: Alluvial, Andosol, Entisol, Humus, Inceptisol, Laterite, Limestone, and Sand. The use of image sharpening significantly enhanced visual quality, clarified soil texture details, and facilitated the classification process.

Originality/value/state of the art: This study integrates image sharpening techniques with CNN ResNet to analyze coastal soils, a method rarely applied in Indonesia. It contributes to understanding coastal soil conditions and supports sustainable land management strategies.

Abstrak

Tujuan: Penelitian ini bertujuan untuk menganalisis kualitas dan klasifikasi jenis tanah di wilayah pesisir Teluk Kendari dengan menggunakan teknik image sharpening dan Convolutional Neural Network (CNN) ResNet152V2, guna

Keywords: CNN, coastal area, Digital Image Processing, image sharpening, ResNet, soil classification,
Kata kunci: area pesisir, CNN ResNet, Klasifikasi tanah, Penajaman citra, Pengolahan citra digital

mendukung pengelolaan sumber daya wilayah pesisir yang berkelanjutan.

Perancangan/metode/pendekatan: Penelitian menggunakan pendekatan pengolahan citra digital dengan tahapan: pengumpulan dataset dari Kaggle dan lapangan, *image preprocessing*, *image sharpening*, dan klasifikasi menggunakan model CNN ResNet152V2. Dataset terdiri dari 880 gambar dari Kaggle dan 110 gambar dari wilayah Teluk Kendari, dibagi menjadi data latih (80%), uji (10%), dan validasi (10%).

Hasil: Model CNN ResNet152V2 berhasil mencapai akurasi klasifikasi sebesar 90.91% dalam mengidentifikasi delapan jenis tanah (Aluvial, Andosol, Entisol, Humus, Inceptisol, Laterit, Kapur, dan Pasir). Teknik *image sharpening* terbukti efektif meningkatkan kualitas visual citra, memperjernih detail tekstur tanah, dan memudahkan proses klasifikasi.

Keaslian/ *state of the art*: Penelitian ini mengintegrasikan teknik *image sharpening* dan CNN ResNet untuk menganalisis tanah pesisir, yang sebelumnya belum banyak dilakukan di Indonesia. Pendekatan ini memberikan kontribusi dalam memahami kondisi tanah di wilayah pesisir dan mendukung strategi pengelolaan berkelanjutan.

1. Pendahuluan

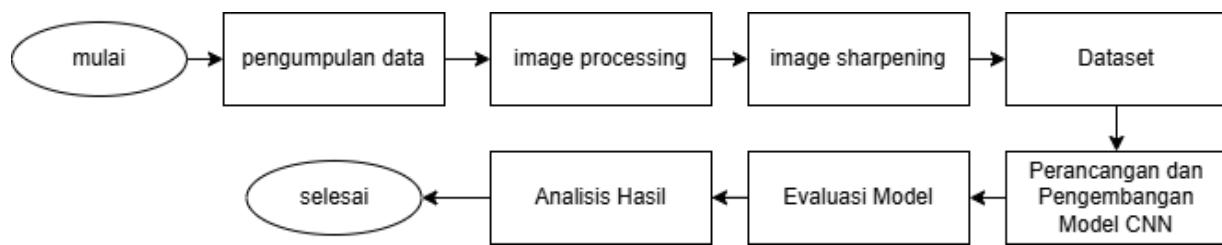
Wilayah pesisir memiliki arti strategis karena merupakan wilayah peralihan antara ekosistem darat dan laut yang berkesinambungan. Di wilayah pesisir ini terdapat sumber daya pesisir berupa sumber daya alam dan jasa lingkungan yang sangat kaya. Kekayaan sumber daya pesisir tersebut menimbulkan daya tarik bagi berbagai pihak untuk mengeksplorasinya dan berbagai instansi berkepentingan untuk meregulasi pemanfaatannya [1]. Daerah pesisir khususnya terpapar pada berbagai bahaya terkait iklim (misalnya, naiknya permukaan air laut, tingkat banjir yang lebih tinggi dan gelombang badi, erosi pantai yang dipercepat, intrusi air laut dan peningkatan keasaman laut dan suhu permukaan) [2]. Salinasi tanah yang disebabkan oleh kenaikan permukaan laut mengancam tanah pertanian pesisir dan lahan basah yang penting secara geokimia di seluruh dunia [3]. Tanah, sebagai dasar ekosistem daratan, memainkan peran penting dalam mendukung pertanian, keanekaragaman hayati, dan layanan ekosistem [4]. Namun, saat ini permintaan pangan berbasis pertanian intensif telah menurunkan kualitas tanah sehingga menimbulkan tantangan besar seperti peningkatan produktivitas pertanian dan mendorong kelestarian lingkungan [5]. Penilaian kualitas tanah menjadi penting untuk memahami kondisi lingkungan dan menentukan langkah-langkah pengelolaan yang berkelanjutan, khususnya di wilayah pesisir yang memiliki tekanan antropogenik yang tinggi.

