

# Analisis Struktur Tulisan Tangan melalui Deteksi Zona Spasi Antarkata menggunakan Convolutional Neural Network Mendalam

Nabilah Mufti<sup>a</sup>, Rudi Heriansyah<sup>b</sup>, Muhammad Haviz Irfani<sup>c\*</sup>

<sup>a,b,c</sup>Universitas Indo Global Mandiri, Indonesia

\*correspondence email : [m.haviz@uigm.ac.id](mailto:m.haviz@uigm.ac.id)

**Abstract**—Advances in image processing and deep learning technology enable more accurate handwriting analysis, including the detection of interword spacing, which exhibits high complexity due to variations in writing styles. This study aims to implement a Convolutional Neural Network (CNN) algorithm using the You Only Look Once version 11 (YOLOv11) framework to detect and classify interword spacing zones into three classes: Narrow Word Spacing (NWS), Medium Word Spacing (MWS), and Wide Word Spacing (WWS). The dataset comprises 150 handwritten images with a total of 4.117 annotated interword spacing objects. The research methodology involves testing the model across variations of learning rates (0.1, 0.01, 0.001, and 0.0001) and data split ratios (70:30, 80:20, and 90:10). Model performance was evaluated using Precision, Recall, F1-Score, and mean Average Precision (mAP) metrics. Based on 12 experimental trials, the best configuration was achieved with a learning rate of 0.001 and a 90:10 data split. This configuration produced an mAP@50 of 0.455, an mAP@50–95 of 0.261, and an F1-Score of 0.49. These results indicate that the YOLOv11 model is capable of detecting interword spacing zones with reasonably good performance, despite remaining classification errors due to visual similarities between classes.

**Index Terms**— Interword spacing; Handwriting; CNN; Learning rate; Split data; YOLOv11.

**Abstrak**—Perkembangan teknologi pengolahan citra dan deep learning memungkinkan analisis tulisan tangan dilakukan secara lebih akurat, termasuk dalam mendeteksi jarak spasi antarkata yang kompleks akibat variasi gaya tulisan. Penelitian ini bertujuan menerapkan algoritma Convolutional Neural Network (CNN) menggunakan framework You Only Look Once versi 11 (YOLOv11) untuk mendeteksi dan mengklasifikasikan zona spasi antarkata ke dalam tiga kelas: Narrow Word Spacing (NWS), Medium Word Spacing (MWS), dan Wide Word Spacing (WWS). Dataset yang digunakan terdiri dari 150 citra tulisan tangan dengan total 4.117 objek terannotasi. Metodologi penelitian melibatkan pengujian model dengan variasi learning rate (0,1; 0,01; 0,001; dan 0,0001) serta variasi pembagian data (split data) dengan rasio 70:30, 80:20, dan 90:10. Evaluasi dilakukan menggunakan metrik Precision, Recall, F1-Score, serta mean Average Precision (mAP). Berdasarkan 12 percobaan, konfigurasi terbaik diperoleh pada learning rate 0,001 dengan split data 90:10, yang menghasilkan nilai mAP@50 sebesar 0,455, mAP@50–95 sebesar 0,261, dan F1-Score sebesar 0,49. Hasil ini menunjukkan bahwa YOLOv11 mampu mendeteksi zona spasi antarkata dengan performa cukup baik, meskipun terdapat tantangan pada kemiripan pola visual antar kelas.

**Kata Kunci**— Spasi antarkata; Tulisan tangan; CNN; Learning rate; Split data; YOLOv11.

## I. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan saat ini semakin mendorong otomatisasi dalam berbagai bidang, termasuk pengolahan tulisan tangan (*handwriting analysis*) yang menjadi bagian dari *pattern recognition* dan *computer vision* [1]. Proses digitalisasi tulisan tangan diperlukan dalam berbagai konteks seperti administrasi pendidikan, sistem input formulir, serta analisis psikologi dokumenter [2]. Penelitian terbaru menunjukkan bahwa tulisan tangan menyimpan struktur pola visual yang dapat dianalisis oleh komputer melalui pendekatan komputasi seperti ekstraksi fitur citra dan pembelajaran mesin [3].

