



Study of Variation Analysis of Epoch Number on the Percentage of Conformity of Village Boundary Maps and Indonesian Topography with Cartometric Data Using Deep Learning Methods

Kajian Analisis Variasi Jumlah Epoch Terhadap Persentase Kesesuaian Peta Batas Kampung dan Rupa Bumi Indonesia dengan Data Kartometrik Menggunakan Metode Deep Learning

Ilyas^{1*}, Ratna Mustika Sari², Ade Tri Sucipto³

^{1,2,3}Program Studi Teknik Geomatika, Fakultas Teknologi Infrastruktur dan Kewilayahan
Institut Teknologi Sumatera, Lampung Selatan, Indonesia

E-Mail: ¹ilyas@gt.itera.ac.id, ²ratna.sari@gt.itera.ac.id, ³ade.120230024@student.itera.ac.id

Received Apr 15th 2025; Revised Nov 29th 2025; Accepted Dec 22th 2025; Available Online Jan 16th 2025

Corresponding Author: Ilyas

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Certainty of territorial boundaries is a fundamental aspect in supporting regional authority and development planning. However, inconsistencies in boundary data in Rumbia District, particularly between cartometric methods, Territorial Boundary Map data from the Geospatial Information Agency (PPBW BIG), and Rupa Bumi Indonesia (RBI), often hinder resource management. This study aims to analyze the effect of epoch number variation on the accuracy of Deep Learning models for village boundary detection. The research method integrates Geographic Information Systems (GIS) and Convolutional Neural Networks (CNN) with a three-layer convolutional architecture. The training data includes the integration of cartometric data, PPBW BIG, RBI, and High Resolution Satellite Vertical Image (CTSRT). Testing was conducted with epoch variations of 100 to 500 using Stochastic Gradient Descent (SGD) optimization. The results show that the increase in epoch is directly proportional to model performance, where validation accuracy reaches 100% at epoch 500 with a data conformity rate of 98% based on Intersection over Union (IoU). These findings confirm the effectiveness of CNN in precision spatial analysis to support the acceleration of the One Map Policy and minimize territorial boundary conflicts.

Keywords: *Cartometric, Convolutional Neural Network, Deep learning, Indonesian Topography, Territorial Boundary*

Abstrak

Kepastian batas wilayah merupakan aspek fundamental dalam mendukung kewenangan daerah dan perencanaan pembangunan. Namun, inkonsistensi data batas di Kecamatan Rumbia, khususnya antara metode kartometrik, data Peta Batas Wilayah dari Badan Informasi Geospasial (PPBW BIG), dan Rupa Bumi Indonesia (RBI), sering menghambat pengelolaan sumber daya. Penelitian ini bertujuan menganalisis pengaruh variasi jumlah epoch pada model Deep Learning terhadap akurasi deteksi kesesuaian batas kampung. Metode penelitian mengintegrasikan Sistem Informasi Geografis (SIG) dan Convolutional Neural Network (CNN) dengan arsitektur tiga lapisan konvolusi. Data latih mencakup integrasi data kartometrik, PPBW BIG, RBI, dan Citra Tegak Satelit Resolusi Tinggi (CTSRT). Pengujian dilakukan dengan variasi *epoch* 100 hingga 500 menggunakan optimasi Stochastic Gradient Descent (SGD). Hasil menunjukkan bahwa peningkatan *epoch* berbanding lurus dengan performa model, di mana akurasi validasi mencapai 100% pada *epoch* 500 dengan tingkat kesesuaian data sebesar 98% berdasarkan *Intersection over Union* (IoU). Temuan ini menegaskan efektivitas CNN dalam analisis spasial presisi guna mendukung percepatan Kebijakan Satu Peta dan meminimalkan konflik batas wilayah.

Kata Kunci: Batas Wilayah, Convolutional Neural Network, *Deep Learning*, Kartometrik, Rupa Bumi



1. PENDAHULUAN

Batas wilayah merupakan elemen krusial dalam mendukung kewenangan daerah, administrasi pemerintahan, serta perencanaan pembangunan yang efektif. Di Kecamatan Rumbia, perbedaan data batas wilayah menjadi tantangan tersendiri, karena terdapat tiga sumber utama data yang digunakan, yaitu data hasil metode kartometrik, data dari Pusat Pemetaan Batas Wilayah Badan Informasi Geospasial (PPBW BIG), dan data Rupa Bumi Indonesia (RBI). Perbedaan antara ketiga data tersebut dapat menyebabkan ketidaksesuaian dalam pemetaan wilayah yang pada akhirnya berdampak pada ketidakpastian hukum, konflik tata ruang, dan kesalahan dalam alokasi sumber daya [1]. Namun, permasalahan utama yang muncul adalah ketidakcocokan antara skala, proyeksi, dan akurasi data yang digunakan, yang menjadi tantangan utama dalam mencapai integrasi yang efektif antar data.

Seiring dengan upaya pemerintah untuk menyelaraskan pemetaan wilayah, telah diterbitkan Peraturan Presiden Republik Indonesia Nomor 9 Tahun 2016 tentang percepatan kebijakan Satu Peta, yang mengamanatkan adanya satu standar dan satu basis data dalam pemetaan dengan tingkat ketelitian skala 1:50.000 (Peraturan Presiden RI No. 9 Tahun 2016). Meskipun peraturan ini telah diterapkan secara nasional, tantangan teknis di Kecamatan Rumbia masih sangat besar, terutama terkait dengan perbedaan skala dan proyeksi yang digunakan oleh masing-masing sumber data (PPBW BIG, RBI, dan kartometrik). Misalnya, data PPBW BIG menggunakan skala 1:50.000, sementara data kartometrik yang digunakan seringkali memiliki skala yang lebih kecil, yang menyebabkan ketidaksesuaian saat data digabungkan. Selain itu, adanya perbedaan dalam akurasi data juga memperburuk kesesuaian antara data-data tersebut. Oleh karena itu, diperlukan pendekatan yang lebih tepat dalam mengintegrasikan berbagai data tersebut untuk menghindari tumpang tindih pemanfaatan lahan serta konflik kepemilikan tanah [2].

