

Ekstraksi Tutupan Lahan Kota Pesisir dari *Band Visible* dan Perhitungan Indeks Spektral dari Citra Sentinel-2 dengan Arsitektur U-NET (Studi Kasus: Kota Pekalongan dan Kota Cirebon)

Land Cover Extraction in Coastal Cities Using Visible Bands and Sentinel-2 Imagery's Spectral Indices with U-Net Architecture (Case Study: Pekalongan City and Cirebon City)

Almaas Syifaa Ardanti^{1*}, Catur Aries Rokhmana²

¹Program Studi Magister Teknik Geomatika, Fakultas Teknik, Universitas Gadjah Mada, Jalan Grafika No.2, Kampus UGM, Yogyakarta, 55281.

²Departemen Teknik Geodesi, Fakultas Teknik, Universitas Gadjah Mada, Jalan Grafika No.2, Kampus UGM, Yogyakarta, 55281.

*Corresponding Author: almaassyifaardanti@mail.ugm.ac.id

Article Info:

Received: 03 – 03 - 2026

Accepted: 15 – 05 - 2026

Published: 25 – 07 - 2026

Kata kunci: Ekstraksi Tutupan Lahan, Kota Pesisir, Sentinel-2, Indeks Spektral, U-Net.

Keywords: Land Cover Extraction, Coastal City, Sentinel-2, Spectral Indices, U-Net.

Abstrak: Wilayah pesisir merupakan zona peralihan darat dan laut yang mengalami perubahan pemanfaatan lahan sehingga memerlukan data tutupan lahan yang mutakhir untuk mendukung pemutakhiran peta dasar. Kota pesisir di Pantai Utara Jawa seperti Kota Pekalongan dan Kota Cirebon menunjukkan perubahan penggunaan lahan dalam beberapa tahun terakhir. Ekstraksi tutupan lahan dilakukan menggunakan citra Sentinel-2 dengan memanfaatkan kombinasi *band visible* (Red, Green, Blue), Near Infrared (NIR), serta perhitungan indeks spektral berupa Normalized Difference Vegetation Index (NDVI), Urban Index (UI), dan Modified Normalized Difference Water Index (MNDWI) yang akan menghasilkan *single band* untuk masing-masing indeks. *Band visible* dan *band* hasil perhitungan indeks diolah menggunakan arsitektur U-Net untuk ekstraksi tutupan lahan. Data dianalisis pada Mei dan Juli 2025 dengan perbedaan variasi curah hujan. Model dikembangkan melalui skema *encoder* dan *decoder* dengan *skip connection*, *hybrid loss*, dan data latih berbasis *tile* 64×64 piksel yang mewakili seluruh kelas tutupan lahan. Penerapan model di Kota Pekalongan menghasilkan rata-rata F1-score 0,95404 dan IoU 0,91228, sedangkan *fine tuning* di Kota Cirebon dengan penambahan kelas hutan bakau menghasilkan rata-rata F1-score 0,93835 dan IoU 0,88470. Perbedaan waktu akuisisi menunjukkan variasi respons spektral terutama pada kelas vegetasi, sementara kelas perairan dan terbangun relatif stabil.

Abstract: Coastal areas represent transitional zones between land and sea that experience land use changes, requiring up-to-date land cover data to support base map updates. Coastal cities along the northern coast of Java such as Kota Pekalongan and Kota Cirebon have shown land use changes in recent years. Land cover extraction was conducted using Sentinel-2 imagery by utilizing visible bands (Red, Green, Blue), Near Infrared (NIR), and spectral indices including the Normalized Difference Vegetation Index (NDVI), Urban Index (UI), and Modified Normalized Difference Water Index (MNDWI) based on a U-Net architecture. Data were analyzed for May and July 2025 under different rainfall conditions. The model was developed using an encoder–decoder scheme with skip connections, a hybrid loss function, and 64×64 pixel tile-based training data representing all land cover classes. Model implementation in Kota Pekalongan produced an average F1-score of 0.95404 and an IoU of 0.91228, while fine-tuning in Kota Cirebon with the addition of a mangrove class resulted in an average F1-score of 0.93835 and an IoU of 0.88470. Differences in acquisition periods indicate spectral response variation primarily in vegetation classes, whereas water and built-up classes remained relatively stable.

How to Cite:

Ardianti, A. S., Rokhmana, C. A. (2026). Ekstraksi Tutupan Lahan Kota Pesisir dari *Band Visible* dan Perhitungan Indeks Spektral dari Citra Sentinel-2 dengan Arsitektur U-NET (Studi Kasus: Kota Pekalongan dan Kota Cirebon). *Jurnal Ilmiah Geomatika*, 6(1), 77-89. <https://doi.org/10.31315/imagi.v6i1.16607>.

1. PENDAHULUAN

Wilayah pesisir menurut UU Nomor 1 Tahun 2014 merupakan daerah peralihan yang dipengaruhi oleh perubahan di darat dan laut. Sebagai kawasan peralihan, kondisi morfologi dari wilayah pesisir sebagian besar adalah dataran rendah. Kota dengan morfologi dataran rendah cenderung rentan terhadap genangan banjir. Permasalahan ini disebabkan oleh curah hujan yang tinggi dan ketersediaan vegetasi yang berkurang sebagai daerah resapan. Fenomena ini terjadi di kota-kota yang terletak di pantai utara pulau Jawa, beberapa diantaranya adalah Kota Cirebon dan Kota Pekalongan. Kedua kota ini memiliki tingkat kerawanan bencana banjir yang tinggi.

