

SEGMENTASI LAHAN PERTANIAN UBI CILEMBU DARI FOTO UDARA MENGGUNAKAN U-NET

(Studi kasus: Desa Cilembu, Kecamatan Pamulihan, Kabupaten Sumedang, Jawa Barat)

Silviawati¹, Levana Apriani, S.T., M.T², Prima Rizky Mirelva, S.T., M.T.³

¹Mahasiswa Teknik Geodesi Universitas Winaya Mukti, Bandung

²Dosen Pembimbing Satu Teknik Geodesi Universitas Winaya Mukti, Bandung

³Dosen Pembimbing Dua Teknik Geodesi Universitas Winaya Mukti, Bandung

Abstrak

Ubi cilembu merupakan komoditas unggulan di Desa Cilembu, Sumedang yang memerlukan pemantauan lahan secara akurat untuk mendukung produktivitas yang berkelanjutan. Penelitian ini bertujuan mengembangkan metode segmentasi otomatis lahan pertanian ubi cilembu menggunakan model *deep learning* U-Net dengan memanfaatkan citra *orthophoto* hasil foto udara drone.

Model U-Net dikembangkan dengan arsitektur *encoder-decoder* simetris lengkap dengan skip connections dan dioptimalkan menggunakan fungsi *loss binary cross-entropy* serta *optimizer adam*. Dataset yang digunakan terdiri dari citra resolusi tinggi dengan ukuran piksel 4,27 cm, dilakukan *preprocessing* berupa konversi 8-bit dan pemecahan citra menjadi patch berukuran 256×256 piksel, serta digitasi manual sebagai *ground truth*.

Hasil segmentasi model menunjukkan performa tinggi dengan nilai *dice coefficient* 87,75%, *Intersection over Union* (IoU) 78,17%, *Precision* 86,12%, dan *Recall* 89,43%. Hasil visual menunjukkan kemampuan model dalam mengidentifikasi batas lahan dengan bentuk kompleks meskipun adanya tantangan pencahayaan tidak merata. Implementasi model pada citra full scene mengindikasikan kemampuan skalabilitas untuk pemetaan lahan pertanian luas secara tepat dan efisien.

Kata Kunci: *Orthophoto, deep learning, U-Net, ubi cilembu, Segmentasi Citra.*

Abstract

Cilembu sweet potatoes are a leading commodity in Cilembu Village, Sumedang, which requires accurate land monitoring to support sustainable productivity. This study aims to develop an automatic segmentation method for Cilembu sweet potato farmland using the U-Net deep learning model, utilizing orthophoto images obtained from drone aerial photography.

The U-Net model was developed with a fully symmetric encoder-decoder architecture, including skip connections, and optimized using the binary cross-entropy loss function and the Adam optimizer. The dataset used consists of high-resolution images with a pixel size of 4.27 cm, preprocessed through 8-bit conversion and image segmentation into 256×256 pixel patches, along with manual digitization as ground truth.

The model's segmentation results showed high performance with a dice coefficient of 87.75%, Intersection over Union (IoU) of 78.17%, Precision of 86.12%, and Recall of 89.43%. The visual results show the model's ability to identify complex land boundaries despite the challenge of uneven lighting. The implementation of the model on full-scene images indicates its scalability for accurate and efficient mapping of large agricultural areas.

Keywords: *Orthophoto, deep learning, U-Net, cilembu yam, Image Segmentation*

PENDAHULUAN

Ubi cilembu (*Ipomoea batatas* 'cilembu') merupakan komoditas pertanian bernilai ekonomi tinggi yang menjadi unggulan Kabupaten Sumedang, Jawa Barat. Sebagai produk spesifik lokasi, kualitas dan produktivitas ubi ini sangat bergantung pada pengelolaan lahan yang presisi. Namun, metode pemantauan lahan konvensional masih mengandalkan survei lapangan secara manual yang memakan waktu, subjektif, dan kurang efisien untuk cakupan wilayah yang luas. Di sisi lain, perkembangan teknologi *Unmanned Aerial Vehicle* (UAV) dan *deep learning* menawarkan solusi inovatif melalui pemetaan berbasis citra resolusi tinggi dan analisis otomatis.