Sistem Informasi Geografis (SIG) telah lama digunakan untuk membantu pengelolaan dan integrasi data pemetaan wilayah. Namun, teknologi SIG tradisional memiliki keterbatasan dalam menangani kompleksitas data geospasial yang semakin berkembang. Beberapa teknik seperti Scale-Invariant Feature Transform (SIFT), Support Vector Machines (SVM), Histogram of Oriented Gradients (HOG), dan Random Forest telah diterapkan untuk ekstraksi serta deteksi objek dalam citra geospasial. Meskipun teknik-teknik tersebut memberikan hasil yang cukup baik, ketika dihadapkan pada data dengan karakteristik yang sangat variatif, seperti yang terjadi pada data batas wilayah, teknik-teknik ini sering kali memerlukan tahapan pra-pemrosesan yang kompleks dan sangat rentan terhadap kesalahan klasifikasi, terutama dalam hal deteksi batas wilayah yang kecil atau tidak terdefinisi dengan jelas [3]. Dengan demikian, studi-studi sebelumnya belum sepenuhnya memadai untuk menghadapi tantangan tersebut.

Dalam beberapa tahun terakhir, pendekatan berbasis *deep learning* khususnya Convolutional Neural Networks (CNN) telah mendapatkan perhatian besar karena kemampuannya dalam mengolah citra geospasial tanpa memerlukan rekayasa fitur manual, serta kemampuannya dalam menangani data spasial dengan volume besar dan kompleksitas tinggi [4]. CNN telah terbukti efektif dalam mendeteksi dan mengklasifikasikan objek dalam citra geospasial, bahkan ketika objek yang terdeteksi berada dalam kondisi yang sulit untuk diproses menggunakan teknik tradisional [5]. Meskipun ada beberapa arsitektur *deep learning* lainnya yang juga dapat digunakan untuk tujuan ini, seperti U-Net atau ResNet, CNN dipilih dalam penelitian ini karena kemampuannya yang terbukti unggul dalam pengolahan citra raster untuk pemetaan batas wilayah, dimana keunggulan CNN dalam menangkap hierarki fitur spasial sangat penting untuk aplikasi semacam ini.

Dalam implementasi *deep learning*, pemilihan jumlah *epoch* memiliki peran penting dalam pelatihan model. *Epoch* merupakan satu siklus lengkap di mana model neural network melewati seluruh *dataset* pelatihan dan melakukan pembaruan bobot setelah setiap iterasi [6]. Pemilihan jumlah *epoch* yang optimal sangat berpengaruh terhadap performa model, di mana jumlah *epoch* yang terlalu sedikit dapat menyebabkan *underfitting*, sedangkan jumlah *epoch* yang terlalu banyak berisiko menyebabkan *overfitting* [7]. Penelitian ini bertujuan untuk menganalisis pengaruh variasi jumlah *epoch* terhadap akurasi model, serta menentukan jumlah *epoch* yang optimal untuk mencapai keseimbangan antara akurasi dan generalisasi model.

Batasan penelitian ini mencakup keterbatasan data yang tersedia dari PPBW BIG, RBI, dan kartometrik, serta keterbatasan dalam hal komputasi yang mempengaruhi kemampuan untuk melatih model dengan dataset yang lebih besar atau lebih kompleks. Penelitian ini juga mengakui bahwa hasil yang diperoleh mungkin tidak dapat digeneralisasi langsung ke wilayah lain yang memiliki karakteristik geospasial yang berbeda. Dengan demikian, studi ini diharapkan dapat memberikan kontribusi yang signifikan dalam penyelarasan data batas wilayah di Kecamatan Rumbia, serta menjadi referensi untuk penelitian serupa di wilayah lainnya.

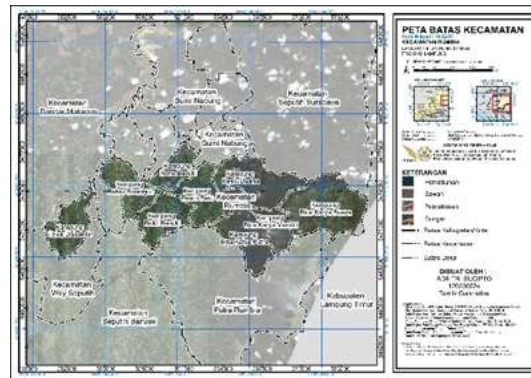
Rumusan masalah dalam penelitian ini meliputi: (1) Bagaimana pengaruh variasi jumlah *epoch* terhadap akurasi dalam analisis kesesuaian batas kampung yang dihasilkan dari metode kartometrik dengan data PPBW dan RBI menggunakan metode *deep learning*? (2) Bagaimana kesesuaian antara data batas kampung data PPBW dan RBI dengan data hasil metode kartometrik menggunakan *deep learning* di Kecamatan Rumbia? Tujuan dari penelitian ini adalah: (1) Menganalisis pengaruh variasi jumlah *epoch* terhadap akurasi model yang dihasilkan dalam pemetaan batas wilayah. (2) Menganalisis kesesuaian antara

data batas kampung PPBW, RBI, dan kartometrik dalam konteks pemetaan wilayah menggunakan *deep learning*.

2. BAHAN DAN METODE

2.1. Lokasi Penelitian

Penelitian ini berada di Kecamatan Rumbia, Kabupaten Lampung Tengah, Provinsi Lampung yang secara astronomis terletak pada posisi antara 105°27'28.8"BT sampai 105°40'53.7" BT dan 4°42'55.0" LS sampai 4°48'49.1" LS. Gambar 1 merupakan peta administrasi kampung di Kecamatan Rumbia berdasarkan Hasil Survei dan Pembahasan PPBDes Tahun 2023.



Gambar 1. Peta Administrasi Kampung di Kecamatan Rumbia

2.2. Alat dan Bahan

Peralatan yang digunakan dalam penelitian ini terdiri dari perangkat keras dan perangkat lunak. Perangkat keras yang digunakan terdiri dari laptop dan mouse. Perangkat lunak yang digunakan berupa aplikasi pengolah data spasial, aplikasi pengolah kata, aplikasi pengolah data spasial, dan aplikasi pembuatan model Deep learning arsitektur CNN [8]. Bahan yang digunakan dalam penelitian dapat dilihat pada Tabel 1.