Pemerintah Kota setempat membutuhkan pemantauan ketersediaan vegetasi dan peningkatan lahan vegetasi untuk langkah awal mitigasi bencana banjir. Dokumen Rencana Pembangunan Jangka Menengah Daerah (RPJMD) tahun 2025-2029 menjelaskan bahwa peningkatan lahan vegetasi sulit untuk dilakukan karena lahan yang terbatas. Di sisi lain, pemantauan ketersediaan lahan vegetasi saat ini masih dilakukan dengan cara survei ke lapangan dan interpretasi langsung dari citra satelit. Diperlukan informasi spasial yang dapat memberikan informasi tutupan lahan secara relevan dalam waktu yang cepat.

Metode pembuatan peta tutupan lahan pada penelitian terdahulu di Kota Cirebon dan Kota Pekalongan menggunakan digitasi manual, *machine learning*, dan *Object Based Image Analysis* (OBIA). Akan tetapi pemanfaatan metode tersebut memiliki beberapa kendala. Menurut Kristal, A., (2022), pembuatan peta dasar dengan metode digitasi manual memiliki kelemahan yaitu rentan terjadi kesalahan interpretasi dari operator dalam mengidentifikasi unsur peta dasar dalam citra. Selain digitasi manual, metode ekstraksi informasi citra satelit berbasis *machine learning* telah banyak digunakan. Kualitas klasifikasi digital dapat menurun apabila model dilatih pada citra wilayah tertentu dan kemudian diterapkan di wilayah lain. Metode OBIA, dapat digunakan untuk pemetaan tutupan lahan dengan batas objek yang terlihat lebih jelas. Akan tetapi metode ini memiliki kekurangan yaitu waktu pemrosesan yang cukup lama dan masih terjadi kesalahan dan melakukan klasifikasi tutupan lahan (Dzaikra, 2022).

Algoritma *deep learning* signifikan digunakan dalam analisis penginderaan jauh. Algoritma ini telah digunakan dalam berbagai aplikasi, termasuk didalamnya ekstraksi informasi citra satelit. Didukung dengan peningkatan daya komputasi dan ketersediaan dataset, penerapan algoritma ini menjadi metode yang banyak digunakan. Keuntungan dari penerapan *deep learning* yaitu menghasilkan akurasi yang lebih tinggi dibanding *machine learning* serta memahami pola yang kompleks dan linear (Solórzano et al., 2021).

Algoritma *deep learning* memiliki kelemahan belum mampu menangkap seluruh representasi penting dari data masukan yang hanya berbasis *band* satelit *visible* atau sinar tampak. Proses ekstraksi informasi tutupan lahan yang dilakukan pada *band visible* akan bergantung pada *digital number* (DN). Hal ini dikarenakan setiap objek di permukaan bumi memiliki sifat reflektansi yang berbeda pada berbagai rentang spektrum elektromagnetik, sehingga DN untuk setiap lanskap akan berbeda dalam citra penginderaan jauh (Gibson, P., Power, 2000). Efek atmosfer juga dapat mempengaruhi DN dari objek yang ada di permukaan bumi yang menyebabkan distorsi (Zhu, 2023). Disamping itu adanya pengaruh perubahan suhu, curah hujan, dan tingkat pertumbuhan vegetasi dapat mempengaruhi karakteristik spektral penutup lahan di sepanjang waktu (Sinha et al., 2012).

Wilayah pesisir lebih rentan mengalami kesalahan atmosfer akibat kombinasi polusi di pusat perkotaan, kondisi topografi, dan pengaruh air dari laut. Kota Cirebon dan Kota Pekalongan mengalami peningkatan konsentrasi gas rumah kaca yang berpengaruh terhadap kondisi atmosfer. Aktivitas manusia di pusat perkotaan, khususnya pembakaran bahan bakar menjadi salah satu penyusun terbentuknya gas rumah kaca. Hal ini dapat memerangkap radiasi energi matahari, menyimpan energi panas, dan meningkatkan temperatur global. Interaksi polusi, kondisi topografi, dan angin laut mempengaruhi dinamika lapisan atmosfer di wilayah pesisir. Perbedaan sifat panas di daratan dan lautan juga mempengaruhi stabilitas atmosfer, sehingga memperbesar potensi kesalahan atmosfer pada citra satelit (Yang et al., 2018).

Salah satu pendekatan untuk mengatasi kesalahan atmosfer pada citra satelit adalah penambahan informasi indeks spektral. Hal ini dikarenakan indeks spektral mampu menunjukkan

kelimpahan relatif dari fitur-fitur yang diamati. Indeks spektral dapat dihitung dari *band spektral* yang tersedia untuk menghasilkan fitur tambahan yang dapat digunakan oleh *deep learning* dalam meningkatkan kemampuan klasifikasi analisis citra (Yaloveha & Hlavcheva, 2021).