Penelitian ini memberikan kontribusi penting dalam memahami kondisi tanah di wilayah pesisir, khususnya Teluk Kendari yang bertujuan untuk memberikan rekomendasi untuk pengelolaan yang berkelanjutan. Terdapat beberapa penelitian sebelumnya terkait judul: pertama penelitian

yang dilakukan oleh Iswari Nur Hidayati¹ , Eni Susanti² , Westi Utami³ [6] tentang Analisis Pan-Sharpening Untuk Meningkatkan Kualitas Spasial Citra Penginderaan Jauh Dalam Klasifikasi Tata Guna Tanah. Pada penelitian tersebut mencoba melakukan analisis pan-sharpened untuk mendapatkan hasil yang lebih maksimal dalam berbagai kenampakan untuk setiap tata guna tanah perkotaan. Hasilnya menunjukkan Akurasi klasifikasi penggunaan tanah menggunakan teknik sharpening mencapai 90,70%. Kedua, penelitian yang dilakukan oleh Syahruu Siyammu Rhomadhon¹ , Diah Rahayu Ningtias² [7]. Penelitian tersebut menggunakan model *convolutional neural network* (CNN) ResNet152V2, untuk mengklasifikasikan jenis tumor otak dari gambar MRI. Hasil penelitian menunjukkan akurasi mencapai 94,44%, yang menandakan bahwa model ResNet152V2 efektif dalam mengklasifikasikan gambar tumor otak. Hasil penelitian diatas memiliki nilai akurasi dan performansi yang cukup tinggi dari penggunaan teknik image sharpening dan metode CNN ResNet. Namun, penelitian yang secara khusus mengintegrasikan kedua metode ini untuk menganalisis jenis tanah di wilayah pesisir, terutama di Indonesia, masih sangat terbatas. Hal ini menciptakan peluang untuk mengeksplorasi bagaimana kombinasi *image sharpening* dan CNN ResNet dapat diterapkan pada citra tanah pesisir guna mendukung pengelolaan sumber daya wilayah pesisir secara berkelanjutan. Penelitian ini bertujuan untuk menjawab kesenjangan tersebut dengan fokus pada wilayah Teluk Kendari. Jadi penelitian ini sangat berkontribusi pada pengelolaan wilayah pesisir dengan pendekatan yang menggabungkan teknik *image sharpening* dan CNN ResNet untuk pemetaan tanah yang sebelumnya belum banyak diterapkan di kawasan pesisir Indonesia

2. Metode/Perancangan

Langkah-langkah yang dilakukan dalam penelitian ini terdapat pada **Gambar 1**:



Gambar 1. Alur Penelitian

2.1.1 Pengolahan Citra

Citra merupakan salah satu bentuk informasi yang berupa gambar. Pengolahan citra bertujuan untuk memperoleh kualitas citra yang lebih baik dibandingkan dengan citra awal. Perbaikan citra merupakan tahap awal dari pengolahan citra yang selanjutnya akan digunakan untuk kebutuhan analisis citra [8]. Citra digunakan dalam berbagai aplikasi saat ini, seperti dalam sistem keamanan, sistem komunikasi, dan sistem medis. Ciri khas citra adalah kapasitas datanya yang besar, terutama untuk citra beresolusi tinggi[9].Citra mempunyai karakteristik yang tidak dimiliki oleh data teks, yaitu citra kaya dengan informasi. Meskipun sebuah citra kaya informasi, namun seringkali citra yang kita miliki penurunan mutu (degradasi) misalnya mengalami cacat atau derau, warnanya terlalu kontras, kurang tajam, kabur, dan sebagainya[10].

2.1.2 Python

Python merupakan sebuah bahasa pemrograman tingkat tinggi yang dibuat oleh Guido Van Rossum dan dirilis pada tahun 1991. Python juga merupakan bahasa yang sangat populer belakangan ini[11]. Python merupakan salah satu bahasa pemrograman yang banyak digunakan oleh perusahaan besar maupun para *developer* untuk mengembangkan berbagai macam aplikasi berbasis desktop, *web* dan *mobile*[12]. Python dimanfaatkan dalam penelitian ini untuk pengolahan citra tanah, terutama pada penerapan teknik *image sharpening*. Pendekatan ini meningkatkan ketajaman detail citra, sehingga mempermudah analisis visual dan pengambilan informasi yang lebih akurat dari data citra tanah.