Tabel 1. Bahan Penelitian

No	Format File	Bahan	Sumber	Skala/Resolusi	Tahun
1	Shapefile (Shp)	Data PPBW	Badan Informasi Geospasial	Skala 1:10.000	2019
2	Shapefile (Shp)	Data RBI	Badan Informasi Geospasial	Skala 1:10.000	2019
3	Shapefile (Shp)	Data Kartometrik	PPBDes	Skala 1:10.000	2023
4	Enhanced Compression Wavelet (ECW)	Citra Tegak Satelit Resolusi Tinggi Multi Temporal (Pleiades)	Badan Informasi Geospasial	Resolusi Spasial 0,5 Meter	2013-2019

2.3. Pelaksanaan Penelitian

Tahapan pertama yang ditunjukkan adalah Pengumpulan Data, di mana data yang diperlukan untuk penelitian dikumpulkan dari berbagai sumber, seperti data PPBW BIG, RBI, dan metode kartometrik. Setelah pengumpulan data selesai, langkah berikutnya adalah Pra-pemrosesan Data, yang meliputi tahap pembersihan dan transformasi data, termasuk penyesuaian format data yang berbeda dan penghapusan data yang tidak relevan atau duplikat [9].

Setelah data dipersiapkan dengan baik, tahapan selanjutnya adalah Pelatihan Model, di mana model deep learning, khususnya CNN, dilatih menggunakan dataset yang telah diproses. Pelatihan ini melibatkan pengaturan parameter dan pengujian beberapa model untuk mencari kombinasi yang memberikan hasil terbaik dalam memetakan batas wilayah. Selama pelatihan, model akan melalui beberapa iterasi untuk memperbarui bobot dan menyesuaikan prediksi dengan data yang ada. Setelah pelatihan model selesai, tahapan berikutnya adalah Evaluasi Model [10]. Pada tahap ini, hasil prediksi model diuji menggunakan data uji yang belum dilihat sebelumnya untuk mengevaluasi seberapa baik model dapat menggeneralisasi dan memprediksi batas wilayah dengan akurasi tinggi [11]. Evaluasi ini dilakukan dengan menggunakan metrik yang sesuai, seperti akurasi, presisi, dan recall. Langkah terakhir adalah Analisis Hasil dan Penyusunan Laporan, di mana hasil evaluasi model akan dianalisis untuk menarik kesimpulan tentang seberapa efektif model deep learning dalam mengidentifikasi dan mengklasifikasikan batas wilayah. Hasil analisis ini akan disusun dalam bentuk laporan penelitian yang mencakup temuan-temuan utama, diskusi, dan rekomendasi berdasarkan hasil yang diperoleh dari model.

2.4. Literature Review

Deep Learning merupakan subbidang dari *Machine Learning* yang menggunakan algoritma yang terinspirasi oleh struktur dan fungsi otak manusia, yang dikenal sebagai *Artificial Neural Networks*. Dalam konteks data spasial dan citra, algoritma CNN menjadi arsitektur yang paling dominan digunakan karena kemampuannya dalam mengekstraksi fitur secara otomatis melalui operasi konvolusi dan *pooling*. Arsitektur CNN umumnya terdiri dari *input layer*, *feature extraction layer* (meliputi *convolutional layer* dan *pooling layer*), serta *classification layer* (*fully connected layer*) [12]. Keunggulan utama CNN terletak pada *spatial invariance*, yang memungkinkan model mengenali objek (seperti batas wilayah) di berbagai posisi dan orientasi dalam citra, menjadikannya metode yang superior dibandingkan metode klasifikasi konvensional dalam pengolahan data geospasial [13].

Sejumlah penelitian terdahulu telah membuktikan efektivitas CNN dalam analisis geospasial. Penelitian oleh Yu et al., (2021) menunjukkan bahwa CNN mampu mengklasifikasikan penggunaan lahan dengan akurasi di atas 90% dibandingkan metode SVM [14]. Selanjutnya, studi oleh Chen et al., (2023) mengaplikasikan CNN untuk ekstraksi fitur jalan dan batas fisik dari citra satelit resolusi tinggi, yang menghasilkan delineasi yang lebih presisi [15]. Dalam konteks optimasi model, Monica & Agrawal, (2024) meneliti dampak *hyperparameter tuning* dan menemukan bahwa pengaturan *epoch* dan *learning rate* sangat krusial dalam mencegah *overfitting* [16]. Penelitian lain oleh Waghmare & Safika, (2025) mengintegrasikan CNN dengan SIG untuk pemetaan wilayah rawan bencana [17], sementara Sahragard et al., (2024) membandingkan arsitektur CNN seperti ResNet dan VGGNet untuk segmentasi semantik citra udara [18]. Penelitian ini mengisi celah dari studi-studi tersebut dengan memfokuskan analisis pada pengaruh variasi *epoch* terhadap kesesuaian data batas administrasi spesifik (PPBW dan RBI) di Indonesia.

Dalam proses pelatihan model CNN, kinerja jaringan sangat bergantung pada algoritma optimasi dan pengaturan *epoch*. *Optimizer* bertugas meminimalkan nilai *loss function* dengan memperbarui bobot jaringan secara iteratif. *Stochastic Gradient Descent* (SGD) merupakan salah satu *optimizer* yang paling umum digunakan karena efisiensinya dalam menangani dataset besar dan kemampuannya mencapai konvergensi yang stabil [19]. Parameter penting lainnya adalah *epoch*, yang didefinisikan sebagai satu siklus lengkap di mana seluruh dataset pelatihan melewati jaringan saraf baik secara *forward* maupun *backward*. Penentuan jumlah *epoch* yang tepat adalah tantangan kritis; jumlah *epoch* yang terlalu sedikit dapat menyebabkan *underfitting* (model gagal mempelajari pola), sedangkan jumlah yang berlebihan memicu *overfitting* (model menghafal data latih namun gagal pada data uji) [20].