Penelitian ekstraksi tutupan lahan berbasis *deep learning* di wilayah pesisir Indonesia masih terbatas pada penggunaan fitur spektral yang parsial serta belum banyak menggunakan metode kombinasi antara *band visible* dan *single band* hasil perhitungan indeks spektral dalam satu kerangka arsitektur U-Net. Selain itu, pengujian konsistensi model pada lanskap pesisir yang heterogen dengan variasi waktu akuisisi dan variasi tingkat curah hujan juga masih jarang dilakukan, sehingga efektivitas pendekatan tersebut dalam meningkatkan ketelitian proses ekstraksi tutupan lahan belum sepenuhnya terverifikasi. Tingkat curah hujan diperlukan sebagai data analisis tambahan karena dalam proses perhitungan indeks spektral, tingkat ketersediaan air di permukaan dapat mempengaruhi hasilnya.

2. METODE PENELITIAN

2.1 Lokasi Penelitian



Gambar 1. Peta Batas Administrasi; (a). Kota Pekalongan dan (b). Kota Cirebon

Lokasi penelitian meliputi Kota Cirebon dan Kota Pekalongan yang merepresentasi kota pesisir di Pulau Jawa dengan keragaman variasi lanskap penutup lahan. Kota Cirebon terletak pada 108°33 Bujur Timur dan 6°41 Lintang Selatan. Kota Pekalongan terletak antara 6 ° 50' 42" - 60 55' 44" Lintang Selatan dan 109 ° 37' 55" - 109 ° 42' 19" Bujur Timur.

2.2 Alat & Bahan

Peralatan yang digunakan dalam penelitian terdiri dari:

1. *Google Earth Engine*;
2. QGIS Versi 3.40;
3. *Google Colaboratory (Google Colab)*.

Data yang digunakan dalam penelitian terdiri dari:

1. Citra Sentinel 2 di lokasi penelitian (Kota Pekalongan dan Kota Cirebon) tahun 2025 dengan waktu akuisisi bulan Mei dan bulan Juli yang diakses melalui *Google Earth Engine*;
2. Citra Satelit Google Earth;
3. Batas administrasi Kota Cirebon yang diperoleh dari Peta RBI Skala 1:25.000;
4. Batas administrasi Kota Pekalongan yang diperoleh dari Peta RBI Skala 1:25.000

2.3 Metode

2.3.1 Indeks Spektral

Dalam penelitian, indeks yang digunakan adalah *Urban Index (UI)*, *Normalized Difference Vegetation Index (NDVI)*, dan *Modified Normalized Difference Water Index (MNDWI)*. Persamaan untuk indeks spektral dapat dilihat sebagai berikut (Kawamura et al., 1996; Tucker, 1979; Xu, 2006):

$$UI = \frac{(SWIR2-NIR)}{(SWIR2+NIR)} + 1 \dots\dots\dots(1)$$

$$NDVI = \frac{(NIR-Red)}{(NIR+Red)} \dots\dots\dots(2)$$

$$MNDWI = \frac{(Green-SWIR1)}{(Green+SWIR1)} \dots\dots\dots(3)$$

2.3.2 U-Net

Algoritma U-net pertama kali dikembangkan oleh Ronneberger et al., (2015). Metode ini merupakan bagian dari Convolutional Neural Network (CNN). CNN merupakan arsitektur jaringan saraf dalam (*deep neural network*) yang secara khusus dirancang untuk mengolah data yang memiliki struktur grid dua dimensi, seperti citra satelit. U-Net merupakan arsitektur *encoder-decoder* yang terdiri atas *contracting path* dan *expanding path* simetris. Bagian *encoder* melakukan *down-sampling* sambil meningkatkan jumlah saluran *feature map*, sedangkan bagian *decoder* melakukan *up-sampling* untuk memulihkan resolusi keluaran. Keunggulan utama U-Net terletak pada *skip-connections* yang menggabungkan *feature map* berlevel rendah dari *encoder* dengan hasil *up-sampling* pada *decoder*, sehingga mempertahankan detail spasial penting untuk segmentasi citra presisi tinggi.

2.3.3 Uji Akurasi Model

Evaluasi akurasi model klasifikasi dilakukan untuk menilai kemampuan model dalam mengidentifikasi kelas secara kuantitatif menggunakan *confusion matrix*. Matriks ini menggambarkan hubungan antara prediksi dan kondisi sebenarnya melalui empat komponen, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). TP dan TN menunjukkan prediksi yang benar pada kelas positif dan negatif, sedangkan FP dan FN menunjukkan kesalahan klasifikasi pada masing-masing kelas (Davis & States, 2006).

