



PERBANDINGAN KINERJA *DECISION TREE* DAN *NEURAL NETWORK* DALAM KLASIFIKASI PENUTUP LAHAN BERDASARKAN CITRA SATELIT

Nurul Amalia Amri¹, Annisa Nurfadhilah², Maya Itasari³, Muhdalifah Muhtar⁴, Muhammad Ridhwan⁵

¹²³⁴⁵Politeknik Negeri Ujung Pandang

¹amaliaamri @poliupg.ac.id, ² annisanurfadhilah@poliupg.ac.id, ³mayaitasari @poliupg.ac.id,

⁴muhdalifahmuhtar@poliupg.ac.id, ⁵ muhammad.ridhwan@poliupg.ac.id

ABSTRAK

Perencanaan infrastruktur telekomunikasi seperti menara BTS membutuhkan identifikasi penutup lahan yang akurat, khususnya lahan terbuka yang ideal untuk pembangunan jaringan. Penelitian ini bertujuan membandingkan kinerja algoritma *Decision Tree* dan *Neural Network* dalam klasifikasi penutup lahan berbasis citra satelit. Data yang digunakan terdiri dari 120 sampel citra yang diklasifikasikan ke dalam empat jenis penutup lahan: hutan, lahan terbuka, permukiman, dan industri. Setiap sampel diekstraksi menjadi lima fitur statistik, yaitu rata-rata warna (R, G, B), *entropy*, dan *contrast*. Model dilatih dan diuji menggunakan metode *10-fold cross validation*. Hasil menunjukkan bahwa *Decision Tree* memperoleh akurasi sebesar 83,33%, sementara *Neural Network* memberikan hasil lebih tinggi yaitu 94,44%. Kinerja *Neural Network* juga lebih unggul dalam mengenali kelas lahan terbuka, menjadikannya lebih sesuai untuk mendukung penentuan lokasi infrastruktur telekomunikasi. Penelitian ini menunjukkan bahwa metode *machine learning* dapat digunakan secara efektif dalam klasifikasi penutup lahan berbasis citra untuk mendukung pengambilan keputusan spasial.

Kata kunci: penutup lahan, citra satelit, klasifikasi, *neural network*, *decision tree*

1. PENDAHULUAN

Identifikasi penutup lahan dari citra satelit berperan penting dalam berbagai bidang, termasuk perencanaan tata ruang, pengelolaan lingkungan, dan khususnya infrastruktur telekomunikasi. Informasi yang akurat mengenai klasifikasi wilayah seperti hutan, permukiman, industri, dan lahan terbuka sangat dibutuhkan untuk mendukung analisis pemilihan lokasi pembangunan menara jaringan 5G, di mana lahan terbuka menjadi faktor utama dalam penentuan lokasi yang ideal secara spasial.

Beberapa penelitian terdahulu telah menggunakan metode *machine learning* untuk klasifikasi penutup lahan berbasis citra satelit. Pal dan Mather [10] menunjukkan bahwa algoritma *Decision Tree* efektif dalam klasifikasi penggunaan lahan, sedangkan Zhang et al. [6] menekankan keunggulan *Neural Network* dalam menangani pola data yang kompleks dan non-linear. Studi lain [1], [2], [18] juga mengkaji berbagai metode klasifikasi seperti *Support Vector Machines* dan metode *deep learning* untuk meningkatkan akurasi klasifikasi penutup lahan. Namun, sebagian besar penelitian tersebut belum banyak difokuskan pada aplikasi strategis untuk perencanaan infrastruktur telekomunikasi dengan penekanan pada identifikasi area lahan terbuka.

Dalam konteks ini, penelitian ini bertujuan untuk mengembangkan dan membandingkan model klasifikasi penutup lahan berbasis fitur citra satelit yang mencakup mean komponen warna (R, G, B), *entropy*, dan *contrast* menggunakan algoritma *Decision Tree* dan *Neural Network*. Fokus utama penelitian adalah mengevaluasi kemampuan kedua metode dalam mengidentifikasi lahan terbuka sebagai calon lokasi pembangunan infrastruktur telekomunikasi, terutama menara BTS 5G. Model akan divalidasi menggunakan metode *10-fold cross validation* untuk menghasilkan estimasi kinerja yang handal dan generalisasi yang baik terhadap data yang beragam.