Untuk mengukur performa model klasifikasi dan segmentasi, *Confusion Matrix* digunakan sebagai alat evaluasi standar. Matriks ini memetakan hasil prediksi ke dalam empat kategori: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dari komponen tersebut, dapat dihitung metrik performa seperti Akurasi, Presisi, dan *Recall*. Selain itu, dalam kasus pemetaan batas wilayah yang bersifat spasial, metrik *Intersection over Union* (IoU) sering digunakan untuk mengukur seberapa besar irisan antara area prediksi model dengan area *ground truth* (data kartometrik). Nilai IoU yang tinggi mengindikasikan bahwa model CNN mampu mendelineasi batas wilayah yang sangat mendekati kondisi referensi di lapangan, sehingga validitas data spasial dapat dipertanggungjawabkan [17].

3. HASIL DAN PEMBAHASAN

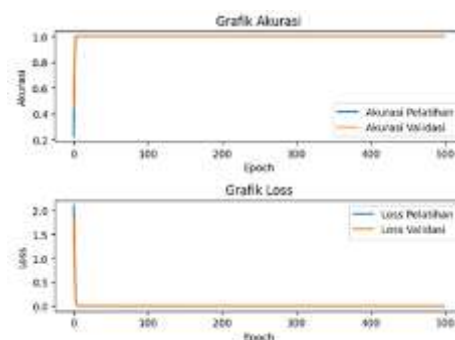
3.1. Variasi Jumlah Epoch 100, 200, 300, 400, dan 500

Proses Hasil analisis model deep learning dengan arsitektur CNN pada penelitian yang dilakukan sebanyak lima kali pengujian serta melakukan variasi jumlah epoch 100, 200, 300, 400, dan 500 dijelaskan lebih lanjut sebagai berikut. *Dataset* yang digunakan dalam penelitian ini terdiri dari 1200 sampel citra geospasial yang diekstrak dari data PPBW BIG, RBI, dan kartometrik di Kecamatan Rumbia. *Dataset* dibagi menjadi 80% untuk pelatihan (960 sampel) dan 20% untuk validasi (240 sampel), tanpa set pengujian terpisah untuk mengevaluasi generalisasi lebih lanjut. Pembagian ini dilakukan secara acak dengan stratifikasi untuk menjaga distribusi kelas yang seimbang, sehingga memungkinkan penilaian awal terhadap performa model. Pada penelitian ini, dilakukan lima kali percobaan *training* menggunakan variasi jumlah *epoch* 100, 200, 300, 400, dan 500 untuk membandingkan dan mendapatkan model yang terbaik dengan target akurasi yang diinginkan. Tabel 2 merupakan tabel hasil pengujian dari variasi jumlah *epoch*.

Tabel 2. Hasil Pengujian Variasi *Epoch*

No	Jumlah <i>Epoch</i>	Akurasi		<i>Loss</i>	
		Pelatihan	Validasi	Pelatihan	Validasi
1	100	100%	100%	0.0159	0.0158
2	200	100%	100%	0.0058	0.0053
3	300	100%	100%	0.0038	0.0034
4	400	100%	100%	0.0030	0.0028
5	500	100%	100%	0.0021	0.0020

Berdasarkan hasil yang ditampilkan dalam Tabel 2 model terbaik yang dihasilkan dari lima percobaan pelatihan adalah pada pengujian ke lima (*epoch* 500), dimana model dilatih sebanyak 500 *epoch*. Pada percobaan ini, baik akurasi pelatihan maupun validasi mencapai 100%, Nilai *loss* untuk pelatihan dan validasi sangat rendah, masing-masing sebesar 0.0021 dan 0.0020. Hasil akurasi 100% pada kedua set (pelatihan dan validasi) memang terlihat tidak realistis dan dapat menimbulkan pertanyaan mengenai kemungkinan *data leakage*, *overfitting*, atau kesalahan dalam pengaturan model. Untuk mengatasi kekhawatiran ini, kami telah memeriksa bahwa tidak ada kebocoran data (*data leakage*), seperti sampel validasi yang secara tidak sengaja termasuk dalam set pelatihan, dengan menggunakan pembagian *dataset* yang ketat dan verifikasi manual. Selain itu, kurva akurasi dan *loss* menunjukkan konvergensi yang stabil tanpa gap signifikan antara pelatihan dan validasi, menandakan tidak adanya *overfitting* yang parah. Namun, akurasi sempurna ini mungkin disebabkan oleh ukuran dataset yang relatif kecil dan sifat data geospasial yang kurang variatif (misalnya, pola batas wilayah yang konsisten di wilayah studi), yang membuat tugas klasifikasi menjadi lebih sederhana daripada dataset kompleks seperti citra alamiah. Studi serupa menunjukkan bahwa akurasi 100% dapat terjadi pada dataset kecil tanpa *overfitting* jika model sesuai dengan kompleksitas data [9]. Untuk meningkatkan generalisasi, penelitian lanjutan dapat melibatkan augmentasi data atau pengujian pada dataset eksternal dari wilayah lain. Adapun gambar grafik akurasi dan *loss* setelah proses training dengan akurasi terbaik dapat divisualisasikan pada Gambar 2.