Perhitungan evaluasi akurasi hasil yang digunakan dalam penelitian adalah *precision*, *recall*, F1-Score, dan *Intersection over Union* (IoU). *Precision* adalah rasio antara jumlah prediksi positif yang benar terhadap total prediksi positif. Secara matematis, *precision* dirumuskan sebagai berikut (Li et al., 2021):

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(4)$$

Recall atau sensitivitas mengukur kemampuan model untuk menangkap seluruh data positif aktual. Dengan kata lain, *recall* menunjukkan seberapa banyak kasus aktual yang benar-benar terdeteksi oleh model. Rumus *recall* adalah sebagai berikut (Zhao et al., 2023):

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(5)$$

F1-Score menggabungkan *precision* dan *recall* dalam satu nilai yang menyeimbangkan keduanya (Pablo et al., 2025). Rumus F1-Score adalah sebagai berikut:

$$F1 - Score = 2 \times \frac{precision \times recall}{precision+recall} \dots\dots\dots(6)$$


Intersection over Union (IoU) atau dikenal juga dengan Jaccard Index digunakan untuk membandingkan hasil prediksi model dengan data acuan berdasarkan tingkat tumpang tindih area keduanya. Secara matematis, IoU didefinisikan sebagai rasio antara luas irisan (*intersection*) dan luas gabungan (*union*) dari dua himpunan (Rezatofighi et al., 2019). IoU dirumuskan sebagai berikut:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \dots\dots\dots(7)$$

A merupakan wilayah hasil prediksi dan B merupakan wilayah data acuan.

2.4 Diagram Konseptual

Gambar 1. Menjelaskan secara singkat tahapan penelitian yang dilakukan.



Gambar 1. Diagram Konseptual Penelitian

3. HASIL DAN PEMBAHASAN

3.1 Hasil dan Analisis Indeks Normalisasi di Kota Pekalongan

Dalam pembahasan akan dianalisis hasil perhitungan indeks spektral, yaitu NDVI, UI, dan MNDWI, di Kota Pekalongan dengan mempertimbangkan perbedaan curah hujan di waktu penelitian, yaitu bulan Mei 2025 dan bulan Juli 2025.

Tabel 1. Statistik Hasil Indeks Spektral Setiap Bulan di Kota Pekalongan

Statistik Indeks Spektral Bulan Mei				Statistik Indeks Spektral Bulan Juli			
Indeks Spektral	Nilai Minimum	Nilai Maksimum	Nilai Rata-rata	Indeks Spektral	Nilai Minimum	Nilai Maksimum	Nilai Rata-rata
NDVI	-0,21647	0,58755	0,13300	NDVI	-0,15881	0,52310	0,15849
UI	-0,58226	0,70579	-0,1097	UI	-0,54410	0,51334	-0,14028
MNDWI	-0,74458	0,36745	-0,1106	MNDWI	-0,55556	0,36314	-0,09897

Berdasarkan **Tabel 1**, peningkatan rata-rata NDVI pada Mei sebesar 0,133 menjadi Juli sebesar 0,158 berkaitan dengan meningkatnya respons vegetasi akibat ketersediaan air yang lebih tinggi. Rata-rata UI pada Mei sebesar -0,110 menjadi Juli sebesar -0,140. Rata-rata MNDWI pada Mei sebesar -0,111 menjadi Juli sebesar -0,099 mencerminkan peningkatan keberadaan air permukaan pada periode Juli. Apabila ditinjau dari tingkat curah hujan, pada bulan Mei, Kota Pekalongan memiliki tingkat curah hujan sebesar 116 mm dan pada bulan Juli sebesar 123 mm (Tjiptanto et al., 2025a, 2025b). Perbedaan nilai curah hujan ini menunjukkan adanya peningkatan ketersediaan air pada bulan Juli yang selaras dengan peningkatan nilai NDVI dan MNDWI pada periode waktu yang sama. Penelitian ini sejalan oleh penelitian oleh Roswintiarti et al. (2025), yang mengatakan apabila curah hujan bernilai positif maka dapat menyebabkan kerapatan dan kehijauan tanaman meningkat, yang tercermin dari NDVI yang lebih tinggi.

3.2 Hasil dan Analisis Indeks Normalisasi di Kota Cirebon

Dalam pembahasan akan dianalisis indeks normalisasi, yaitu NDVI, UI, dan MNDWI, di Kota Cirebon dengan mempertimbangkan perbedaan curah hujan di waktu penelitian, yaitu bulan Mei 2025 dan bulan Juli 2025.


Tabel 2. Statistik Indeks Setiap Bulan di Kota Cirebon

Statistik Indeks Bulan Mei				Statistik Indeks Bulan Juli			
Indeks	Nilai Minimum	Nilai Maksimum	Nilai Rata-rata	Indeks	Nilai Minimum	Nilai Maksimum	Nilai Rata-rata
NDVI	-0,14134	0,57589	0,19310	NDVI	-0,15304	0,57325	0,19176
UI	-0,58276	0,56704	-0,12322	UI	-0,55710	0,50075	-0,11708
MNDWI	-0,65109	0,30963	-0,18584	MNDWI	-0,52843	0,32625	-0,17949