Namun, pengolahan tulisan tangan memiliki tantangan tersendiri karena karakteristik tulisan manusia sangat bervariasi, baik dari bentuk huruf hingga konsistensi spasi antarkata [1]. Salah satu permasalahan penting yang masih kurang dieksplorasi adalah deteksi spasi antarkata yang memengaruhi keberhasilan segmentasi kata sebelum masuk ke proses pengenalan teks [3]. Selain itu, dalam analisis kepribadian berbasis tulisan tangan, spasi antarkata juga memiliki makna psikologis tertentu karena mencerminkan pola berpikir serta kecenderungan hubungan sosial penulis [4].

Metode konvensional seperti *thresholding* memiliki keterbatasan dalam menghadapi kualitas citra yang bervariasi, sehingga sering menghasilkan segmentasi yang kurang optimal [5]. Seiring perkembangan *deep learning*, *Convolutional Neural Network* (CNN) mulai banyak digunakan karena kemampuannya mengekstraksi fitur spasial secara otomatis [6]. Studi terbaru menyebutkan bahwa YOLOv11 memiliki peningkatan signifikan dalam akurasi deteksi objek kecil dan kompleks dibanding versi sebelumnya [7]. Penggabungan CNN dan YOLOv11 dianggap sebagai pendekatan adaptif untuk meningkatkan akurasi deteksi pada area kecil seperti spasi antarkata.

Penelitian terdahulu oleh Rahmanda dan Irfani (2025) menunjukkan bahwa YOLOv11 memberikan hasil deteksi paling optimal untuk spasi antar baris dibanding versi sebelumnya. Selain itu, penggunaan YOLO dalam deteksi tulisan tangan telah terbukti efektif dalam konteks pendidikan, seperti deteksi huruf Hijaiyah [8]. Berdasarkan keberhasilan tersebut, penelitian ini memanfaatkan YOLOv11 yang dirancang dengan arsitektur *backbone* lebih efisien dan mekanisme *feature aggregation* yang lebih adaptif untuk mengisi celah penelitian pada aspek deteksi spasi antarkata.

Rumusan masalah dalam penelitian ini berfokus pada bagaimana pengaruh variasi *learning rate* dan *split data* terhadap performa deteksi spasi antarkata menggunakan metode CNN berbasis YOLOv11. Penelitian ini dibatasi pada tulisan tangan bahasa Indonesia oleh mahasiswa tingkat awal dengan klasifikasi zona NWS, MWS, dan WWS. Metodologi yang digunakan meliputi akuisisi data, *preprocessing* (binarisasi *Otsu*), anotasi, hingga evaluasi menggunakan metrik *precision*, *recall*, *F1-score*, dan *mean Average Precision* (mAP).

## II. TINJAUAN PUSTAKA

Tulisan tangan merupakan hasil koordinasi kompleks antara sistem saraf pusat dan keterampilan motorik halus yang menghasilkan pola unik pada setiap individu, seperti variasi bentuk huruf, tekanan, dan spasi [9]. Karakteristik unik ini dapat dianalisis sebagai fitur visual terstruktur yang diolah menggunakan pendekatan komputasional dalam bentuk citra digital [6]. Dalam analisis tulisan tangan, spasi antarkata menjadi salah satu aspek penting yang menunjukkan keteraturan struktur tulisan dan memiliki makna psikologis tertentu [4].

Analisis tulisan tangan secara digital melibatkan pengolahan citra untuk mengubah dokumen fisik menjadi data yang dapat diproses komputer melalui tahapan *preprocessing* seperti *grayscale*, *noise removal*, dan binarisasi [1]. Salah satu teknik binarisasi yang efektif adalah metode *Otsu*, yang bekerja dengan mencari nilai ambang optimal untuk memisahkan objek dari latar belakang berdasarkan distribusi intensitas piksel [5], [10]. Proses ini krusial untuk memastikan fitur spasial seperti jarak antarkata dapat dideteksi dengan jelas tanpa gangguan derau.

Implementasi kecerdasan buatan dalam deteksi tulisan tangan kini didominasi oleh *Convolutional Neural Network* (CNN), sebuah arsitektur *deep learning* yang dirancang untuk memproses data spasial [6]. CNN mampu melakukan ekstraksi fitur secara otomatis melalui lapisan konvolusi, *pooling*, dan *fully connected layer*, yang memungkinkan model mengenali pola rumit pada tulisan tangan tanpa perlu ekstraksi fitur manual. Kemampuan ini sangat relevan untuk mengidentifikasi area kosong atau spasi yang seringkali memiliki batas yang tidak tegas.