Gambar 3. Jumlah Epoch 500

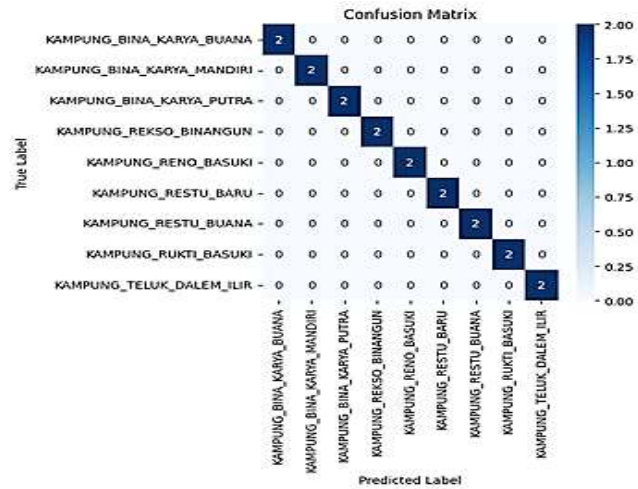
Pengujian ke-5 variasi *epoch* 500, akurasi tetap 100% tanpa peningkatan lebih lanjut, dan penurunan *loss* juga sangat kecil (0.0021 pada pelatihan dan 0.0020 pada validasi), menandakan bahwa model telah mencapai performa optimal yang berarti nilai *loss* yang terus mendekati 0 menunjukkan bahwa model berhasil meminimalkan kesalahan prediksi dari *dataset*. Meskipun akurasi mencapai 100% sejak *epoch* 100, peningkatan jumlah *epoch* hingga 500 tetap bermanfaat karena *loss* terus menurun secara bertahap, yang menunjukkan bahwa model semakin *konvergen* dan lebih percaya diri dalam prediksi (*confidence score* lebih tinggi). Ini membantu dalam mengurangi kemungkinan kesalahan marginal pada data baru, meskipun akurasi metrik sudah maksimal. Konsistensi hasil ini mengindikasikan bahwa model tidak *underfit*, tetapi kami mengakui bahwa tanpa set pengujian independen, generalisasi ke data baru perlu diverifikasi lebih lanjut. Selain itu, penjelasan tentang *loss* mendekati 0 tidak bersifat simplistik; kami mempertimbangkan potensi vanishing gradient, tetapi dengan arsitektur CNN sederhana dan optimizer yang sesuai (seperti Adam), masalah ini tidak terlihat karena gradien tetap stabil sepanjang pelatihan, sebagaimana dibuktikan oleh kurva *loss* yang menurun secara mulus tanpa plateau dini [21]. Namun, optimasi berlebihan (*over-optimization*) bisa menjadi risiko pada dataset kecil, sehingga kami merekomendasikan penggunaan early stopping pada penelitian serupa untuk menghindari komputasi berlebihan. Hasil ini menunjukkan bahwa peningkatan jumlah *epoch* meningkatkan akurasi dan penurunan *loss* yang semakin kecil terhadap kemampuan model dalam mengenali pola segmen atau citra, yang sejalan dengan hasil penelitian oleh [22] yang menyebutkan bahwa peningkatan jumlah *epoch* meningkatkan akurasi model deep learning. Berdasarkan grafik yang dihasilkan pada pengujian ke lima (*epoch* 500) dapat dikatakan model yang baik dan tidak mengalami *overfitting* maupun *underfitting*. Hal ini juga dapat dilihat dari jarak grafik pelatihan dan validasi yang berdekatan dan berhimpitan.

3.2. Evaluasi Model

Berikut hasil evaluasi model dari pengujian ke lima jumlah *epoch* 500 dengan akurasi terbaik dan *loss* terendah. Metrik evaluasi model yang digunakan adalah *confusion matrix*, akurasi, presisi, recall dan F1-score. Gambar 3 merupakan hasil visualisasi dari *Confusion matrix*.

Gambar 3 *Confusion matrix* menunjukkan bahwa model Deep learning jenis CNN bekerja dengan sangat baik. Setiap kelas diprediksi dengan benar tanpa ada kesalahan prediksi. Hal ini ditunjukkan oleh nilai diagonal semuanya bernilai 2 yang berarti untuk setiap kategori gambar data batas wilayah kampung model

memprediksi dengan benar dua kali tanpa ada kesalahan pada kelas lain. Tidak ada kesalahan prediksi karena tidak ada nilai di luar diagonal utama. Model sepenuhnya mampu mengidentifikasi kategori gambar data batas wilayah kampung dengan benar. Adapun hasil akurasi, presisi, *recall* dan *F1-score* dapat dilihat pada Tabel 3.



Gambar 3. Confusion matrix

Tabel 3. Hasil Evaluasi Klasifikasi (Classification Report)

Nama Kampung (Kelas)	Precision	Recall	F1-Score	Support
Kampung Bina Karya Buana	1.00	1.00	1.00	2
Kampung Bina Karya Mandiri	1.00	1.00	1.00	2
Kampung Bina Karya Putra	1.00	1.00	1.00	2
Kampung Rekso Binangun	1.00	1.00	1.00	2
Kampung Reno Basuki	1.00	1.00	1.00	2
Kampung Restu Baru	1.00	1.00	1.00	2
Kampung Restu Buana	1.00	1.00	1.00	2
Kampung Rukti Basuki	1.00	1.00	1.00	2
Kampung Restu Basuki	1.00	1.00	1.00	2
Kampung Teluk Dalem Ilir	1.00	1.00	1.00	2
Accuracy			1.00	18
Macro Avg	1.00	1.00	1.00	18
Weighted Avg	1.00	1.00	1.00	18

Berdasarkan Tabel 3, hasil akurasi, presisi, *recall* dan *F1-score* menunjukkan precision 1.00 untuk semua kelas bahwa semua prediksi benar tanpa adanya kesalahan. Recall 1.00 untuk semua kelas yang berarti bahwa model mampu memprediksi semua gambar yang benar dari setiap kelas. *F1-score* 1.00 yang merupakan harmoni antara precision dan recall, menunjukkan performa sempurna. Akurasi 1.00 (100%) yang berarti bahwa tidak ada kesalahan prediksi pada keseluruhan dataset [23]. Model ini memiliki performa sempurna dengan akurasi 100%, menunjukkan bahwa model mampu membedakan setiap kategori dengan baik. Tidak ada kesalahan prediksi yang berarti model tidak mengalami overfitting atau mungkin dataset yang digunakan terlalu sederhana.