Berdasarkan **Tabel 2**, rata-rata NDVI pada Mei sebesar 0,193 dan Juli sebesar 0,192. Rata-rata UI pada Mei sebesar -0,123 menjadi Juli sebesar -0,117. Rata-rata MNDWI pada Mei sebesar -0,186 menjadi Juli sebesar -0,179 dengan nilai maksimum lebih tinggi pada Juli sebesar 0,326. Apabila ditinjau dari tingkat curah hujan berdasarkan data dari Badan Pusat Statistik Kota Cirebon, Kota Cirebon pada bulan Mei memiliki curah hujan sebesar 205 mm, sedangkan pada bulan Juli menurun menjadi 89 mm. Perbedaan nilai curah hujan tersebut menunjukkan ketersediaan air yang lebih tinggi pada bulan Mei dibandingkan bulan Juli. Kondisi ini selaras dengan karakteristik indeks spektral yang menunjukkan respons vegetasi dan air permukaan yang lebih kuat pada periode dengan curah hujan yang lebih tinggi. Curah hujan yang relatif tinggi berkontribusi terhadap peningkatan kepadatan dan kehijauan vegetasi, yang tercermin dari nilai NDVI yang lebih besar, serta mendukung keberadaan air permukaan yang teridentifikasi melalui indeks MNDWI. Hasil analisis ini menunjukkan keterkaitan antara variasi curah hujan dan perubahan respons spektral vegetasi, yang sejalan dengan temuan penelitian terdahulu.

3.3 Hasil dan Analisis Pembangunan Model *Deep Learning*


Pembangunan model deep learning berbasis arsitektur U-Net pada penelitian ini memerlukan data pelatihan dan data validasi yang representatif terhadap variasi tutupan lahannya yang tersebar pada *Region of Interest* (ROI) masing-masing wilayah penelitian. Pembagian data sampel menjadi data pelatihan dan data validasi dilakukan menggunakan metode *stratified sampling* berdasar kelas dominasi pada setiap *tile*. Dari ROI tersebut dilakukan pemotongan citra menjadi *tile* berukuran 64 × 64 piksel.



Gambar 2. Data Sampel Kota Pekalongan

Arsitektur U-Net terdiri atas *encoder* dan *decoder*. *Encoder* mengekstraksi fitur spasial melalui *convolution* dan *max-pooling* dengan peningkatan filter 64 hingga 1024, sedangkan *decoder* merekonstruksi resolusi citra menggunakan *transposed convolution* dan *skip connection* yang menggabungkan fitur pada tingkat resolusi yang sama. (Pablo et al., 2025). *Loss function* yang digunakan pada penelitian ini didasarkan pada konsep *hybrid loss* yang menggabungkan fungsi *loss* berbasis cross-entropy dan Dice-based *loss* sebagaimana diformulasikan dalam *Unified Focal* (UF) *loss* oleh Yeung et al., (2022). Secara umum, *hybrid loss* dirumuskan sebagai kombinasi linear antara komponen *loss* klasifikasi dan *loss* tumpang tindih area untuk mengatasi ketidakseimbangan kelas data pelatihan.

Pelatihan model dilakukan setelah membangun arsitektur dan *loss function* yang digunakan. Model awal menggunakan *epoch* 200 yang lalu diterapkan *early stopping* supaya tidak terjadi *overfitting*. Seperti pada **Gambar 3**, kurva *training* dan *validation* yang dihasilkan dari proses pelatihan mengalami konvergensi yang stabil hingga *epoch* ke 187. Nilai *training loss* menurun secara konsisten sepanjang *epoch*, sementara *validation loss* juga menunjukkan tren penurunan yang sejalan meskipun cenderung melandai pada fase akhir pelatihan.



Gambar 3. Grafik Pelatihan Model

Evaluasi model *deep learning* dilakukan menggunakan matriks konfusi untuk menilai keandalan klasifikasi terhadap data masking hasil digitasi. Hasilnya menunjukkan performa klasifikasi yang tinggi pada seluruh kelas tutupan lahan.


Tabel 3. Evaluasi Model *Deep Learning*

Kelas	Precision	Recall	F1-Score	IoU
Perairan	0,98361	0,96057	0,97195	0,94543
Permukiman	0,95865	0,969	0,9638	0,93012
Lahan Tidak Terbangun	0,95751	0,9314	0,94428	0,89443
Sawah	0,99168	0,95718	0,97413	0,94956
Perkebunan	0,90911	0,95599	0,93196	0,87258
Semak	0,92078	0,96455	0,94216	0,89064
Rata-Rata	0,95808	0,95888	0,95404	0,91228

Tabel 3 menunjukkan model memiliki performa yang konsisten pada seluruh kelas. Nilai rata-rata *precision*, *recall*, dan F1-score diatas 0,95 menunjukkan model dapat melakukan ekstraksi tutupan lahan secara akurat.


3.4 Hasil dan Analisis *Fine Tuning* Model Deep Learning

Fine Tuning dilakukan untuk mengadaptasi model awal menjadi model dengan penambahan kelas hutan bakau. Sama seperti dalam pembangunan model *deep learning*, dalam proses *fine tuning* digunakan data pelatihan dan data validasi berukuran 64 x 64 piksel.