Berdasarkan analisis mendalam terhadap penelitian-penelitian terdahulu, peneliti mengidentifikasi bahwa pendekatan *deep learning*, khususnya arsitektur U-Net, menawarkan solusi potensial untuk mengatasi permasalahan tersebut. Arsitektur ini dipilih karena kemampuannya yang unggul dalam mempertahankan informasi spasial melalui mekanisme *skip connection*, adaptabilitasnya terhadap objek dengan bentuk tidak beraturan, serta performanya yang terbukti efektif bahkan dengan jumlah data terbatas. Solusi yang dikembangkan dalam penelitian ini memadukan tiga komponen utama: data citra UAV beresolusi sangat tinggi untuk menangkap detail spasial, arsitektur U-Net termodifikasi dengan *encoder-decoder* simetris, serta *pipeline preprocessing* khusus yang dirancang untuk karakteristik lahan pertanian tropis.

Penelitian ini memiliki tiga tujuan utama. Pertama, mengembangkan model segmentasi lahan ubi cilembu berbasis U-Net. Kedua, merancang protokol *preprocessing* yang optimal khusus untuk citra UAV pertanian. Ketiga, mengevaluasi implementasi model pada skala operasional melalui uji coba pemrosesan *full-scene* untuk memvalidasi kesiapan teknologi ini untuk aplikasi praktis.


METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen berbasis *deep learning*. Dalam penelitian ini melibatkan perlakuan terhadap data berupa pelatihan dan pengujian model U-Net menggunakan dataset Foto udara yang telah dianotasi. Dengan metode ini, peneliti bisa mengkondisikan proses pelatihan model U-Net secara terstruktur menggunakan dataset foto udara pertanian, sehingga model dapat belajar mengenali pola dan fitur yang membedakan area lahan pertanian dari objek lain secara efektif.

Selanjutnya, pengujian model dilakukan menggunakan data uji untuk mengevaluasi sejauh mana model dapat menggeneralisasi hasil segmentasi pada citra baru yang belum pernah dilihat sebelumnya, sehingga validitas kinerja model dapat diukur secara objektif.

Kerangka Pemikiran

Kerangka pemikiran yang dilaksanakan dalam kegiatan ini dapat dilihat dari diagram di bawah ini:



Gambar 1 Diagram Alir Penelitian

Tahap Pengolahan Data

Proses pengolahan data dalam penelitian ini dilakukan melalui beberapa tahapan kritis untuk memastikan kualitas input yang optimal bagi model U-Net. Tahap pertama melibatkan konversi citra *orthophoto* hasil pengolahan fotogrametri dari format asli 16-bit ke 8-bit, yang bertujuan untuk mengurangi kompleksitas komputasi sekaligus mempertahankan informasi visual esensial. Konversi ini dilakukan dengan normalisasi nilai piksel ke rentang 0-255, disertai pemeriksaan distribusi histogram untuk memastikan tidak terjadi kehilangan informasi penting.

Tahap berikutnya adalah pembuatan data *ground truth* melalui proses digitasi manual menggunakan perangkat lunak ArcMap. Digitasi dilakukan dengan cermat oleh peneliti untuk memahami karakteristik lahan ubi cilembu, menghasilkan *masking* biner (1 untuk lahan ubi cilembu, 0 untuk area lainnya) dengan akurasi sub-piksel.