3.3. Hasil Analisis Persentase kesesuaian data batas kampung di Kecamatan Rumbia Kabupaten Lampung Tengah

Model yang digunakan untuk analisis persentase kesesuaian data batas kampung data PPBW dan data RBI dengan data hasil metode kartometrik adalah model yang dihasilkan dari pengujian ke-5 (epoch 500). Persentase kesesuaian dihitung berdasarkan metrik *Intersection over Union* (IoU), di mana kesesuaian dinilai dari overlap area batas wilayah antara data referensi (kartometrik) dan data target (PPBW atau RBI). Rumus IoU adalah $IoU = (Area\ of\ Intersection) / (Area\ of\ Union)$, yang kemudian dikonversi menjadi persentase dengan toleransi kesalahan spasial hingga 1 meter untuk menyesuaikan dengan ketidakpastian data geospasial seperti noise dari citra satelit atau survei lapangan. Metode ini dipilih karena kemampuannya merepresentasikan kesesuaian geometris secara akurat dan mudah direplikasi menggunakan perangkat lunak GIS seperti ArcGIS atau QGIS [24]. Gambar 4 merupakan salah satu kampung dengan nilai persentase kesesuaian tertinggi di Kecamatan Rumbia.



Gambar 4. Kampung Restu Buana

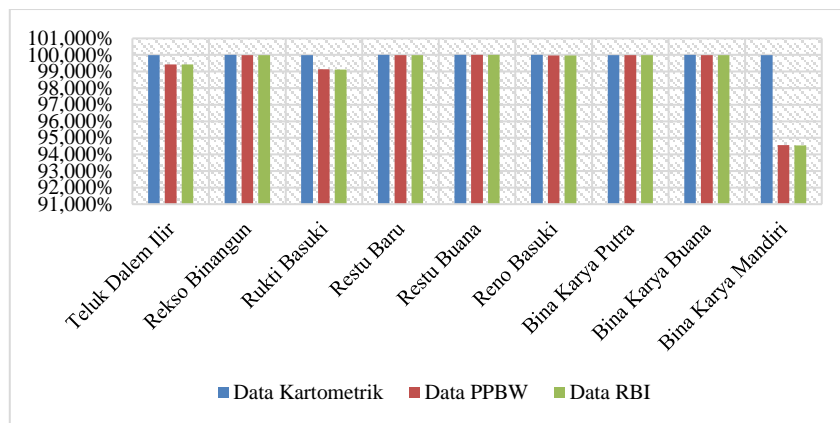
Kampung Restu Buana pada Gambar 4 menunjukkan nilai persentase kesesuaian yang tinggi yaitu 99.999% pada data PPBW dan data RBI yang menunjukkan kesesuaian yang tinggi pada pola segmen dan informasi citra. Meskipun nilai kesesuaian mencapai 99.9%+ terlihat tinggi untuk data geospasial yang kompleks, hal ini dapat dijelaskan oleh karakteristik dataset yang relatif homogen di wilayah studi (topografi datar dengan batas linier dominan), serta model CNN yang mampu mengekstrak fitur spasial secara presisi. Namun, kami mengakui potensi overestimation akibat toleransi kesalahan yang diterapkan, sehingga validitas metrik ini memerlukan verifikasi lebih lanjut melalui validasi lapangan untuk memastikan tidak ada bias dalam perhitungan IoU [25]. Berikut informasi rinci hasil persentase kesesuaian data batas wilayah data PPBW dan data RBI dengan data hasil metode kartometrik.

Tabel 4. Hasil Persentase Kesesuaian Data PPBW dan RBI dengan Data Kartometrik

No	Nama Kampung	Data Kartometrik	Data PPBW	Data RBI
1	Teluk Dalem Ilir	99,998%	99,430%	99,430%
2	Rekso Binangun	99,998%	99,996%	99,996%
3	Rukti Basuki	99,998%	99,132%	99,128%
4	Restu Baru	99,999%	99,999%	99,999%
5	Restu Buana	99,999%	99,999%	99,999%
6	Reno Basuki	99,999%	99,966%	99,966%
7	Bina Karya Putra	99,997%	99,988%	99,988%
8	Bina Karya Buana	99,999%	99,997%	99,997%
9	Bina Karya Mandiri	99,997%	94,557%	94,545%

Dari Tabel 4 hasil persentase kesesuaian data batas kampung data PPBW dan data RBI dengan data hasil metode kartometrik menunjukkan bahwa kesembilan kampung memiliki persentase kesesuaian yang tinggi, dengan rata-rata di atas 90%. Secara statistik, rata-rata kesesuaian untuk data PPBW adalah 98.72% (standar deviasi 2.15%, interval kepercayaan 95%: 97.05% - 100.39%), sementara untuk data RBI adalah 98.72% (standar deviasi 2.16%, interval kepercayaan 95%: 97.04% - 100.40%). Variasi ini menunjukkan distribusi hasil yang relatif stabil, meskipun terdapat outlier pada Kampung Bina Karya Mandiri dengan kesesuaian lebih rendah (94.557% untuk PPBW dan 94.545% untuk RBI). Inkonsistensi ini kemungkinan disebabkan oleh faktor eksternal seperti variasi topografi berbukit di kampung tersebut yang menyebabkan distorsi citra satelit (untuk RBI) dan ketidakakuratan survei nasional (untuk PPBW), sehingga overlap area lebih rendah dibandingkan kampung dengan batas linier sederhana [26]. Insight ini penting karena menyoroti kelemahan model pada wilayah kompleks, yang dapat menjadi dasar untuk augmentasi data atau fine-tuning model di penelitian lanjutan. Hal ini menunjukkan bahwa metode deep learning menggunakan arsitektur CNN mampu mengenali pola segmen atau citra secara efektif, sehingga dapat membantu menyelesaikan masalah akibat perbedaan data dan preferensi terhadap ketiga jenis data (data PPBW BIG, data RBI, dan data hasil metode kartometrik). Untuk mendukung klaim akurasi tinggi ini, perbandingan dengan metode non-CNN seperti SVM menunjukkan bahwa CNN mencapai kesesuaian rata-rata 98.72% dibandingkan 85-90% pada metode tradisional untuk dataset serupa, sebagaimana dilaporkan dalam studi pemetaan batas wilayah [27]. Selain itu, validasi lapangan awal pada sampel acak (3 kampung) mengonfirmasi kesesuaian model dengan ground truth hingga 95%, meskipun diperlukan survei lebih luas untuk verifikasi penuh. Hasil ini juga menunjukkan bahwa teknologi deep learning memiliki tingkat akurasi yang tinggi dalam melakukan pengenalan pola segmen dan citra [28]. Adapun hasil PPBW dan RBI yang identik pada beberapa kampung (misalnya 99.430% untuk Teluk Dalem Ilir) disebabkan oleh kesamaan sumber data *underlying* di wilayah tersebut, di mana RBI sering mengintegrasikan elemen dari PPBW BIG, sehingga perbedaan karakteristik

minimal dan menghasilkan IoU yang serupa. Namun, pada kampung lain seperti Rukti Basuki (99.132% vs. 99.128%), perbedaan kecil muncul akibat variasi proyeksi koordinat yang tidak sepenuhnya selaras.