*Framework* yang digunakan dalam penelitian ini adalah YOLO (*You Only Look Once*), sebuah algoritma deteksi objek *real-time* yang memperlakukan deteksi sebagai masalah regresi tunggal [11], [12]. YOLO bekerja dengan membagi citra ke dalam kisi-kisi dan memprediksi *bounding box* serta probabilitas kelas secara bersamaan, sehingga menawarkan kecepatan dan efisiensi yang tinggi. Versi terbaru, YOLOv11, membawa peningkatan pada struktur *backbone* dan *neck* yang lebih efisien untuk menangani objek dengan berbagai skala, termasuk objek kecil seperti spasi antarkata.

Eksperimen model YOLO sangat dipengaruhi oleh pengaturan *hyperparameter*, salah satunya adalah *learning rate* yang mengontrol kecepatan penyesuaian bobot model selama proses pelatihan [1]. Selain itu, pembagian data (*split data*) menjadi *training set* dan *validation set* menjadi faktor penentu stabilitas model. Rasio pembagian data yang tepat memastikan model memiliki representasi fitur yang cukup untuk belajar sekaligus mampu melakukan generalisasi pada data baru yang belum pernah dilihat sebelumnya.

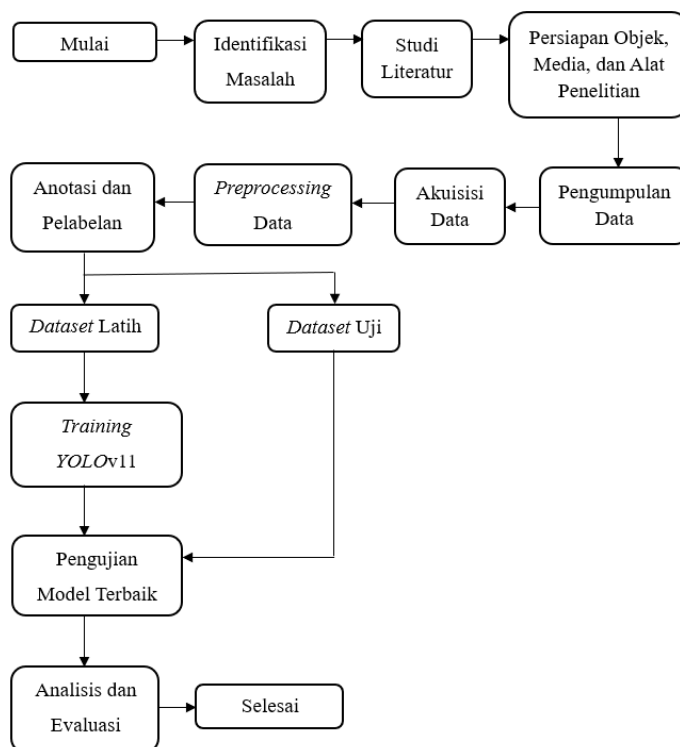
Evaluasi performa model deteksi dilakukan menggunakan metrik standar seperti *Precision*, *Recall*, dan *F1-Score* untuk mengukur akurasi dan kelengkapan prediksi. Selain itu, *mean Average Precision* (mAP) digunakan sebagai metrik utama untuk mengevaluasi kualitas *bounding box* pada berbagai ambang batas *Intersection over Union* (IoU). Penggunaan metrik ini memberikan gambaran komprehensif mengenai kemampuan model dalam mengklasifikasikan kategori spasi *Narrow*, *Medium*, dan *Wide* secara presisi.

Kajian penelitian terdahulu menunjukkan bahwa meskipun deteksi tulisan tangan telah banyak dipelajari, sebagian besar studi masih berfokus pada pengenalan karakter atau spasi antarbaris [7]. Penelitian mengenai deteksi spasi antarkata menggunakan YOLOv11 masih relatif terbatas. Oleh karena itu, penelitian ini mengisi celah tersebut dengan mengoptimalkan konfigurasi *learning rate* dan pembagian data untuk meningkatkan akurasi deteksi fitur spasial pada tulisan tangan [13].