2.1.3 Pengumpulan Data

Data dalam penelitian ini dikumpulkan melalui dua sumber. Sumber pertama berasal dari *platform* Kaggle, yang menyediakan dataset gambar tanah dengan label klasifikasi yang sudah tersedia. Dataset ini digunakan sebagai data dasar untuk melatih model menggunakan algoritma CNN dengan arsitektur ResNet dengan jumlah data sebanyak 880 gambar. Sumber kedua adalah data lapangan yang dikumpulkan langsung dari wilayah pesisir Teluk Kendari dengan jumlah data sebanyak 110 gambar yang terbagi menjadi 3 Area yang ada di Wilayah tersebut. Lokasi ini dipilih karena memiliki karakteristik tanah yang beragam akibat pengaruh aktivitas pesisir dan tekanan lingkungan. Sampel tanah diambil dari beberapa titik strategis yang dipilih berdasarkan peta wilayah, dengan memperhatikan variasi jenis tanah dan kondisi lingkungan sekitar. Selain pengambilan sampel fisik, citra tanah dari lokasi tersebut juga di dokumentasikan untuk dianalisis lebih lanjut menggunakan teknik pengolahan citra digital.

2.1.4 Image Preprocessing

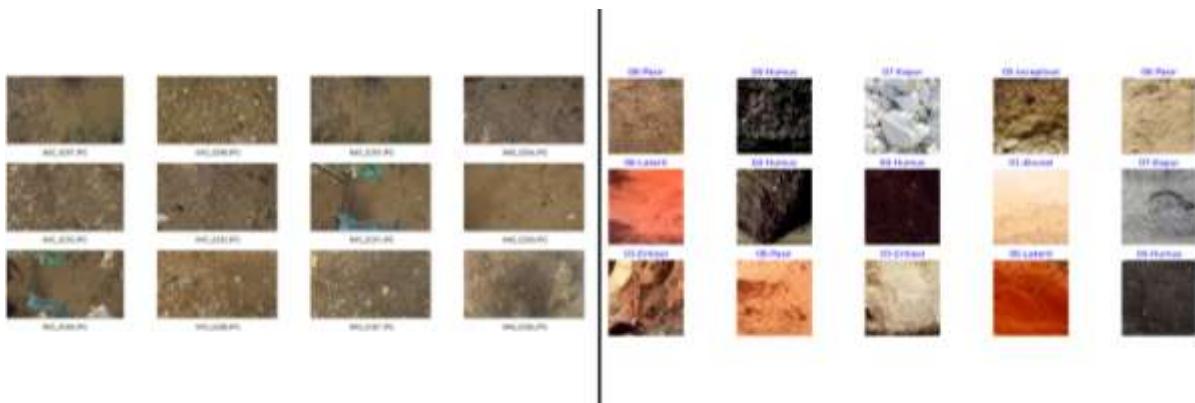
Perbaikan kualitas citra merupakan salah satu proses awal dalam pengolahan citra (*image processing*). Istilah pengolahan citra digital secara umum didefinisikan sebagai pemrosesan citra dua dimensi dengan komputer[13].

2.1.5 Image Sharpening

Metode *Image sharpening* yang telah dikembangkan adalah dengan menggunakan metode klasik, dimana data diproses dengan menggunakan bit yang bernilai 0 atau 1[8]. Penerapan sharpening dalam pengolahan dapat meningkatkan (*enhance*) data citra perolehan sehingga detail objek yang diinginkan tampak cukup jelas. Sharpening dijumpai dalam banyak bidang dan aplikasi. Industri pencitraan, industri percetakan, industri medis, industri otomotif, sampai industri militer menggunakan *sharpening* pada aplikasi-aplikasi yang mensyaratkan detail citra yang tegas[14].