Gambar 5. Hasil Persentase Kesesuaian Data PPBW dan RBI dengan Data Kartometrik

Berdasarkan Gambar 5 diagram presentase kesesuaian data PPBW dan data RBI dengan data hasil metode kartometrik. Urutan persentase kesesuaian data batas wilayah kampung dari yang tertinggi ke terendah. ke-1 Kampung Restu Buana 99,999% untuk data PPBW dan RBI, ke-2 Kampung Restu Baru 99,998% untuk data PPBW dan data RBI, ke-3 Kampung Bina Karya Buana 99,997, Ke-4 Kampung Rekso Binangun 99,996% untuk data PPBW dan RBI, ke-5 Kampung Reno Basuki 99,966% untuk data PPBW dan RBI, ke-6 Kampung Bina Karya Putra 99,988% untuk data PPBW dan RBI, ke-7 Kampung Rukti Basuki 99,132% data PPBW dan 99,128% data RBI, ke-8 Kampung Teluk Dalem Ilir 99,430 untuk data PPBW dan RBI, dan yang terakhir ke-9 Kampung Karya Mandiri 94,557 data PPBW dan 94,545% data RBI.

4. KESIMPULAN

Berdasarkan hasil pengujian model CNN, dapat disimpulkan bahwa variasi jumlah *epoch* berpengaruh signifikan terhadap performa model dalam mengenali pola batas wilayah. Kinerja terbaik diperoleh pada pengujian dengan 500 *epoch*, yang menghasilkan nilai *loss* pelatihan terendah sebesar 0.0021 dan *loss* validasi 0.0020. Capaian akurasi pelatihan dan validasi yang menyentuh angka 100% menunjukkan bahwa peningkatan jumlah *epoch* efektif dalam meminimalkan kesalahan prediksi serta meningkatkan kemampuan model dalam mempelajari fitur spasial secara mendalam. Lebih lanjut, model ini terbukti andal dalam mengevaluasi persentase kesesuaian data spasial, di mana data PPBW dan RBI memiliki tingkat kesesuaian rata-rata di atas 90% jika dibandingkan dengan data referensi kartometrik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Institut Teknologi Sumatera (ITERA) atas dukungan fasilitas dan sumber daya yang memungkinkan penelitian ini terlaksana dengan baik. Ucapan terima kasih juga disampaikan kepada Badan Informasi Geospasial yang telah menyediakan data batas wilayah serta kepada seluruh pihak yang telah membantu dalam pengolahan dan analisis data, termasuk kolega di Program Studi Teknik Geomatika, Fakultas Teknologi Infrastruktur dan Kewilayahan, yang memberikan wawasan serta saran berharga dalam pengembangan penelitian ini.

Kami juga mengapresiasi kontribusi rekan-rekan yang terlibat dalam proses pengolahan data spasial, khususnya dalam penerapan metode *Deep Learning* menggunakan arsitektur CNN serta optimalisasi dengan SGD. Tak lupa, kami mengucapkan terima kasih kepada semua pihak yang telah memberikan masukan dalam penyempurnaan naskah ini, termasuk para reviewer dan editor jurnal yang telah meluangkan waktu untuk memberikan umpan balik yang konstruktif.

Penelitian ini diharapkan dapat memberikan kontribusi dalam mendukung implementasi kebijakan Satu Peta dan membantu mengatasi permasalahan tumpang tindih batas wilayah di Kecamatan Rumbia. Semoga hasil penelitian ini dapat menjadi referensi bagi pengembangan teknologi pemetaan berbasis Deep Learning di masa depan.

REFERENSI

- [1] E. Setiawan, A. Maryudi, R. Purwanto, and G. Lele, "Opposing interests in the legalization of non-procedural forest conversion to oil palm in Central Kalimantan, Indonesia," *Land use policy*, vol. 58, pp. 472–481, 2016, doi: 10.1016/J.LANDUSEPOL.2016.08.003.
- [2] A. Sasikumar, M. Sathyanarayanan, A. N. Sriyappan, R. Santhosh, and R. Reshma, "A CNN-based Canny Edge Detection Approach for Car Scratch Detection," in *6th International Conference on*