Penelitian ini mengisi kekurangan pada studi sebelumnya yang kurang menitikberatkan pada klasifikasi lahan terbuka yang relevan untuk pembangunan infrastruktur telekomunikasi, dengan fokus pada pemanfaatan fitur-fitur spesifik dari citra satelit resolusi tinggi. Kebaruan penelitian ini terletak pada kombinasi unik pemilihan fitur citra yang tepat serta evaluasi komparatif kinerja dua algoritma machine learning populer dalam konteks aplikasi telekomunikasi.

Lingkup penelitian ini meliputi pengumpulan data citra satelit dari berbagai lokasi representatif di Kabupaten Maros, Sulawesi Selatan. Data citra kemudian diekstraksi menjadi fitur statistik seperti *mean* komponen warna (R, G, B), *entropy*, dan *contrast*. Selanjutnya, dilakukan pembangunan model klasifikasi menggunakan algoritma *Decision Tree* dan *Neural Network*. Model yang dihasilkan dievaluasi secara komprehensif menggunakan metrik akurasi, *precision*, dan *recall* untuk mengukur performa klasifikasi. Hasil penelitian diharapkan memberikan kontribusi praktis dalam mendukung pengambilan keputusan spasial terkait perencanaan jaringan telekomunikasi, serta menjadi dasar pengembangan metode klasifikasi penutup lahan berbasis *machine learning* yang lebih baik dan sesuai dengan kondisi wilayah setempat.

2. METODE PENELITIAN

2.1 Jenis Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimental yang menggunakan metode simulasi dan analisis data citra satelit. Data yang digunakan merupakan data sekunder berupa citra satelit dengan resolusi tinggi yang telah diklasifikasikan ke dalam empat kategori penutup lahan, yaitu hutan, lahan terbuka, permukiman, dan industri.

Metode yang digunakan adalah pengembangan dan evaluasi model klasifikasi menggunakan dua algoritma *machine learning*, yakni *Decision Tree* dan *Neural Network*. Analisis dilakukan dengan melakukan ekstraksi fitur statistik dari citra satelit berupa rata-rata komponen warna (R, G, B), *entropy*, dan *contrast*, kemudian membangun model klasifikasi berdasarkan fitur tersebut.

Pelatihan dan pengujian model dilakukan menggunakan *software* Rapidminer dengan skema validasi silang *10-fold cross validation* untuk menghasilkan estimasi performa yang andal. Selanjutnya, kinerja kedua model dievaluasi dan dibandingkan berdasarkan metrik kuantitatif seperti akurasi, *precision*, dan *recall*.


2.2 Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan dengan mengambil citra satelit dari wilayah Kabupaten Maros, Sulawesi Selatan, yang dipilih karena representatif untuk empat kategori penutup lahan yang menjadi fokus penelitian, yaitu hutan, lahan terbuka, permukiman, dan industri.

Citra satelit diperoleh dari sumber data terbuka yang menyediakan gambar dengan resolusi tinggi, memungkinkan identifikasi yang jelas terhadap karakteristik lahan di daerah tersebut. Pemilihan wilayah ini juga didasarkan pada keberadaan area lahan terbuka yang signifikan sebagai calon lokasi pembangunan infrastruktur telekomunikasi, seperti menara BTS 5G.


Setiap citra satelit kemudian diklasifikasikan secara manual berdasarkan analisis visual dan informasi pendukung untuk memastikan keakuratan label penutup lahan. Data yang sudah berlabel tersebut selanjutnya diproses untuk ekstraksi fitur statistik seperti *mean* nilai warna (R, G, B), *entropy*, dan *contrast* yang menjadi variabel input dalam model klasifikasi.

Proses pengambilan sampel data dilakukan secara representatif dengan total 120 sampel citra yang terbagi merata pada keempat kategori penutup lahan. Pendekatan ini memastikan bahwa model yang dibangun dapat belajar dari variasi karakteristik citra yang ada di area penelitian, sehingga hasil klasifikasi diharapkan dapat memberikan prediksi yang akurat dan aplikatif untuk pengambilan keputusan di Kabupaten Maros.