2.1.6 Dataset

Setelah menyelesaikan proses *Image preprocessing* dan *image sharpening*, dataset tersebut nantinya akan dipakai sebagai data baru untuk menguji kemampuan model dalam memprediksi jenis tanah di area Teluk Kendari. Sedangkan Dataset yang diambil di kaggle dibagi menjadi tiga bagian yaitu 80% untuk data latih, 10% untuk data uji, dan 10% untuk data validasi. Pembagian ini dilakukan untuk memastikan distribusi yang merata dan mendukung evaluasi performa model secara akurat. Dataset ini kemudian dilatih menggunakan algoritma CNN dengan arsitektur ResNet untuk membangun model prediksi



Gambar 2. Dataset

2.1.7 Klasifikasi

Klasifikasi adalah pengelompokan data atau objek baru ke dalam kelas atau label berdasarkan atribut-atribut tertentu. Teknik dari klasifikasi adalah dengan melihat variabel dari kelompok data yang sudah ada. Klasifikasi bertujuan untuk memprediksi kelas dari suatu objek yang tidak diketahui sebelumnya[15]. Algoritma klasifikasi yang digunakan akan membantu dalam memahami pola dan distribusi jenis tanah di wilayah pesisir. Tahapan ini melibatkan analisis fitur yang diperoleh dari citra tanah.

2.1.8 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu metode *machine learning* dari pengembangan Multi Layer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena dalamnya tingkat jaringan dan banyak diimplementasikan dalam data citra[16]. CNN merupakan operasi konvolusi yang menggabungkan beberapa lapisan pemrosesan, menggunakan beberapa elemen yang beroperasi secara paralel dan terinspirasi oleh sistem saraf biologis. Pada CNN setiap Jaringan dipresentasikan dalam bentuk 2 dimensi, sehingga metode ini cocok untuk pemrosesan dengan input berupa citra[17]. Dalam penelitian ini kami menggunakan

2.1.9 ResNet152V2

ResNet152V2 merupakan salah satu model arsitektur yang dipakai dalam penelitian ini karena modelnya yang canggih dan efektif dalam pengenalan gambar. ResNet152V2 merupakan salah satu unit dari ResNet (*Residual Network*), ResNet memiliki struktur residual untuk mengurangi degradasi jaringan saraf yang dalam. Struktur unit ini adalah jaringan yang feedforward, kelebihan utama dari unit ini adalah menghasilkan akurasi klasifikasi yang lebih baik tanpa meningkatkan kompleksitas model[18].

3 Hasil dan Pembahasan

Pada penelitian ini kami melakukan beberapa tahapan sampai di tahap pemetaan Wilayah Pesisir

3.1.1 Proses Pengolahan Citra Menggunakan Teknik Image Sharpening

Pada proses ini gambar pada Dataset yang sudah diambil secara manual akan kita lakukan prapemrosesan citra menggunakan Teknik Image Sharpening yang hasilnya dapat dilihat pada gambar 2.



Gambar 3. A). Sebelum Sharpening, B). Sesudah Sharpening

Dapat dilihat perbedaan Sebelum dilakukan sharpening, gambar terlihat lebih buram dengan tekstur yang kurang menonjol, sehingga elemen seperti batang tanaman dan permukaan tanah tampak samar. Setelah proses sharpening, gambar menjadi lebih tajam dan jelas, dengan detail tekstur tanah yang lebih menonjol serta kontras yang lebih baik. Perubahan ini membuat objek dalam gambar terlihat lebih hidup dan mudah dikenali, menunjukkan efektivitas sharpening dalam meningkatkan kualitas visual sebuah gambar. Proses ini dilakukan pada semua gambar yang di ambil secara manual di Wilayah Pesisir Teluk Kendari

3.1.2 Implementasi Model CNN ResNet152V2

Ada beberapa Tahapan yang dilakukan pada Pada pengimplementasian ini diantaranya ialah .

3.1.3 Persiapan Data

Tahapan awal ialah melakukan Persiapan Data terhadap Dataset yang sudah di kumpulkan sebelumnya melalui Kaggle dengan melakukan pengorganisasian file gambar dari direktori yang ada pada , serta pembuatan label untuk setiap gambar berdasarkan folder tempat gambar tersebut berada. Data yang telah diproses kemudian disusun dalam bentuk *DataFrame* dengan dua kolom utama: *filepaths* untuk menyimpan jalur file gambar dan *labels* untuk menyimpan label kategori masing-masing gambar.

3.1.4 Pembagian Dataset

Pada tahap ini, dataset yang telah disiapkan dibagi menjadi tiga bagian utama: *train* (pelatihan), *test* (pengujian), dan *validasi*. Pembagian dilakukan secara proporsional, dengan menggunakan rasio yang telah ditentukan (80% untuk pelatihan, 10% untuk pengujian, dan 10% untuk validasi). Setiap kelas diproses secara terpisah agar distribusi kelas tetap seimbang di masing-masing subset. Hasil akhirnya adalah tiga *DataFrame* yang terpisah untuk masing-masing subset data. data *train* sebanyak 80%, kemudian data testing sebanyak 10% dan untuk data *validation* sebanyak 10% dapat dilihat pada Tabel 1.