Gambar 4. Data Sampel Kota Cirebon

Secara arsitektural, *fine-tuning* tetap menggunakan arsitektur U-Net yang sama dengan model awal. Perubahan hanya dilakukan pada *layer* keluaran, di mana jumlah *filter* disesuaikan dengan penambahan kelas Hutan Bakau. Pelatihan model dilakukan setelah membangun arsitektur dan *loss function* yang digunakan. Model awal menggunakan *epoch* 250 yang lalu diterapkan *early stopping* supaya tidak terjadi *overfitting*. Seperti pada **Gambar 5**, kurva *training* dan *validation* yang dihasilkan dari proses pelatihan mengalami konvergensi yang stabil hingga *epoch* ke 106. Nilai *training loss* menurun secara konsisten sepanjang *epoch*, sementara *validation loss* juga menunjukkan tren penurunan yang sejalan meskipun cenderung melandai pada fase akhir pelatihan.



Gambar 5. Grafik Pelatihan Fine-Tuning Model


Setelah dilakukan proses evaluasi model, diperoleh hasil masing-masing kelas tutupan lahan memiliki tingkat akurasi yang tinggi. Performa model yang ditampilkan pada **Tabel 4** menunjukkan masing-masing kelas tutupan lahan memiliki tingkat akurasi yang tinggi.

Tabel 4. Hasil Evaluasi *Fine-Tuning Model*

Kelas Tutupan Lahan	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>IoU</i>
Perairan	0,93457	0,93457	0,93457	0,87717
Permukiman	0,97810	0,95917	0,96854	0,93900
Lahan Tidak Terbangun	0,89831	0,95562	0,92608	0,86233
Sawah	0,93208	0,99161	0,96093	0,92479
Perkebunan	0,87960	0,92160	0,90011	0,81836
Semak	0,92802	0,92603	0,92702	0,86397
Hutan Bakau	0,92989	0,97353	0,95121	0,90695
Rata-rata	0,92579	0,95173	0,93835	0,88470

3.5 Hasil dan Analisis Ekstraksi Tutupan Lahan Kota Pekalongan

Pemanfaatan citra Sentinel-2 yang dikombinasikan dengan indeks spektral NDVI, UI, dan MNDWI mampu merepresentasikan karakteristik tutupan lahan secara efektif. Kombinasi ketiga indeks tersebut dengan *Band Red*, *Green*, *Blue*, dan NIR menyediakan keragaman informasi spektral, di mana NDVI merepresentasikan kerapatan vegetasi, UI mencerminkan karakteristik area terbangun, dan MNDWI mengidentifikasi keberadaan badan air.




Gambar 6. Peta Tutupan Lahan Kota Pekalongan

Perbedaan hasil dari proses ekstraksi disebabkan karena adanya perbedaan curah hujan antara bulan Mei dan Juli yang memengaruhi respons spektral vegetasi dan berdampak pada ketelitian klasifikasi tutupan lahan. Curah hujan yang sedikit lebih tinggi pada bulan Juli meningkatkan respons vegetasi pada kelas Sawah, sehingga nilai NDVI kelas ini menjadi semakin mendekati kelas Perkebunan dan Semak. Kedekatan nilai indeks vegetasi antar kelas tersebut menyebabkan tumpang tindih spektral yang memperbesar potensi pertukaran kelas pada hasil klasifikasi.

Peningkatan kehijauan vegetasi yang relatif merata menyebabkan NDVI Sawah, Perkebunan, dan Semak berada pada rentang yang saling berdekatan, sementara nilai UI dan MNDWI pada ketiga kelas tersebut sama-sama rendah atau negatif. Kondisi ini menyulitkan pemisahan kelas vegetasi berbasis piksel

karena informasi spektral yang digunakan tidak lagi bersifat kontras. Secara lebih lanjut, perbedaan nilai respon spektral di setiap kelas tersaji pada **Gambar 7**.




Gambar 7. Grafik Perbandingan Rata-Rata Indeks Spektral Kota Pekalongan

Konteks Kota Pekalongan sebagai kota pesisir turut memengaruhi stabilitas klasifikasi kelas non-vegetasi. Keberadaan perairan laut dan jaringan sungai di bagian utara wilayah studi menghasilkan respons MNDWI yang konsisten dan kontras terhadap kelas lain, sehingga kelas Perairan tetap teridentifikasi dengan baik pada kedua waktu akuisisi. Karakteristik pesisir ini memperkuat perbedaan spektral antara kelas perairan dan daratan, meskipun terjadi perubahan respons vegetasi akibat variasi curah hujan.

Kelas terbangun menunjukkan ketahanan terhadap perubahan respons vegetasi dibandingkan kelas vegetasi. Karakter spektral kawasan Permukiman yang didominasi permukaan terbangun relatif tidak dipengaruhi oleh peningkatan respons vegetasi, sehingga batas kelas Permukiman tetap terjaga meskipun terjadi perubahan nilai NDVI pada kelas vegetasi di sekitarnya. Hal ini menunjukkan bahwa variasi curah hujan lebih berdampak pada kelas vegetasi dibandingkan kelas terbangun di wilayah kota pesisir.