Gambar 2.1 Data Citra Satelit Hutan: Menunjukkan area yang didominasi oleh vegetasi lebat dengan warna hijau gelap yang homogen, tekstur kasar akibat keberadaan pohon dan pepohonan.

(d)



Gambar 2.2 Data Citra Satelit Lahan Terbuka; Area terbuka dengan sedikit atau tanpa vegetasi, tampak sebagai warna coklat atau krem dengan tekstur halus dan pola yang lebih seragam, cocok untuk pembangunan infrastruktur telekomunikasi.




Gambar 2.3 Data Citra Satelit Pemukiman: Menampilkan kelompok bangunan dan infrastruktur penduduk dengan warna campuran abu-abu dan putih, tekstur yang lebih terfragmentasi dan garis-garis teratur dari jalan dan atap bangunan.



Gambar 2.4 Data Citra Satelit Industri: Area yang biasanya mempunyai bangunan besar dan jalanan luas dengan warna abu-abu gelap sampai hitam, permukaan yang cenderung keras dan pola simetris yang membedakan dari permukiman.

2.3 Tahapan Penelitian

Penelitian ini dilakukan dalam beberapa tahap, yang dimulai dengan pengumpulan data dan berakhir dengan evaluasi model. Berikut adalah tahapan-tahapan yang diikuti dalam penelitian ini sebagaimana ditunjukkan pada Gambar 2.4.



Gambar 2.4 Flowchart Tahapan Penelitian

Tahap pertama dalam penelitian ini adalah pengumpulan data citra satelit yang mencakup area dengan empat jenis penutup lahan: Hutan, Area Terbuka, Permukiman, dan Industri. Setelah citra satelit diperoleh, langkah selanjutnya adalah melakukan ekstraksi fitur. Pada tahap ini fitur untuk klasifikasi yakni *Mean RGB* (R, G, B), *entropy*, dan *contrast* diekstrak dari citra dengan memanfaatkan perangkat lunak Python.

Setelah fitur diekstraksi, data melalui tahap *pre-processing* untuk memastikan kualitas data yang optimal dalam model klasifikasi. Pada tahap ini, dilakukan beberapa proses, termasuk normalisasi data untuk mengubah rentang nilai fitur agar sebanding dan menghindari dominasi fitur dengan rentang nilai lebih besar, serta labeling untuk mengkategorikan dan memberi label data sesuai dengan jenis penutup lahan yang diinginkan.

Data yang digunakan dibagi menjadi data latih (training data) dan data uji (testing data) menggunakan metode *10-fold cross validation* agar model dapat dievaluasi secara menyeluruh dan menghasilkan estimasi kinerja yang handal.

Proses pembuatan model meliputi pelatihan model dengan *Decision Tree* untuk menentukan aturan klasifikasi berdasarkan nilai fitur, serta pelatihan model *Neural Network* untuk menangkap pola non-linear antara fitur citra dan label penutup lahan, di mana kedua model ini dilatih menggunakan dataset pelatihan yang telah dipersiapkan sebelumnya.

Setelah proses pelatihan selesai, model dievaluasi menggunakan data uji. Kinerja setiap model diukur dengan metrik evaluasi seperti akurasi, *precision*, dan *recall* melalui *10-fold cross validation*. Hasil evaluasi dibandingkan untuk menentukan model mana yang memberikan performa terbaik, terutama dalam mengidentifikasi kategori lahan terbuka yang menjadi fokus untuk penentuan lokasi infrastruktur telekomunikasi. Hasil evaluasi model diinterpretasikan untuk menentukan kelebihan dan kekurangan masing-masing algoritma. Analisis ini meliputi pembahasan mengenai distribusi kesalahan melalui *confusion matrix* dan dampaknya terhadap pengambilan keputusan praktis dalam perencanaan infrastruktur telekomunikasi.



2.4 Metode Klasifikasi

Penelitian ini menggunakan dua algoritma *supervised learning* yang berbeda karakteristik, yaitu *Decision Tree* dan *Neural Network*, untuk membandingkan kinerja dalam klasifikasi penutup lahan berbasis citra satelit. Pemilihan dua metode ini didasarkan pada perbedaan pendekatan dan kemampuan dalam mengenali pola data.