Tabel 1. Hasil Pembagian Dataset

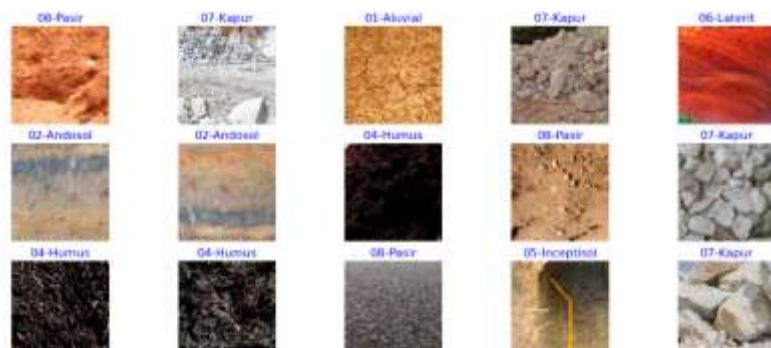
No.	Jenis Tanah	Train	Test	Valid
1.	Aluvial	88	11	11
2.	Andosol	88	11	11
3.	Entisol	88	11	11
4.	Humus	88	11	11
5.	Inceptisol	88	11	11
6.	Laterit	88	11	11
7.	Kapur	88	11	11
8.	Pasir	88	11	11

3.1.5 Data Preprocessing dan Augmentasi

Dalam konteks pelatihan model CNN. Tahap ini, data gambar yang telah dibagi menjadi subset pelatihan, validasi, dan pengujian diproses menggunakan *ImageDataGenerator*. Ini termasuk normalisasi gambar (*rescaling*) agar nilai piksel berada dalam rentang yang sesuai untuk model, serta pengaturan parameter untuk memuat data ke dalam model dalam bentuk batch. Data yang diproses akan digunakan untuk melatih, memvalidasi, dan menguji model *Convolutional Neural Network* (CNN).

3.1.6 Visualisasi Sample Gambar

Pada tahap ini, beberapa sampel gambar dari dataset pelatihan yang telah diproses dan dibagi oleh *ImageDataGenerator* ditampilkan untuk memberikan gambaran tentang data yang digunakan untuk pelatihan model. Fungsi ini menampilkan gambar beserta label kelas yang sesuai dalam bentuk grid, dengan tujuan untuk memeriksa kualitas data dan memastikan bahwa gambar dan label telah terproses dengan benar dapat dilihat pada Gambar 3.



Gambar 4. Visualisasi Sample Gambar

3.1.7 Model Architecture

Pada tahap ini, model *Convolutional Neural Network* (CNN) dibangun menggunakan *ResNet152V2* sebagai model dasar (pre-trained) yang dilanjutkan dengan beberapa lapisan tambahan, seperti *GlobalAveragePooling2D*, *Dropout*, dan *Dense* untuk mengklasifikasikan data berdasarkan jumlah kelas yang telah ditentukan. Model ini kemudian dikompilasi dengan memilih *optimizer*, *loss function*, dan metrik evaluasi yang sesuai. Tahap ini bertujuan untuk merancang arsitektur model yang akan digunakan untuk pelatihan dan evaluasi.

3.1.8 Model Training

Pada tahap ini, model yang telah dibangun dilatih menggunakan data pelatihan (`train_gen`) dan data validasi (`valid_gen`). Model dilatih dengan data pelatihan dan validasi selama beberapa epoch. *EarlyStopping* menghentikan pelatihan jika *loss* validasi tidak membaik dalam 3 epoch, sedangkan *ModelCheckpoint* menyimpan model terbaik dengan `val_loss` terendah.

3.1.9 Evaluasi Model

Pada tahap ini, model yang telah dilatih diuji menggunakan data pengujian (test data) untuk mengukur performa akhir model dalam hal akurasi dan loss. Hasil evaluasi model menunjukkan bahwa model yang telah dilatih mencapai akurasi sekitar **90.91%** pada data pengujian. Ini menunjukkan bahwa model berhasil mengklasifikasikan data uji dengan tingkat ketepatan yang cukup tinggi, yaitu hampir 91%.

Untuk memberikan gambaran yang lebih jelas tentang kinerja model selama pelatihan, grafik di bawah ini menunjukkan *Training Loss* dan *Validation Loss* serta *Training Accuracy* dan *Validation Accuracy* selama proses pelatihan yang dapat dilihat pada gambar di bawah ini.