Untuk mempersiapkan data *training*, dilakukan proses *patching* dengan membagi citra *orthophoto* dan *masking* ke dalam segmen-segmen berukuran 256×256 piksel. Ukuran ini dipilih setelah melalui serangkaian uji coba untuk menyeimbangkan antara kebutuhan detail spasial dan efisiensi komputasi. Setiap *patch* melalui pemeriksaan kualitas ketat yang meliputi: keselarasan sistem koordinat antara citra dan *masking*, konsistensi nilai piksel, serta distribusi area lahan dalam setiap *patch*. Dataset akhir kemudian dibagi menjadi data *training* (80%) dan validasi (20%) dengan memperhatikan distribusi spasial yang merata di seluruh area penelitian.

Kemudian membuat data generator yang memuat *patch* pada *batch* (sesi pelatihan) selama pelatihan untuk menghemat memori. Membuat *generator instance* untuk masing-masing set (data *training* dan validasi). Tujuannya adalah untuk memastikan bahwa data *training* hanya digunakan untuk proses pelatihan dan pembelajaran bagi model, sementara data validasi digunakan untuk memvalidasi hasil pemodelan dan data validasi bersifat

independen (tidak digunakan dalam *Training*).

Kemudian membangun arsitektur dasar U-Net *Conv2D*, *MaxPooling2D*, *UpSampling2D*, dan *Concatenate* serta pemanfaatan *Backbone* untuk ekstraksi fitur. Arsitektur ini merupakan inti dari pemodelan segmentasi menggunakan U-net. Setelah arsitektur model U-Net dibuat, latih data menggunakan data generator yang telah didefinisikan.

Setelah pelatihan selesai, model digunakan untuk segmentasi pada citra uji hasil deteksi dibandingkan dengan data referensi untuk mengevaluasi akurasi model. Metrik evaluasi yang digunakan meliputi *precision*, *recall*, *Dice Coefficient*, dan *Intersection over Union* (IoU). Metrik ini membantu untuk mengukur tingkat kesesuaian antara hasil segmentasi dengan *ground truth* secara lebih komprehensif, sekaligus meminimalkan potensi kesalahan klasifikasi.

Tahap Analisis

Pada penelitian ini mengimplementasikan evaluasi dilakukan menggunakan empat metrik utama yaitu *Intersection over Union* (IoU), *Dice Coefficient*, *Precision*, dan *Recall*.

IoU dipilih karena sensitivitasnya terhadap akurasi spasial dan kemampuannya memberikan gambaran holistik tentang presisi segmentasi. Perhitungan IoU dilakukan melalui perbandingan *pixel-wise* antara *predicted mask* (hasil segmentasi model) dan *ground truth* (data referensi hasil digitasi manual), dengan formulasi matematis:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \dots \dots \dots (1)$$

Keterangan:

- IoU : Perpotongan Antar Data
- A : area prediksi model
- B : area referensi (*ground truth*)

Dice Coefficient, atau Koefisien Dice, merupakan metrik evaluasi yang secara khusus digunakan untuk mengukur tingkat kesamaan (*similarity*) antara dua set data biner, terutama dalam konteks segmentasi citra. *Dice Coefficient* banyak diaplikasikan untuk menilai performa

model segmentasi dengan membandingkan hasil prediksi (*predicted masking*) terhadap data referensi (*ground truth*). Nilainya berkisar antara 0 hingga 1, di mana nilai 1 menunjukkan kesempurnaan antara prediksi dan referensi, sedangkan 0 menandakan tidak ada kesamaan sama sekali.

$$Dice = \frac{2 | A \cap B |}{| A | + | B |} \dots \dots \dots (2)$$

Keterangan:

Dice : kesamaan Antar Data

A : area prediksi model

B : area referensi (*ground truth*)