2.4.1 Decision Tree

Decision Tree adalah algoritma klasifikasi berbasis pohon yang membagi data secara rekursif ke dalam subset berdasarkan nilai fitur tertentu. Setiap simpul pada pohon merepresentasikan suatu kondisi atau keputusan terhadap salah satu fitur, dan proses berlanjut hingga mencapai simpul daun (*leaf node*) yang menunjukkan kelas prediksi. Dalam membangun pohon keputusan, pemilihan fitur yang optimal untuk pemisahan node dilakukan menggunakan metrik berikut:

- Entropy

Entropy mengukur tingkat ketidakpastian atau *impurity* dalam dataset. Formula entropi untuk dataset S dengan kelas c adalah:

$$E(S) = - \sum_{i=1}^c p_i \log_2 p_i$$

Dimana p_i adalah proporsi sampel dalam kelas ke- i .

- Information Gain

Information Gain mengukur pengurangan entropi setelah dataset dibagi berdasarkan fitur tertentu A dirumuskan sebagai berikut:

$$IG(S, A) = E(S) - \sum_{v \in \text{values}(A)} \frac{|S_v|}{|S|} E(S_v)$$

- Gini Indeks

Gini Indeks merupakan alternatif pengukuran *impurity* digunakan dalam algoritma CART (*Classification and Regression Tree*) dirumuskan sebagai berikut:

$$GI(S) = 1 - \sum_{i=1}^c p_i^2$$

Proses pemilihan fitur untuk pembentukan node dilakukan dengan memilih fitur yang memberikan nilai Information Gain tertinggi atau Gini Index terendah.

2.4.2 Neural Network

Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST) adalah model *machine learning* yang terinspirasi dari cara kerja sistem syaraf biologis manusia dalam memproses informasi. ANN digunakan dalam berbagai aplikasi klasifikasi, regresi, dan deteksi pola, khususnya ketika data memiliki hubungan non-linear yang kompleks.

Struktur dasar ANN terdiri atas tiga jenis lapisan yakni Input Layer : menerima fitur-fitur dari data masukan, Hidden Layer(s) : lapisan tersembunyi yang memproses input melalui bobot dan fungsi aktivasi, Output Layer : menghasilkan prediksi akhir berdasarkan pemrosesan sebelumnya. Proses pelatihan dilakukan dengan algoritma *backpropagation* yang menyesuaikan bobot berdasarkan kesalahan prediksi (*error*) menggunakan metode optimasi seperti *gradient descent*.

Setiap neuron pada *hidden* dan *output* layer menggunakan fungsi aktivasi Sigmoid, yang didefinisikan sebagai berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Output neuron j dihitung sebagai berikut:

$$o_j = \sigma \left(\sum_{i=1}^n w_{ji} x_i + b_j \right)$$

Dimana x_i adalah input ke neuron tersebut (baik dari data fitur atau output neuron sebelumnya)

w_{ji} adalah bobot dari input i ke neuron j

b_j adalah bias neuron j



2.5 Hyperparameter Tuning

Untuk meningkatkan performa model klasifikasi, dilakukan proses *hyperparameter tuning* pada kedua algoritma yang digunakan, yakni *Decision Tree* dan *Neural Network*. Pada *Decision Tree*, *hyperparameter* yang disesuaikan meliputi maksimal *max_depth* yang membatasi tingkat pertumbuhan pohon sehingga dapat mencegah *overfitting*, kriteria pemisahan yang dipilih antara *Information Gain (Entropy)* atau Gini Index untuk menentukan fitur terbaik pada setiap pembagian, serta jumlah minimal sampel yang diperlukan pada node agar dapat dibagi. Penentuan nilai-nilai *hyperparameter* ini dilakukan dengan eksperimen menggunakan data validasi untuk menghasilkan konfigurasi yang memberikan performa klasifikasi terbaik.