### III. METODE

#### A. Akuisisi Data dan Pra-pemrosesan

Penelitian ini diawali dengan persiapan objek menggunakan kertas A4 80 gsm dan pulpen Faber-Castell 0,7 mm untuk menjaga konsistensi ketebalan goresan tulisan. Responden terdiri dari mahasiswa tingkat awal Universitas Indo Global Mandiri yang menulis ulang teks acuan dalam bahasa Indonesia di bawah pencahayaan lampu TL 36 watt. Data fisik kemudian dikonversi menjadi citra digital melalui proses pemindaian menggunakan scanner Epson L3110 dengan resolusi 400 dpi dalam format PNG. Tahap pra-pemrosesan dilakukan untuk meningkatkan kualitas input model, meliputi konversi ke grayscale, penghilangan derau (noise removal) menggunakan Gaussian Blur dan Median Filtering, serta binarisasi citra menggunakan metode Otsu Thresholding [5], [14]. Adapun alur pemikiran dalam penelitian ini disusun secara sistematis untuk menjawab permasalahan deteksi spasi antarkata, yang secara visual digambarkan pada Gambar 1.

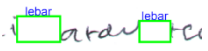




Gambar 1. Kerangka Kerja Penelitian

#### B. Anotasi Objek dan Klasifikasi Spasi

Anotasi area spasi antarkata dilakukan secara manual menggunakan format bounding box. Berdasarkan perhitungan lebar spasi (*space width*) melalui bantuan skrip MATLAB, setiap area diklasifikasikan ke dalam tiga kelas: *Narrow Word Spacing* (NWS) dengan lebar  $\leq 25$  px, *Medium Word Spacing* (MWS) dengan lebar 28–38 px, dan *Wide Word Spacing* (WWS) dengan lebar  $\geq 43$  px. Penelitian ini menerapkan skema pengujian dengan memvariasikan rasio pembagian data (split data), yaitu 70:30, 80:20, dan 90:10, guna menganalisis stabilitas model terhadap volume data latih yang berbeda. Tabel 1 berikut menampilkan contoh hasil parameter rasio klasifikasi spasi antarkata pada tulisan tangan.

Tabel 1. Contoh Hasil Parameter Rasio Klasifikasi Spasi Antarkata

No	Gambar	Aturan Parameter	Kelas
1.		$\geq 43$ piksel	WWS
2.		28–38 piksel	MWS
3.		$space\ width \leq 25$ piksel	NWS

### C. Pelatihan Model

Pelatihan model dilakukan menggunakan framework YOLOv11 yang dijalankan pada lingkungan Google Colab dengan akselerasi GPU. Arsitektur YOLOv11 dipilih karena keunggulannya dalam mendeteksi objek kecil melalui mekanisme feature aggregation yang adaptif (Rahmanda dan Irfani, 2025). Proses pelatihan dilakukan sebanyak 100 epoch dengan variasi learning rate antara 0,1 hingga 0,0001 untuk menemukan titik konvergensi yang optimal. Performa model dievaluasi secara kuantitatif menggunakan metrik Precision, Recall, F1-Score, dan mean Average Precision (mAP@50), serta secara kualitatif melalui analisis confusion matrix untuk melihat akurasi klasifikasi antarkelas spasi. Adapun rincian jumlah objek perkelas yang digunakan dalam pelatihan model disajikan pada Tabel 2.

Tabel 2. Rincian Jumlah Objek Per kelas

Kelas	Jumlah Objek
NWS	1440
MWS	1365
WWS	1312
<b>Total Objek</b>	<b>4117</b>

### D. Skenario Pengujian dan Evaluasi

Pengujian dilakukan melalui pendekatan eksperimental dengan 12 skenario percobaan untuk menjawab rumusan masalah. Parameter yang divariasikan meliputi *learning rate* (0,1; 0,01; 0,001; dan 0,0001) serta rasio pembagian data (*split data*) 70:30, 80:20, dan 90:10. Performa model dievaluasi menggunakan metrik standar visi komputer, yaitu *Precision*, *Recall*, *F1-Score*, dan *mean Average Precision* (mAP@50). Selain itu, pengujian kualitatif dilakukan menggunakan *confusion matrix* untuk menganalisis tingkat akurasi prediksi model terhadap data uji yang belum pernah dilihat sebelumnya.