Gambar 4. Training dan Validation untuk Loss dan Akurasi

Grafik diatas menggambarkan bagaimana model terus belajar dan mengadaptasi bobotnya seiring berjalaninya waktu. Secara umum, terlihat bahwa *training loss* dan *validation loss* mengalami penurunan yang konsisten, sementara *training accuracy* dan *validation accuracy* meningkat, yang menunjukkan bahwa model tidak hanya belajar dengan baik pada data pelatihan tetapi juga menggeneralisasi dengan baik pada data validasi.

Selanjutnya adalah Evaluasi model menggunakan *Confusion Matrix* dapat dilihat pada Gambar 5.



Gambar 5. Confusion Matrix

Berdasarkan *confusion matrix* yang ditampilkan, model menunjukkan distribusi yang baik antara prediksi yang benar dan salah untuk setiap kelas. Mayoritas prediksi berada pada diagonal utama, yang menunjukkan bahwa sebagian besar gambar diklasifikasikan dengan benar sesuai dengan kelas yang dituju. Sebagai contoh, untuk kelas '01-Aluvial', model berhasil mengklasifikasikan 8 gambar dengan benar, namun ada beberapa gambar yang salah diklasifikasikan ke kelas lain (misalnya 1 gambar ke kelas '03-Entisol' dan 2 gambar ke kelas '08-Pasir'). Namun, secara keseluruhan, model menunjukkan akurasi yang baik dengan kesalahan klasifikasi yang relatif kecil.

Selanjutnya adalah hasil dari *Classification Report* dapat dilihat pada Tabel 2.

Tabel 2. Classification Report

No.	Jenis Tanah	Precision	Recall	f1 score	Support
1.	Aluvial	0.80	0.73	0.76	11
2.	Andosol	0.91	0.91	0.91	11
3.	Entisol	0.82	0.82	0.82	11
4.	Humus	1.00	1.00	1.00	11
5.	Inceptisol	0.91	0.91	0.91	11
6.	Laterit	0.83	0.91	0.87	11
7.	Kapur	1.00	1.00	1.00	11
8.	Pasir	1.00	1.00	1.00	11

accuracy	0.91	88
macro avg	0.91	0.91
weighted avg	0.91	0.91

Model menunjukkan kinerja yang sangat baik dengan akurasi 91% secara keseluruhan. *Precision*, *recall*, dan *F1-score* sebagian besar mendekati 1.00, terutama pada kelas Humus dan Pasir, yang menunjukkan prediksi sangat akurat dan kemampuan mendeteksi gambar dengan baik. Beberapa kelas seperti Aluvial dan Entisol memiliki nilai yang sedikit lebih rendah, namun tetap menunjukkan hasil yang cukup memadai. Pengujian ini menghasilkan akurasi, *recall*, *precision* serta *F1-Score/F-Measure*

3.1.10 Prediksi Data Baru

Pada tahap ini, gambar akan diunggah lalu diproses dan diberikan ke model untuk menghasilkan prediksi tentang kelas gambar tersebut. Hasil prediksi yang diberikan adalah label kelas yang diprediksi beserta probabilitas untuk setiap kelas yang mungkin, atau dapat dilihat pada gambar di bawah ini .



Prediksi Kelas :		4.Humus
No.	Jenis Tanah	Prediksi
1.	Aluvial	0.0015
2.	Andosol	0.0039
3.	Entisol	0.0003
4.	Humus	0.6559
5.	Inceptisol	0.0018
6.	Laterit	0.0001
7.	Kapur	0.0003
8.	Pasir	0.3362

Gambar 6. Prediksi Data Baru

Pada gambar diatas merupakan data yang diambil secara manual dan telah melalui pra-pemrosesan citra yang dipakai untuk melakukan Prediksi data baru dan hasilnya diprediksi pada kelas Humus karena probabilitasnya lebih tinggi dibandingkan dengan kelas-kelas lainnya.

3.2 Pemetaan Wilayah Pesisir

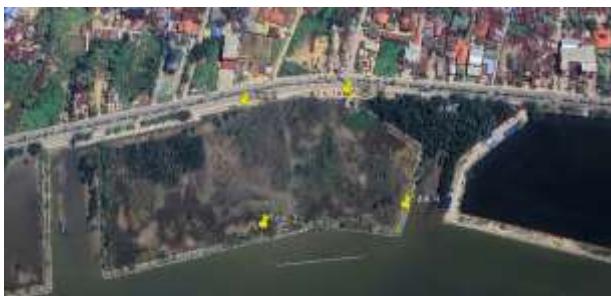
Tahap sebelumnya ialah memprediksi Data gambar yang telah diambil secara manual dan telah melalui pra-pemrosesing citra dan menghasilkan gambaran mengenai jenis tanah pada setiap 3 Area yang telah di Ambil sampelnya di wilayah Teluk Kendari , Tahap Selanjutnya ialah melakukan pemetaan untuk Pemanfaatan wilayah pesisir khususnya di Teluk Kendari dapat disimpulkan:



Prediksi Kelas :		
No.	Jenis Tanah	Prediksi
1.	Aluvial	0.0183
2.	Andosol	0.0529
3.	Entisol	0.0035
4.	Humus	0.5237
5.	Inceptisol	0.0068
6.	Laterit	0.0100
7.	Kapur	0.0125
8.	Pasir	0.3722

Gambar 7. Area 1

Area 1 dengan kandungan 50% humus dan 40% pasir, cocok untuk pertanian ringan seperti padi, nanas, dan kelapa. Tanahnya subur berkat unsur hara tinggi dari humus, tetapi membutuhkan pengkayaan nutrisi dan sistem drainase yang baik untuk mendukung pertumbuhan tanaman optimal.



Prediksi Kelas :		
No.	Jenis Tanah	Prediksi
1.	Aluvial	0.0184
2.	Andosol	0.5740
3.	Entisol	0.0180
4.	Humus	0.2002
5.	Inceptisol	0.0394
6.	Laterit	0.0031
7.	Kapur	0.0123
8.	Pasir	0.1346

Gambar 8. Area 2

Area 2 dengan kandungan 57% tanah andosol, yang memiliki kadar organik dan air tinggi serta kelembaban rendah, menjadikannya subur dan ideal untuk pertanian. Jenis tanaman yang cocok ditanam di tanah ini meliputi sayuran, bunga, teh, kopi, dan hutan pinus, karena kondisi tanah mendukung pertumbuhan tanaman dengan kebutuhan nutrisi tinggi dan struktur tanah yang baik.



Prediksi Kelas :		
No.	Jenis Tanah	Prediksi
1.	Aluvial	0.0546
2.	Andosol	0.2319
3.	Entisol	0.0352
4.	Humus	0.0347
5.	Inceptisol	0.0054
6.	Laterit	0.0554
7.	Kapur	0.0049
8.	Pasir	0.5779

Gambar 9. Area 3

Area 3 dengan kandungan 57% tanah pasir yang memiliki sedikit nutrisi dan kemampuan rendah dalam menahan kelembapan. Namun, jenis tanaman seperti wortel, bit, parsnip, kentang,

bawang merah, bawang putih, sukulen, dan kaktus cocok ditanam di tanah ini karena mampu beradaptasi dengan kondisi tanah yang kering dan kurang subur.

4 Kesimpulan dan Saran

Penelitian mengenai analisis kualitas dan klasifikasi jenis tanah di wilayah pesisir Teluk Kendari menggunakan teknik image sharpening dan CNN ResNet152V2 menunjukkan hasil yang sangat signifikan. Metode yang digunakan berhasil mengklasifikasikan delapan jenis tanah dengan akurasi mencapai 90.91%, membuktikan efektivitas pendekatan kombinasi *image sharpening* dan *deep learning* dalam menganalisis citra tanah. Teknik *image sharpening* terbukti mampu meningkatkan kualitas visual citra, memperjernih detail tekstur, dan mengoptimalkan proses klasifikasi. Model CNN ResNet152V2 menunjukkan performa yang sangat baik, dengan *precision*, *recall*, dan *F1-score* yang tinggi untuk hampir semua kelas tanah. Hal ini menunjukkan bahwa metode yang diusulkan dapat diandalkan dalam mengidentifikasi dan membedakan karakteristik tanah di wilayah pesisir.

Penelitian ini memberikan kontribusi penting dalam pemahaman mendalam tentang kondisi tanah di wilayah pesisir Teluk Kendari, yang dapat digunakan sebagai dasar untuk strategi pengelolaan sumber daya pesisir yang berkelanjutan. Kombinasi teknik image processing dan deep learning membuka peluang baru dalam analisis dan pemetaan sumber daya lahan, khususnya di wilayah yang kompleks seperti pesisir. Untuk penelitian selanjutnya, disarankan untuk memperluas dataset, menguji model pada wilayah pesisir yang berbeda, dan mengeksplorasi teknik *image enhancement* dan arsitektur *deep learning* lainnya guna meningkatkan akurasi dan generalisasi model.