Sementara itu, pada *Neural Network* dilakukan *tuning* terhadap beberapa *hyperparameter* penting seperti jumlah neuron pada lapisan tersembunyi (*hidden layer*) yang mempengaruhi kapasitas model dalam menangkap pola *non-linear*, *learning rate* yang menentukan kecepatan pembelajaran bobot pada setiap iterasi *training*, jumlah *epoch* yang mengatur banyaknya siklus pelatihan, dan fungsi sigmoid yang digunakan. Selain itu, metode optimasi seperti *gradient descent* juga disesuaikan agar proses pelatihan dapat mencapai konvergensi yang optimal. Proses *tuning hyperparameter* *Neural Network* dilakukan melalui pendekatan *trial and error* dengan evaluasi menggunakan metrik *akurasi*, *precision*, dan *recall* pada data validasi.


Dengan melakukan *hyperparameter tuning* yang sistematis, diharapkan model dapat menghasilkan performa klasifikasi yang maksimal, mengurangi kesalahan prediksi, serta menghasilkan kestabilan dan generalisasi yang lebih baik terhadap data baru.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Ekstraksi Fitur

Dari 120 data citra satelit dilakukan ekstraksi fitur menggunakan Python. Dilakukan ekstraksi fitur dari 120 sampel citra satelit yang mewakili empat kategori penutup lahan, yaitu hutan, lahan terbuka, permukiman, dan industri di Kabupaten Maros, Sulawesi Selatan. Ekstraksi fitur bertujuan untuk mendapatkan karakteristik statistik penting dari citra yang dapat digunakan sebagai input dalam proses klasifikasi.


Fitur yang diambil dari tiap citra meliputi nilai rata-rata komponen warna merah (*mean R*), hijau (*mean G*), biru (*mean B*), *entropy*, dan *contrast*. Distribusi nilai fitur-fitur tersebut untuk keempat kelas ditampilkan pada grafik histogram masing-masing fitur pada Gambar 3.1 (a) sampai (e).




(a) Histogram Ekstraksi Fitur Mean R




(b) Histogram Ekstraksi Fitur Mean G



(b) Histogram Ekstraksi Fitur Mean B



(d) Histogram Ekstraksi Fitur Entropy



(e) Histogram Ekstraksi Fitur *Contrast*
Gambar 3.1 Hasil Ekstraksi Fitur Citra

Dari histogram terlihat bahwa masing-masing kelas menunjukkan pola distribusi fitur yang berbeda, misalnya kelas hutan memiliki nilai *mean G* yang lebih tinggi dengan *entropy* yang relatif besar akibat variasi tekstur pohon, sementara kelas lahan terbuka memiliki nilai *mean R* dan *mean B* yang cenderung lebih rendah dan *contrast* yang lebih homogen.


Analisis visual dari distribusi fitur mengindikasikan bahwa fitur yang dipilih mampu memberikan pemisahan awal antar kelas, sehingga layak digunakan sebagai variabel input dalam pembangunan model klasifikasi *Decision Tree* dan *Neural Network*.

3.2 Hasil Pemodelan

Tahap ini menyajikan hasil pembangunan model klasifikasi penutup lahan menggunakan algoritma *Decision Tree* dan *Neural Network* berdasarkan fitur citra satelit yang telah diekstraksi, yaitu *mean R*, *mean G*, *mean B*, *entropy*, dan *contrast*.

3.2.1 Decision Tree

Visualisasi *Decision Tree* yang dihasilkan ditunjukkan pada Gambar 3.2. Node akar (root) dari pohon memisahkan data berdasarkan nilai *mean_r* dengan threshold 143.580, yang secara awal memisahkan area terbuka dari jenis penutup lahan lainnya.



Gambar 3.2 Hasil Pemodelan *Decision Tree*


Selanjutnya, cabang-cabang pohon melakukan pemisahan bertingkat dengan menggunakan nilai *threshold* dari fitur-fitur lain seperti *mean G*, *entropy*, dan *contrast* untuk mengidentifikasi kelas hutan, permukiman, dan industri. Proses ini membentuk aturan klasifikasi yang mudah dipahami dan diinterpretasikan.

Dari visualisasi, dapat dilihat bahwa fitur warna (*mean R*, *G*, *B*) dan fitur tekstur (*entropy*, *contrast*) berperan penting dalam membagi data secara efektif, meskipun model cenderung mengandalkan fitur-fitur dominan pada setiap level pemisahan.