Hasil uji akurasi menunjukkan bahwa ekstraksi tutupan lahan di Kota Pekalongan memiliki tingkat ketelitian yang tinggi pada kedua waktu akuisisi. Pada bulan Mei, nilai *overall accuracy* mencapai 88,50% dengan standar deviasi 0,013, yang menunjukkan sebagian besar titik sampel berhasil diklasifikasikan sesuai data referensi. Sementara itu, pada bulan Juli nilai *overall accuracy* sebesar 85,70% dengan standar deviasi 0,023, yang juga mengindikasikan bahwa mayoritas titik sampel telah terklasifikasi dengan baik meskipun tingkat akurasinya sedikit lebih rendah dibandingkan bulan Mei.


3.6 Hasil dan Analisis Ekstraksi Tutupan Lahan Kota Cirebon



Gambar 8. Peta Tutupan Lahan Kota Cirebon

Sama seperti di Kota Pekalongan, hasil ekstraksi tutupan lahan di Kota Cirebon menunjukkan perbedaan respon spektral antara bulan Mei dan Juli yang dipengaruhi variasi curah hujan. Pada bulan Mei dengan curah hujan relatif lebih tinggi, NDVI cenderung lebih tinggi dan MNDWI pada beberapa kelas menunjukkan pengaruh kandungan air yang lebih besar. Pada bulan Juli saat curah hujan menurun, respons spektral antar kelas menjadi lebih kontras pada kelas tertentu, tetapi pada kelas vegetasi justru tampak lebih homogen.

Berdasar **Gambar 9**, kelas vegetasi menunjukkan perubahan respons spektral paling jelas. Pada bulan Mei, Sawah, Perkebunan, dan Semak menunjukkan nilai NDVI yang relatif tinggi dengan perbedaan antar kelas yang masih dapat dibedakan. Memasuki Juli, penurunan ketersediaan air menyebabkan penurunan atau penyempitan rentang nilai NDVI sehingga karakter spektral antar vegetasi menjadi lebih mirip.



Gambar 9. Grafik Perbandingan Rata-Rata Indeks Spektral Kota Cirebon

Kelas Lahan Tidak Terbangun menunjukkan perubahan respons yang dipengaruhi kelembapan permukaan. Pada Mei, kandungan air tanah yang lebih tinggi menyebabkan nilai indeks air relatif meningkat. Pada Juli, permukaan yang lebih kering menurunkan respons kelembapan dan mempertegas perbedaan dengan kelas Perairan, tetapi pada beberapa lokasi justru mendekati respons spektral vegetasi kering.

Kelas Perairan dan Hutan Bakau di bagian utara yang berasosiasi dengan Laut Jawa menunjukkan respons spektral yang khas dan relatif stabil. Perairan konsisten dengan nilai MNDWI tinggi dan NDVI rendah pada kedua bulan. Hutan Bakau tetap menunjukkan kombinasi nilai vegetasi tinggi dan kedekatan dengan indeks air, meskipun pada Juli terjadi sedikit penurunan kelembapan akibat berkurangnya curah hujan.

Kelas Permukiman mempertahankan respons spektral yang relatif konstan antara Mei dan Juli. Permukaan terbangun menghasilkan nilai NDVI rendah dan indeks air yang kecil, sehingga variasi musiman curah hujan tidak banyak mengubah karakter spektralnya. Temuan ini mengindikasikan bahwa variasi curah hujan di wilayah kota pesisir Cirebon lebih berpengaruh terhadap ketelitian klasifikasi kelas vegetasi dibandingkan kelas non-vegetasi.

Hasil uji akurasi menunjukkan bahwa ekstraksi tutupan lahan di Kota Cirebon memiliki performa yang baik pada kedua waktu akuisisi. Pada bulan Mei, nilai *overall accuracy* mencapai 91,2% dengan standar deviasi 0,016, yang menandakan sebagian besar titik sampel berhasil diklasifikasikan sesuai data referensi serta menunjukkan konsistensi model dalam memetakan tutupan lahan kota pesisir. Sementara itu, pada bulan Juli nilai *overall accuracy* sebesar 86,5% dengan standar deviasi 0,032, yang juga mengindikasikan mayoritas titik sampel terklasifikasi dengan baik.

4. KESIMPULAN

Model *deep learning* berbasis arsitektur U-Net yang dibangun dari kombinasi citra *visible* (Red, Green, Blue), NIR, serta indeks spektral NDVI, UI, dan MNDWI terbukti mampu mengekstraksi informasi tutupan lahan secara efektif pada Kota Pekalongan dan Kota Cirebon. Kombinasi beberapa *band* dan indeks spectral dapat memperkaya representasi fitur spasial. Proses pelatihan menunjukkan konvergensi stabil tanpa *overfitting* signifikan, sedangkan pendekatan *fine-tuning* memungkinkan adaptasi model terhadap penambahan kelas hutan bakau tanpa mengubah struktur utama jaringan. Dengan strategi *hybrid loss* dan pembagian data terstratifikasi, model menghasilkan ekstraksi yang konsisten pada dua periode akuisisi berbeda.