Precision (Presisi) adalah rasio antara jumlah prediksi positif yang benar (*True Positive*) dengan total prediksi positif (*True Positive* + *False Positive*). *Precision* menunjukkan seberapa tepat model dalam mengidentifikasi lahan ubi cilembu, atau dengan kata lain, dari semua lahan yang diprediksi sebagai ubi cilembu, berapa banyak yang benar-benar ubi Cilembu. Rumus matematisnya:

$$Precision = \frac{TP}{TP + FP} \dots \dots \dots (3)$$

Recall (*Sensitivitas*) adalah rasio antara jumlah prediksi positif yang benar (*True Positive*) dengan total data aktual positif (*True Positive* + *False Negative*). *Recall* mengukur seberapa baik model dalam menemukan seluruh lahan ubi Cilembu yang ada.

$$Recal = \frac{TP}{TP + FN} \dots \dots \dots (4)$$

HASIL DAN PEMBAHASAN


Penelitian ini berhasil mengembangkan model segmentasi lahan pertanian ubi cilembu menggunakan arsitektur U-Net dengan memanfaatkan citra *orthophoto* resolusi tinggi yang dihasilkan dari foto udara drone. Dataset yang digunakan terdiri dari citra hasil pengolahan foto udara dan digitasi manual sebagai *ground truth*. Proses *preprocessing* meliputi konversi citra ke

format 8-bit, pembagian citra menjadi patch berukuran 256×256 piksel, serta normalisasi nilai piksel untuk memastikan konsistensi data. Model U-Net diimplementasikan dengan konfigurasi *encoder-decoder* simetris, *skip connections*, serta *fungsi loss binary cross-entropy* dan *optimizer Adam*. Pelatihan model dilakukan selama 50 *epoch* dengan ukuran *batch* sebesar 8.

Hasil Data Preprocessing

Penelitian ini menghasilkan Data *Preprocessing* yang harus disiapkan sebelum melakukan pemodelan dan pelatihan model U-Net yang diantaranya yaitu pengecekan Distribusi Nilai Piksel dan pengecekan sistem koordinat foto udara dan data *masking* harus sama.

Distribusi nilai piksel sangat penting dalam pemodelan segmentasi. Distribusi nilai piksel pada foto udara input setelah dikonversi idealnya adalah 0 - 255, sementara untuk foto udara mask bernilai biner 1 dan 0. Hal ini ditujukan untuk membantu model belajar lebih efektif dengan memastikan semua fitur berada dalam skala yang sama yang dapat meningkatkan stabilitas dan kecepatan konvergensi selama pelatihan.



Gambar 2 Hasil Final Check dan Summary FU Input dan Mask


Hasil Pemodelan dan Pelatihan Model U-Net

Model U-Net dilatih menggunakan pasangan data *orthophoto* dan *masking*. Arsitektur U-Net yang memiliki jalur

kontraksi (*encoder*) dan ekspansi (*Decoder*) memungkinkan ekstraksi fitur spasial dan kontekstual secara efektif. Mekanisme *skip connections* menjaga detail spasial penting sehingga segmentasi lahan ubi menjadi presisi. Fungsi *loss binary cross-entropy* dan *optimizer Adam* digunakan untuk mengoptimalkan pelatihan.

Proses pelatihan dilakukan melalui *notebook* berbasis *python* yang dijalankan dengan bantuan *google colab*. Gambar *input* digunakan dengan resolusi sebesar 256x256 *piksel*. Proses pelatihan dilakukan selama 50 *epoch* dengan ukuran *batch* sebesar 8.

Model yang sudah dibangun dites untuk diterapkan pada *Patch* data test, bila hasilnya sesuai dengan *patch masking*, secara visual model berhasil dilatih menggunakan sample dataset yang disediakan.




Gambar 3 Tes Model U-Net

Visualisasi hasil segmentasi memperlihatkan bahwa model dapat membedakan area lahan ubi dari area sekitarnya secara jelas, meskipun terdapat beberapa kesalahan minor pada batas-batas objek yang kompleks. Hal ini menunjukkan bahwa metode U-Net efektif dalam mendukung pemetaan lahan pertanian secara otomatis.