3.2.2 Neural Network

Pemodelan klasifikasi penutup lahan menggunakan algoritma Neural Network pada Gambar 3.3 menunjukkan arsitektur jaringan yang terdiri dari lima neuron input (*mean_r*, *mean_g*, *mean_b*, *entropy*, dan *contrast*), enam neuron *hidden layer*, dan empat neuron pada layer output untuk empat kelas target: hutan, lahan terbuka, permukiman, dan industri.

Setiap neuron dalam hidden layer menggunakan fungsi aktivasi sigmoid, dengan bobot dan bias yang bervariasi terhadap fitur masukan. Bobot-bobot yang diperoleh pada hidden layer menunjukkan pengaruh yang berbeda dari masing-masing fitur terhadap aktivasi neuron. Dari hasil pemodelan didapatkan Pada Node 6, nilai *mean_r*, *mean_g*, dan *mean_b* memiliki kontribusi positif yang tinggi, sedangkan *contrast* memiliki kontribusi negatif. Pada layer output Node 1 dan Node 2 memiliki bobot positif yang cukup tinggi (2.684 dan 1.614) menunjukkan bahwa kedua node tersebut sangat relevan dalam mendeteksi ciri khas dari kawasan hutan.



Gambar 3.3 Hasil Pemodelan *Neural Network*

3.3 Hasil Evaluasi Model

Evaluasi model dilakukan untuk mengukur performansi klasifikasi penutup lahan yang dibangun menggunakan algoritma *Decision Tree* dan *Neural Network*. Proses pelatihan dan pengujian model dilakukan dengan teknik *10-fold cross validation* di mana data dibagi menjadi 10 bagian yang secara bergantian digunakan sebagai data uji dan data latih guna memastikan generalisasi model terhadap data yang bervariasi. Data dibagi dalam rasio 80:20, yaitu 80% digunakan sebagai data latih dan 20% sebagai data uji pada setiap *fold*.

Untuk mengukur kualitas klasifikasi yang dihasilkan oleh model, digunakan beberapa metrik evaluasi penting. Pertama adalah akurasi, yaitu persentase data uji yang berhasil diklasifikasikan dengan benar dari keseluruhan data, yang mencerminkan seberapa tepat model dalam melakukan prediksi secara umum. Selanjutnya, *precision* atau presisi mengukur kemampuan model dalam mengidentifikasi sampel-sampel yang benar-benar termasuk dalam kelas positif, sehingga menggambarkan ketepatan prediksi positif yang dilakukan. *Recall* atau sensitivitas menunjukkan kemampuan model dalam menemukan seluruh sampel positif dari kelas tertentu, yang berarti seberapa baik model tidak melewatkan data yang seharusnya termasuk dalam kelas tersebut. Selain itu, *confusion matrix* digunakan untuk memvisualisasikan distribusi hasil prediksi terhadap kelas sebenarnya, memberikan gambaran rinci mengenai jenis kesalahan klasifikasi yang terjadi, serta memudahkan analisis performa model secara menyeluruh.

Hasil evaluasi *confusion matrix* dari model *Decision Tree* dapat dilihat pada Tabel 3.1 dan model Neural Network pada Tabel 3.2. Model *Decision Tree* mampu mengklasifikasikan sebagian besar sampel dengan benar, namun terlihat sejumlah kesalahan terutama dalam mengenali kelas lahan terbuka dan hutan. Kesalahan ini tercermin dari nilai *prediction* yang masih di bawah Neural Network. Model *Neural Network* menunjukkan distribusi prediksi yang lebih merata dan cenderung lebih minim kesalahan.

Tabel 3.1 *Confusion Matrix Model Decision Tree*

	true hutan	true industri	true terbuka	true permukiman
pred. hutan	7	1	1	0
pred. industri	2	8	1	0
pred. terbuka	0	0	7	0
pred. permukiman	0	1	0	8

Tabel 3.2 *Confusion Matrix Model Neural Network*

	true hutan	true industri	true terbuka	true permukiman
pred. hutan	9	1	1	0
pred. industri	0	9	0	0
pred. terbuka	0	0	8	0
pred. permukiman	0	0	0	8