Analisis akurasi menunjukkan performa klasifikasi yang tinggi di seluruh lokasi penelitian, meskipun terdapat variasi antar waktu akuisisi. Di Kota Pekalongan, akurasi sedikit menurun pada bulan Juli seiring meningkatnya kemiripan respons spektral vegetasi akibat perubahan curah hujan, sedangkan di Kota Cirebon performa tetap tinggi dengan penurunan moderat pada periode kering. Nilai *precision*, *recall*, *F1-score*, dan IoU pada sebagian besar kelas berada pada kategori sangat baik, dengan kelas perairan dan permukiman paling stabil, sementara kelas vegetasi menunjukkan variasi lebih besar.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) dan Badan Pusat Statistik (BPS) Kota Cirebon atas penyediaan data curah hujan, serta kepada Badan Informasi Geospasial (BIG) atas penyediaan data geospasial yang digunakan dalam penelitian ini.

Daftar Pustaka

- Davis, J. J. O. N., & States, U. (2006). The relationship between Precision-Recall and ROC curves The Relationship Between Precision-Recall and ROC Curves. *Proceedings of the 23rd International Conference on Machine Learning, ICML '06*(June 2006), 23–240. <https://doi.org/10.1145/1143844.1143874>
- Dzaikra, Y. J. (2022). Analisis Ketersediaan Ruang Terbuka Hijau Melalui Metode Object Based Image Analysis (Studi Kasus: Kota Administrasi Jakarta Timur). *Jurnal Ilmiah Geomatika*, 2(1), 1–15. <https://doi.org/10.31315/imagi.v2i1.7847>
- Gibson, P., Power, C. H. (2000). *Introductory Remote Sensing Principles and Concepts (1st ed.)* (S. E. Press (ed.)). <https://doi.org/https://doi.org/10.4324/9780203714522>
- Kawamura, M., Jayamanna, S., & Tsujiko, Y. (1996). Relation Between Social and Environmental Conditions in Colombo, Sri Lanka and The Urban Index Estimated by Satellite Remote Sensing Data. *International Archives of the Photogrammetry and Remote Sensing*, XXXI(Part B7), 321–326.
- Kristal, A., H. (2022). Analisis Keandalan Ekstraksi Garis Tepi Bangunan dari Data Foto Udara Menggunakan Pendekatan Deep Learning Berbasis Mask R-CNN. *Geoid*, 17(2), 273–285.
- Pablo, J., Ibarra, G., Javier, F., & De, C. (2025). Evaluation of the Effectiveness of the UNet Model with Different Backbones in the Semantic Segmentation of Tomato Leaves and Fruits. *Horticulturae*, 11(514), 1–19. <https://doi.org/https://doi.org/10.3390/horticulturae11050514>
- Rezatofighi, H., Tsoi, N., Gwak, J., Reid, I., & Savarese, S. (2019). Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 658–666.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*.
- Roswintarti, O., Indriasari, N., Halim, F., Inggit, R., Sari, L., & Hengki, K. (2025). On the Use of Remote Sensing Data for Monitoring NDVI Anomalies and Correlations with Rainfall Anomalies in West Java

- Province , Indonesia : Addressing Sustainable Development Goal 2. *Remote Sensing in Earth Systems Sciences*, 8(2), 815–833. <https://doi.org/10.1007/s41976-025-00222-7>
- Sinha, P., Kumar, L., & Reid, N. (2012). Seasonal Variation in Land-Cover Classification Accuracy in a Diverse Region. *Photogrammetric Engineering & Remote Sensing*, 78(3), 271–280.
- Solórzano, J. V, Mas, J. F., Gao, Y., & Gallardo-Cruz, J. A. (2021). Land Use Land Cover Classification with U-Net : Advantages of Combining Sentinel-1 and Sentinel-2 Imagery. *MDPI*, 13(3600), 1–23. <https://doi.org/doi.org/10.3390/rs13183600> Academic
- Tjiptanto, G., Sulistiyowati, Endah, S., & Umaroh. (2025a). BULETIN INFORMASI IKLIM EDISI AGUSTUS 2025. *Badan Meteorologi, Klimatologi, Dan Geofisika (BMKG)*, 17–21.
- Tjiptanto, G., Sulistiyowati, Endah, S., & Umaroh. (2025b). BULETIN INFORMASI IKLIM EDISI JUNI 2025. *Badan Meteorologi, Klimatologi, Dan Geofisika (BMKG)*, 17–22.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/https://doi.org/10.1016/0034-4257(79)90013-0)
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Yaloveha, V., & Hlavcheva, D. (2021). Spectral Indexes Evaluation for Satellite Images Classification using CNN. *JIOS*, 45(2), 435–449.
- Yang, Z., Calderer, A., He, S., Sotiropoulos, F., Doyle, J. D., Flagg, D. D., MacMahan, J., Wang, Q., Haus, B. K., Graber, H. C., & Shen, L. (2018). Numerical study on the effect of air-sea-land interaction on the atmospheric boundary layer in coastal area. *Atmosphere*, 9(2), 1–12. <https://doi.org/10.3390/atmos9020051>
- Yeung, M., Sala, E., Schonlieb, C.-B., & Rundo, L. (2022). Computerized Medical Imaging and Graphics Unified Focal loss : Generalising Dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*, 95(November 2021), 1–13. <https://doi.org/10.1016/j.compmedimag.2021.102026>
- Zhu, W. (2023). Effects of Atmospheric Correction on Remote Sensing Statistical Inference in an Aquatic Environment. *Remote Sensing*, 15(1907), 1–9.