Evaluasi Model Segmentasi

Setelah proses pelatihan model U-Net selesai, tahap selanjutnya adalah melakukan evaluasi terhadap performa model menggunakan data validasi dan pengujian yang telah dipisahkan sebelumnya. Evaluasi ini bertujuan untuk mengukur seberapa baik model mampu melakukan segmentasi lahan pertanian ubi cilembu secara akurat dan konsisten.

Visualisasikan hasil pelatihan dengan menggunakan beberapa parameter metrik untuk melihat performa model. Biasanya, metrik yang digunakan diantaranya adalah *Intersection over Union (IoU)*, *Dice Coefficient*, *Precision*, dan *Recall*.




Gambar 4 Evaluasi Metrik Segmentasi

Hasil evaluasi menunjukkan bahwa model segmentasi lahan yang dikembangkan mencapai performa yang sangat memuaskan. Berdasarkan metrik evaluasi yang digunakan, model ini memperoleh nilai *Dice Coefficient* sebesar 87,75%, *IoU (Intersection over Union)* 78,17%, *recall* 89,43%, dan *Precision* 86,12%.

Berbagai metrik ini saling melengkapi dalam memberikan gambaran komprehensif tentang kualitas segmentasi yang dihasilkan. Penting untuk dicatat bahwa meskipun akurasi tinggi penting, namun dalam kasus data tidak seimbang, metrik seperti *Dice Coefficient* dan *IoU* menjadi indikator yang lebih representatif karena mampu mengukur tingkat kesesuaian antara hasil segmentasi dengan *ground truth* secara lebih komprehensif, sekaligus meminimalkan potensi kesalahan klasifikasi.

Hasil Pemodelan pada Foto Udara Full Scene

Implementasi model U-Net yang telah dilatih kemudian diuji pada foto udara *full scene* untuk mengevaluasi performanya dalam skala yang lebih besar dan kondisi riil.



Gambar 5 Hasil Prediksi FullScene

Hasil segmentasi menunjukkan bahwa model mampu mempertahankan konsistensi akurasi meskipun diaplikasikan pada area yang lebih luas, dengan presisi dalam mengidentifikasi batas-batas lahan ubi cilembu yang kompleks. Beberapa area dengan tekstur vegetasi yang kurang jelas atau pencahayaan yang tidak merata menunjukkan sedikit penurunan akurasi, namun secara keseluruhan model berhasil memetakan distribusi lahan dengan baik.




Gambar 6 visualisasi hasil segmentasi lahan pertanian ubi cilembu menggunakan ArcMap.

Pada Gambar 6 Hasil segmentasi lahan pertanian ubi cilembu yang diperoleh dari model U-Net berhasil divisualisasikan secara efektif menggunakan ArcMap yang menghasilkan delineasi batas lahan yang jelas dan akurat. Visualisasi ini menampilkan distribusi spasial lahan ubi cilembu dengan warna putih, sementara area non-pertanian ditampilkan dalam warna hitam untuk membedakan kedua kelas secara visual.


Hasil Pemodelan pada Foto Udara Baru

Dalam penerapan model yang sudah dibangun (*pre-trained* model) pada foto udara baru untuk segmentasi lahan pertanian ubi cilembu dengan metode U-Net, terdapat beberapa tahapan yang penting untuk dipahami. U-Net, sebagai arsitektur *deep learning* yang dirancang khusus untuk segmentasi gambar, mampu menghasilkan kelas objek yang berbeda dalam sebuah citra, bahkan pada detail skala piksel. Model U-Net yang telah dilatih pada dataset serupa akan menyimpan pengetahuan fitur khusus yang relevan untuk segmentasi lahan, seperti bentuk petak lahan, vegetasi, dan tekstur tanah. Gambar 7 menunjukkan foto udara baru yang digunakan untuk melakukan segmentasi lahan menggunakan model yang telah dikembangkan sebelumnya.