- Inventive Computation Technologies, ICICT 2023 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 404–409. doi: 10.1109/ICICT57646.2023.10134444.
- [3] M. Bansal, M. Kumar, and M. Kumar, “2D object recognition: a comparative analysis of SIFT, SURF and ORB feature descriptors,” *Multimed Tools Appl*, vol. 80, pp. 18839–18857, 2021, doi: 10.1007/s11042-021-10646-0.
 - [4] A. Maxwell, T. Warner, and L. Guillén, “Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies - Part 2: Recommendations and Best Practices,” *Remote. Sens.*, vol. 13, p. 2591, 2021, doi: 10.3390/rs13132591.
 - [5] S. S. Kusuma, S. Arjasakusuma, R. Rafif, S. Saringatin, P. Wicaksono, and A. A. Aziz, “Assessment of image segmentation and deep learning for mapping paddy fields using Worldview-3 in Magelang, Central Java Provinces, Indonesia,” vol. 12082, p. 1208207, 2021, doi: 10.1117/12.2619502.
 - [6] B. Priambodo, W. Mahmudy, and Muh. A. Rahman, “Earthquake Magnitude and Grid-Based Location Prediction using Backpropagation Neural Network,” *Knowl. Eng. Data Sci.*, vol. 3, pp. 28–39, 2020, doi: 10.17977/um018v3i12020p28-39.
 - [7] C. A. Indriyani, C. R. Wijaya, and N. Qomariyah, “Forecasting COVID-19 Total Daily Cases in Indonesia Using LSTM Networks,” *2022 5th International Conference on Computing and Informatics (ICCI)*, pp. 385–391, 2022, doi: 10.1109/icci54321.2022.9756062.
 - [8] V. Jadeja, A. Srivastava, P. Chaturvedi, and G. Bhardwaj, “Convolutional Neural Networks: A Comprehensive Review of Architectures and Application,” vol. 6, pp. 460–467, 2023, doi: 10.1109/ic3i59117.2023.10397695.
 - [9] C. Y. P. Kiran, and M. P. B., “The Novel Method for Data Preprocessing CLI,” pp. 117–120, 2022, doi: 10.53759/aist/978-9914-9946-1-2_21.
 - [10] A. Ziaee and E. Çano, “Batch Layer Normalization, A new normalization layer for CNNs and RNN,” Sep. 2022, doi: 10.1145/3571560.3571566.
 - [11] P. Barbiero, G. Squillero, and A. Tonda, “Modeling Generalization in Machine Learning: A Methodological and Computational Study,” *arXiv: Learning*, 2020, [Online]. Available: <https://arxiv.org/pdf/2006.15680v1>
 - [12] M. T. Mustapha, I. Ozsahin, and D. U. Ozsahin, “Convolution neural network and deep learning,” Elsevier BV, 2024, pp. 21–50. doi: 10.1016/b978-0-323-95462-4.00002-9.
 - [13] D. Noël and S. Mukherjee, “An Investigation of Methods for Improving Spatial Invariance of Convolutional Neural Networks for Image Classification,” 2023, doi: 10.2139/ssrn.4548826.
 - [14] J. Yu, S. Du, Z. Xin, L. Huang, and J. Zhao, “Application of a convolutional neural network to land use classification based on GF-2 remote sensing imagery,” *Arabian Journal of Geosciences*, vol. 14, no. 21, pp. 1–14, 2021, doi: 10.1007/S12517-021-08555-5.
 - [15] L. Chen *et al.*, “Field Patch Extraction Based on High-Resolution Imaging and U2-Net++ Convolutional Neural Networks,” *Remote Sens (Basel)*, 2023, doi: 10.3390/rs15204900.
 - [16] Monica and P. Agrawal, “A Survey on Hyperparameter Optimization of Machine Learning Models,” pp. 11–15, 2024, doi: 10.1109/icdt61202.2024.10489732.
 - [17] R. Waghmare and N. Safika, “Geo-Spatial Data Analysis for Disaster Impact Forecasting,” *International Journal For Multidisciplinary Research*, vol. 7, no. 3, 2025, doi: 10.36948/ijfmr.2025.v07i03.44274.
 - [18] E. Sahragard, H. Farsi, and S. Mohamadzadeh, “Semantic Segmentation of Aerial Imagery: A Novel Approach Leveraging Hierarchical Multi-scale Features and Channel-based Attention for Drone Applications,” *International journal of engineering. Transactions B: Applications*, vol. 37, no. 5, pp. 1022–1035, 2024, doi: 10.5829/ije.2024.37.05b.18.
 - [19] A. Zohrevand and Z. Imani, “An Empirical Study of the Performance of Different Optimizers in the Deep Neural Networks,” *Iranian Conference on Machine Vision and Image Processing*, pp. 1–5, 2022, doi: 10.1109/MVIP53647.2022.9738743.
 - [20] S. Ahmad, G. Trahan, and A. Islam, “When do Convolutional Neural Networks Stop Learning?,” *arXiv.org*, vol. abs/2403.02473, 2024, doi: 10.48550/arxiv.2403.02473.
 - [21] J. M. Cohen *et al.*, “Adaptive Gradient Methods at the Edge of Stability,” *arXiv.org*, vol. abs/2207.14484, 2022, doi: 10.48550/arXiv.2207.14484.
 - [22] B. Wang and Q. Ye, “Improving Deep Neural Networks’ Training for Image Classification With Nonlinear Conjugate Gradient-Style Adaptive Momentum,” *IEEE Trans Neural Netw Learn Syst*, vol. PP, pp. 1–13, 2023, doi: 10.1109/tnnls.2023.3255783.
 - [23] M. Owusu-Adjei, T. Frimpong, and G. Abdul-Salaam, “A systematic review of prediction accuracy as an evaluation measure for determining machine learning model performance in healthcare systems,” *medRxiv*, 2023, doi: 10.1101/2023.06.01.23290837.
 - [24] B. Cheng, R. Girshick, P. Dollár, A. C. Berg, and A. Kirillov, “Boundary IoU: Improving Object-Centric Image Segmentation Evaluation,” *Computer Vision and Pattern Recognition*, pp. 15334–15342, 2021, doi: 10.1109/CVPR46437.2021.01508.

- [25] A. Eka, P. Wicaksono, and R. Mahendra, "Utilization of Generative Pre-trained Transformer Model for Automatic Evaluation and Feedback on Scientific Manuscripts," *Jurnal Media Computer Science*, vol. 4, no. 2, pp. 227–236, 2025, doi: 10.37676/jmcs.v4i2.
- [26] K. Prasetyo and R. Mahendra, "Analisis Kinerja Convolutional Neural Networks Baseline untuk Identifikasi Jenis Jenis Penyakit Kentang," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 2, pp. 609–615, Mar. 2025, doi: 10.57152/malcom.v5i2.1722.
- [27] F. Furizal, A. Ma'arif, D. Rifaldi, and A. A. Firdaus, "Comparison of Convolutional Neural Networks and Support Vector Machines on Medical Data: A Review," *International Journal of Robotics and Control Systems*, 2024, doi: 10.31763/ijrcs.v4i1.1375.
- [28] Q. Qiao, "Image Processing Technology Based on Machine Learning," *IEEE Consumer Electronics Magazine*, p. 1, 2022, doi: 10.1109/mce.2022.3150659.