Tabel 3.3 Hasil Evaluasi Model

Performansi (%)	Model	
	Decision Tree	Neural Network
Akurasi	83,33	94,44
Precision (Hutan)	77,78	81,82
Precision (Industri)	72,73	100
Precision (Lahan Terbuka)	100	100
Precision (Pemukiman)	88,89	100
Recall (Hutan)	77,78	100
Recall (Industri)	80	90
Recall (Lahan Terbuka)	77,78	88,89
Recall (Pemukiman)	100	100

Dari hasil evaluasi performa pada Tabel 3.3, hasil menunjukkan bahwa model Neural Network memberikan akurasi tertinggi sebesar 94,44% dibandingkan model *Decision Tree* dengan nilai akurasi 83,22%. Neural Network menunjukkan keunggulan pada hampir semua metrik *precision* dan *recall*, dengan performa sempurna (100%) pada kelas lahan terbuka dan permukiman, yang merupakan kelas prioritas dalam penelitian ini. *Decision Tree* juga menunjukkan performa yang baik, terutama pada kelas lahan terbuka yang memiliki *precision* 100%, namun secara keseluruhan kurang stabil dibandingkan *Neural Network*.

Dari hasil pemodelan dapat dilihat bahwa Neural Network lebih unggul dibanding *Decision Tree* dalam hal akurasi keseluruhan dan klasifikasi kelas area terbuka. *Decision Tree* meskipun lebih mudah diinterpretasikan, cenderung bergantung pada *threshold* dan pemilihan fitur dominan, sehingga kurang fleksibel ketika menghadapi data dengan variasi tinggi. Sedangkan Neural Network dalam mengatasi pola non-linear kompleks pada data citra menyebabkan tingkat kesalahan yang lebih sedikit dan klasifikasi yang lebih akurat.

Hasil evaluasi ini menunjukkan bahwa metode Neural Network lebih cocok digunakan untuk mendukung pengambilan keputusan spasial dalam perencanaan pembangunan infrastruktur telekomunikasi, terutama dalam mengidentifikasi area lahan terbuka secara akurat. Namun, *Decision Tree* tetap dapat menjadi pilihan yang efektif jika dibutuhkan model yang lebih sederhana dan mudah dipahami.



4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Neural Network menunjukkan performa yang lebih unggul dibandingkan *Decision Tree* dengan akurasi keseluruhan sebesar 94,44% dibandingkan 83,33%. *Neural Network* mampu menangkap pola non-linear kompleks dari fitur citra (*mean RGB*, *entropy*, *contrast*), sehingga memberikan klasifikasi yang lebih akurat terutama untuk kelas lahan terbuka yang menjadi fokus utama dalam perencanaan infrastruktur telekomunikasi. *Decision Tree* tetap menunjukkan performa yang baik, dan memiliki kelebihan pada aspek kemudahan interpretasi model. Namun, keputusannya cenderung dipengaruhi oleh fitur dominan dan pembagian data yang sederhana, sehingga kurang fleksibel dalam mengatasi kasus yang membutuhkan generalisasi lebih kuat.

Fitur yang diekstraksi dari citra satelit berupa statistik warna dan tekstur terbukti cukup representatif untuk mendukung proses klasifikasi penutup lahan dalam konteks aplikasi pembangunan menara telekomunikasi. Hasil ini mendukung penggunaan *machine learning* berbasis citra sebagai solusi untuk mengotomatisasi identifikasi penutup lahan, khususnya lahan terbuka yang menjadi faktor penting dalam penentuan lokasi infrastruktur telekomunikasi seperti BTS atau menara 5G. Model *Neural Network* dapat direkomendasikan untuk digunakan pada sistem klasifikasi berbasis citra yang memerlukan akurasi tinggi dan klasifikasi yang stabil.

4.2 Saran

Untuk meningkatkan kualitas model klasifikasi pada penelitian selanjutnya, disarankan untuk memperluas jumlah dan variasi data citra yang digunakan, baik dari segi lokasi geografis maupun kondisi penutup lahannya, agar model memiliki kemampuan generalisasi yang lebih baik. Selain itu, fitur yang digunakan dalam penelitian ini masih terbatas pada nilai rata-rata warna (R, G, B), *entropy*, dan *contrast*. Penelitian lanjutan diharapkan dapat mengeksplorasi fitur yang lebih kompleks seperti indeks vegetasi (NDVI), tekstur GLCM lengkap, ataupun fitur spektral dari citra *multispektral* guna meningkatkan kemampuan deteksi terhadap jenis penutup lahan secara lebih akurat. Optimasi Model dan Hyperparameter Tuning kedua metode (seperti kedalaman pohon pada *Decision Tree* atau *learning rate*, jumlah neuron pada *Neural Network*) agar performa model dapat dimaksimalkan secara optimal.