Gambar 7 Hasil Pre-trained model ke foto udara baru

Ketika model *pre-trained* ini diterapkan ke foto udara baru, proses utamanya adalah melakukan inferensi, yaitu model akan langsung mengidentifikasi area-area yang menjadi wilayah lahan pertanian ubi cilembu pada citra yang sebelumnya belum pernah dilihat. Hal ini menjadi keunggulan *transfer learning*, di mana model tidak perlu dilatih dari awal, melainkan hanya perlu dilakukan *fine-tuning* jika ada penyesuaian pada karakteristik data baru. Proses ini mempercepat waktu analisis dan secara signifikan menghemat sumber daya komputasi, karena model sudah memahami pola umum pada citra lahan pertanian.



Gambar 8 Hasil Penerapan Model Yang Sudah Dibangun (Pre-Trained Model) Ke foto udara baru

Pada Gambar 8, hasil segmentasi lahan pertanian ubi Cilembu yang dihasilkan oleh model U-Net berhasil divisualisasikan secara optimal menggunakan perangkat lunak ArcMap. Visualisasi tersebut memperlihatkan batas-batas lahan dengan jelas dan akurat. Dalam tampilan tersebut, lahan ubi Cilembu ditandai dengan warna putih, sedangkan area yang bukan lahan pertanian ditandai dengan warna hitam untuk membedakan kedua kelas secara visual.

Hasil ini membuktikan bahwa arsitektur U-Net yang dikembangkan memiliki skalabilitas yang baik untuk diaplikasikan pada pemetaan lahan skala luas, sekaligus mengkonfirmasi efektivitas *preprocessing* dan pelatihan yang dilakukan sebelumnya.

PENUTUP

Kesimpulan

Berdasarkan hasil penelitian, model U-Net mampu melakukan segmentasi lahan pertanian ubi cilembu dari foto udara dengan performa yang sangat baik. Nilai evaluasi seperti *dice Coefficient* sebesar 87,75 %, *IoU* sebesar 78,17%, *recall* sebesar 89,43%, dan *precision* sebesar 86,12% menunjukkan bahwa model ini tidak hanya akurat dalam mengenali area target, tetapi juga efektif dalam meminimalkan kesalahan klasifikasi. Penggunaan U-Net terbukti efektif dalam mempertahankan detail spasial sehingga mampu mengidentifikasi batas-batas lahan secara tepat. Dengan demikian, integrasi

teknologi *drone* untuk pengambilan citra dan metode *deep learning* U-Net dapat menjadi solusi yang praktis dan efisien untuk pemetaan serta pengelolaan lahan pertanian ubi cilembu secara akurat. Penelitian ini diharapkan dapat mendukung pengembangan teknologi pemantauan lahan pertanian berbasis Foto udara dan *deep learning* yang lebih lanjut di masa depan.

Saran

Saran yang dapat diberikan penulis bagi penelitian selanjutnya yaitu:

1. Disarankan untuk memperluas jumlah dan variasi data citra *orthophoto* serta data *masking* agar model U-Net dapat belajar dari beragam kondisi lahan dan pencahayaan. Hal ini akan meningkatkan kemampuan generalisasi model dalam segmentasi lahan ubi cilembu di berbagai situasi lapangan.
2. Perlu lebih cermat dalam melakukan digitasi manual dikarenakan lahan pertanian ubi cilembu cukup rapat maka perlu hati-hati dalam pembuatan *masking* data. Dikarenakan hasil digitasi manual bisa mempengaruhi hasil pemodelan dikarenakan menjadi acuan atau pembanding.
3. Meningkatkan ukuran dan variasi dataset pelatihan, termasuk data dari musim atau kondisi cuaca berbeda, dapat membuat model lebih robust dan generalisasi lebih baik terhadap variasi kondisi lahan pertanian di lapangan.