Daftar Pustaka

- [1] F. Jamal, “Peran Pemerintah Daerah dalam Pengelolaan Wilayah Pesisir,” *RECHTSREGEL Jurnal Hukum*, vol. 2, no. 1, pp. 464–473, 2019.
- [2] T. Gopalakrishnan, M. K. Hasan, A. T. M. Sanaul Haque, S. L. Jayasinghe, and L. Kumar, “Sustainability of Coastal Agriculture under Climate Change,” *Sustainability*, vol. 11, no. 7200, pp. 1–24, 2019.
- [3] S. Mazhar, E. Pellegrini, and M. Contin, “Impacts of Salinization Caused by Sea Level Rise on the Biological Processes of Coastal Soils - A Review,” *Frontiers in Environmental Science*, vol. 10, pp. 1–18, 2022.
- [4] H. Bature and M. Mearker, “A Systematic Review on Digital Soil Mapping Approaches in Lowland Areas,” *Jurnal MDPI Land*, vol. 13, no. 379, pp. 1-22, 2024.
- [5] G. Mahajan, B. Das, and S. Morajkar, “Comparison of soil quality indexing methods for salt-affected soils of Indian coastal region,” *Jurnal Springer Nature*, vol. 80, no. 725, 2021.
- [6] I. N. Hidayati, E. Susanti, and W. Utami, “Analisis Pan-Sharpening Untuk Meningkatkan Kualitas Spasial Citra Penginderaan Jauh Dalam Klasifikasi Tata Guna Tanah,” *BHUMI: Jurnal Agraria dan Pertanahan*, vol. 3, no. 1, pp. 122–135, 2017.
- [7] I. N. Hidayati, E. Susanti, and W. Utami, “Analisis Pan-Sharpening Untuk Meningkatkan

Kualitas Spasial Citra Penginderaan Jauh Dalam Klasifikasi Tata Guna Tanah,” *BHUMI: Jurnal Agraria dan Pertanahan*, vol. 3, no. 1, pp. 122–135, 2017.

- [8] M. A. Saefuddin, I. Robiyansyah, A. Fauzi, S. Wardi, and I. H. Ikasari, “Implementasi Metode Sharpening Untuk Memperbaiki Kualitas Citra,” *BIIKMA: Buletin Ilmiah Ilmu Komputer dan Multimedia*, vol. 1, no. 4, pp. 656–659, Desember 2023.
- [9] S. U. Khan, “Noisy Image Quality Improvement Using Combinational Filter Models and Sharpening,” ProQuest Dissertations & Theses, 2023.
- [10] E. Simarmata, “Implementasi Metode High Pass Filtering Dan Metode Contras Streching Dalam Perbaikan Kualitas Citra,” *Journal of Informatics, Electrical and Electronics Engineering*, vol. 2, no. 2, pp. 31–38, Desember 2022.
- [11] M. R. S. Alfarizi, M. Z. Al-farish, M. T. Alfariz, G. Ardiansah, and M. Elgar, “Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning,” *Jurnal Karimah Tauhid*, vol. 2, no. 1, 2023.
- [12] M. Romzi and B. Kurniawan, “Pembelajaran Pemrograman Python Dengan Pendekatan Logika Algoritma,” *JTIM: Jurnal Teknik Informatika Mahakarya*, vol. 3, no. 2, pp. 37–44, 2020.
- [13] E. Simarmata, “Implementasi Metode High Pass Filtering Dan Metode Contras Streching Dalam Perbaikan Kualitas Citra,” *Journal of Informatics, Electrical and Electronics Engineering*, vol. 2, no. 2, pp. 31–38, 2022.
- [14] M. I. Achmad, “Operator Laplacian Melalui Persamaan Finite Difference Untuk Tapis Spasial Sharpening Citra,” *Jurnal Mahandia*, vol. 6, no. 2, pp. 001–085, 2022.
- [15] D. A. Nasution, H. H. Khotimah, and N. Chamidah, “Perbandingan Normalisasi Data Untuk Klasifikasi Wine Menggunakan Algoritma K-NN,” *CESS (Journal of Computer Engineering System and Science)*, vol. 4, no. 1, pp. 78–82, 2019.
- [16] R. W. Wiratama, “Implementasi dan Klasifikasi Jenis-Jenis Batik Menggunakan Algoritma Convolutional Neural Network (CNN) dengan Model Arsitektur ResNet,” Skripsi, 2024.
- [17] S. I. R. Putra, “Rancang Bangun Human Interface Pendekripsi Suhu Serta Masker,” Laporan Tugas Akhir, 2021.
- [18] A. Kurdi, “Aplikasi Deteksi Penyakit pada Daun Bawang Merah Menggunakan Metode Deep Learning Berbasis Website,” Laporan Tugas Akhir, 2024.