DAFTAR PUSTAKA

- [1] J. R. Jensen, *Introductory Digital Image Processing: A Remote Sensing Perspective*, 4th ed. Boston: Pearson, 2015.
- [2] L. Breiman, J. Friedman, R. Olshen, and C. Stone, *Classification and Regression Trees*. Belmont, CA: Wadsworth, 1984.
- [3] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ: Pearson Education, 2009.
- [4] T. M. Mitchell, *Machine Learning*. New York: McGraw-Hill, 1997.
- [5] C. Bishop, *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
- [6] G. Mountrakis, J. Im, and C. Ogole, "Support vector machines in remote sensing: A review," *ISPRS J. Photogramm. Remote Sens.*, vol. 66, no. 3, pp. 247–259, May 2011.
- [7] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015.
- [8] B. Lakshmi and A. Nagesh, "Land cover classification using decision tree algorithm," *Proc. IEEE Int. Conf. Comput. Commun. Inf. (ICCCI)*, Coimbatore, India, Jan. 2015, pp. 1–6.
- [9] A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, "A survey of the recent architectures of deep convolutional neural networks," *Artificial Intelligence Review*, vol. 53, no. 8, pp. 5455–5516, Oct. 2020.
- [10] M. Pal and P. M. Mather, "An assessment of the effectiveness of decision tree methods for land cover classification," *Remote Sens. Environ.*, vol. 86, no. 4, pp. 554–565, Aug. 2003.
- [11] M. A. Wulder et al., "Satellite data for monitoring land use and land cover change," *Remote Sens. Environ.*, vol. 122, pp. 66–74, Jul. 2012.
- [12] P. Ghamisi, J. A. Benediktsson, and J. R. Sveinsson, "Automatic spectral–spatial classification framework based on attribute profiles and supervised feature extraction," *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 2, pp. 577–590, Feb. 2014.
- [13] Y. Yang et al., "A remote sensing image classification method based on decision tree and neural network," *Proc. 3rd Int. Conf. Image Process. Commun. Comput. (IPCC)*, Shanghai, China, Dec. 2016, pp. 1–5.
- [14] A. S. M. Sajjad et al., "Machine learning-based land cover classification using spectral indices," *Sustainability*, vol. 12, no. 16, pp. 1–19, Aug. 2020.
- [15] J. Zhu and M. Liu, "Comparison of decision tree and neural network classifiers for land use classification," *Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS)*, Vancouver, Canada, Jul. 2011, pp. 1250–1253.
- [16] N. A. Amri, D. Kurnia Imanda, E. Y. Hamid and A. Munir, "Image Quality Assessment on Microwave Tomography Based on Filtered-Back-Projection," *2020 14th International Conference on Telecommunication Systems, Services, and Applications (TSSA)*, Bandung, Indonesia, 2020, pp. 1–4, doi: 10.1109/TSSA51342.2020.9310790.
- [17] M. Ridwan Effendi, F. Anis Sekar Ningrum, N. Amalia Amri, B. Abubakar, S. Risnanto and A. Munir, "Interpolation Effect on FBP-Based Image Reconstruction of Measured L-Band Microwave Tomography," *2021 IEEE International Conference on Communication, Networks and Satellite (COMNETSAT)*, Purwokerto, Indonesia, 2021, pp. 290–293, doi: 10.1109/COMNETSAT53002.2021.9530773.
- [18] N. A. Amri, F. Oktafiani, E. Y. Hamid and A. Munir, "Comparison of Image Reconstruction on Microwave Tomography Using Filtered Back Projection," *2020 27th International Conference on Telecommunications (ICT)*, Bali, Indonesia, 2020, pp. 1–4, doi: 10.1109/ICT49546.2020.9239487.