DAFTAR PUSTAKA

- Abidin, H. Z. (2007). *Penentuan posisi dengan GPS dan aplikasinya*. Jakarta: PT Pradnya Paramita.
- Al, S. J. (2025). *Panduan Lengkap Image Segmentation Pengertian, Jenis, dan Aplikasinya*. Diambil kembali dari <https://hub.kirim.ai/panduan-lengkap-image-segmentation/>

- Ariyanto, M. (2020). *Sistem Kendali Quadcopter untuk Pemetaan Lahan Pertanian*. Yogyakarta: Deepublish.
- Attia, H. H. (2017). Deep Learning: A Review for the Electrical and Computer Engineering Community. IEEE Access.
- Brahmantara. (2017). Metode Foto Rentang Dekat (Close Range Photogrammetry) Dan Aerial Untuk Pendokumentasian Tiga Dimensi Cagar Budaya. *Konservasi Cagar Budaya Borobudur*, XI, 76-88.
- Brainwave. (2023). *U-NET : Arsitektur Deep Learning untuk Semantic Segmentation*. Diambil kembali dari <https://brainwavee.medium.com/u-net-arsitektur-deep-learning-untuk-semantic-segmentation-5607fb4536c9>
- Emil Naf'an, S. M. (2022). Dasar- dasar deep learning dan contoh aplikasinya. sumatera barat: CV. MITRA CENDIKIA MEDIA.
- Kementarian Pertanian Indonesia. (2022, September 21). Diambil kembali dari Pusat perpustakaan dan literasi pertanian: <https://pustaka.setjen.pertanian.go.id/info-literasi/mengenal-ubi-cilembu>
- lyman, C. (2023, April 6). Diambil kembali dari Penting di AI, Apa itu Image Segmentation dan Contohnya?: <https://pintu.co.id/blog/image-segmentation-ai#apa-itu-image-segmentation>
- Mayastuti, A. (2002). Ubi Cilembu. Medan: Universitas Sumatera Utara Press.
- Priyono. (2008). *Metode Penelitian Kuantitatif*. Sidoarjo: Zifatama Publishing.
- sari, R. p. (2024, august 24). *Apa itu Convolutional Neural Networks? Pengertian & Cara Kerja*. Diambil kembali dari <https://aihub.id/pengetahuan-dasar/apa-itu-cnn>
- Silvia. (2025). *eksplorasi segmentasi citra*. Diambil kembali dari <https://bisa.ai/portofolio/detail/NDU4NA>
- Skola, D. (2025). *Apa itu Deep Learning: Konsep Dasar, Cara Kerja, dan Implementasinya*. Diambil kembali dari <https://digitalskola.com/blog/data-science/deep-learning>
- Soetaat. (1994). *Diktat Fotogrametri Analitik*. Yogyakarta: Universitas Gadjah Mada.
- Sugiyono. (2016). *Metode Penelitian Kuantitatif, Kualitatif, dan R&D (Cetakan ke-23)*. Bandung: CV. Alfabeta.
- Sugiyono. (2009). *Metode Penelitian Pendidikan (Pendekatan Kuantitatif, R&D)*. Bandung: Alfabeta.
- Sugiyono. (2006). *Statistika Untuk Penelitian*. Bandung: CV. Alfabeta.
- Sugiyono. (2006). *Statistika Untuk Penelitian*. Bandung: CV. Alfabeta.
- Suharsana. (1999). *Fotogrametri Dasar*. Yogyakarta: Teknik Geodesi Fakultas Teknik Universitas Gadjah Mada.
- Suriawiria. (2001). Ubi jalar Cilembu: Karakteristik dan potensi pengembangan.
- Tedja, H. a. (2023, May 11). *Konsep dan Implementasi U-Net model untuk Image Segmentation dengan Tensorflow*. Diambil kembali dari <https://medium.com/@haidhiangkawijan/konsep-dan-implementasi-u-net-model-untuk-image-segmentation-dengan-tensorflow-3de40171c5ac>
- Wolf, P. R. (1993). *Elements of Photogrammetry with Applications in GIS*.