## IV. HASIL DAN PEMBAHASAN

### A. Hasil Eksperimen dan Performa Model

Penelitian ini menggunakan *dataset* yang terdiri dari 150 citra tulisan tangan mahasiswa dengan total 2.677 objek zona spasi yang telah dianotasi secara manual. Eksperimen dirancang melalui 12 skenario pengujian yang mengombinasikan dua parameter krusial: *lr* dengan nilai 0,1; 0,01; 0,001; dan 0,0001, serta variasi rasio pembagian data (*split data*) 70:30, 80:20, dan 90:10. Berdasarkan pemantauan selama 100 *epoch*, performa model menunjukkan fluktuasi yang signifikan; nilai *lr* yang terlalu tinggi (0,1) menyebabkan *loss* tidak stabil dan gagal konvergen, sementara LR yang terlalu rendah (0,0001) membuat proses belajar berjalan sangat lambat. Hasil keseluruhan percobaan dapat dilihat pada Tabel 3.

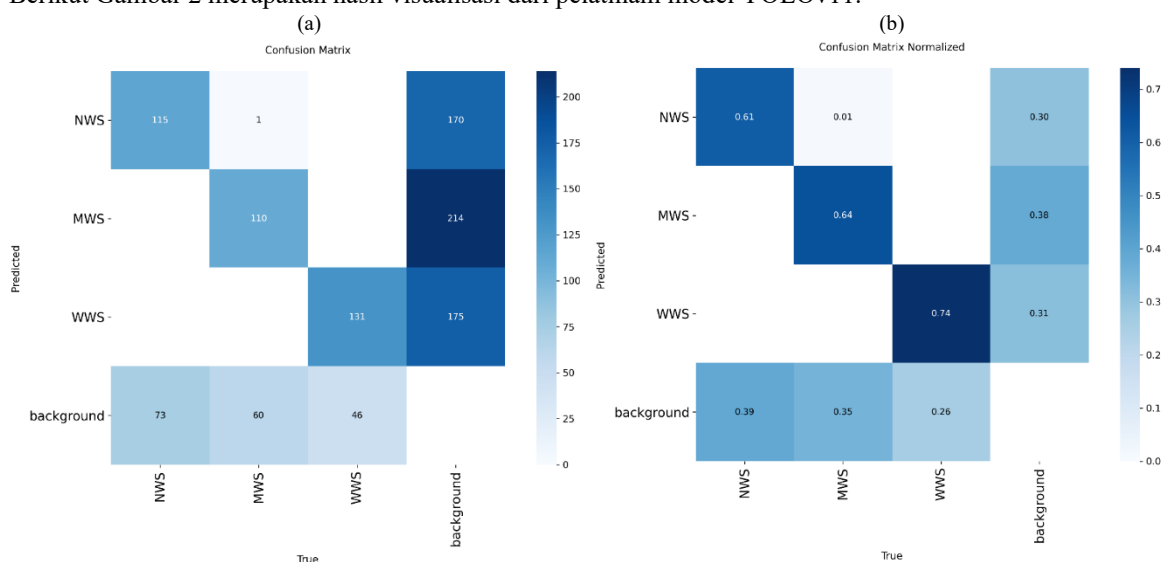
Konfigurasi paling optimal ditemukan pada Percobaan ke-9 dengan *learning rate* 0,001 dan rasio *split data* 90:10, di mana model menunjukkan grafik *loss* yang menurun konsisten pada tahap *training* maupun *validation* tanpa indikasi *overfitting* yang ekstrem. Penggunaan *learning rate* 0,001 memberikan langkah pembaruan bobot yang presisi bagi algoritma AdamW dalam menemukan titik minimum global tanpa fenomena *overshooting*, sementara alokasi 90% data latih memungkinkan model terpapar pada lebih banyak variasi karakteristik tulisan tangan seperti perbedaan ketebalan tinta dan kemiringan huruf sehingga mampu membentuk fitur representatif yang lebih kuat guna meningkatkan nilai mAP@50 dan *F1-Score* dalam menggeneralisasi zona spasi yang abstrak.

Tabel 3. Hasil Pelatihan Model YOLOv11 Menggunakan Variasi Split Data dan Nilai Lr

No	Learning Rate	Split Data	Precision	Recall	mAP @50	mAP @50-95	F1-Score
1	0,1	70:30	0,334	0,26	0,204	0,126	0,21
2	0,1	80:20	0,263	0,28	0,231	0,145	0,18
3	0,1	90:10	0,301	0,29	0,290	0,136	0,22
4	0,01	70:30	0,290	0,08	0,342	0,196	0,12
5	0,01	80:20	0,498	0,54	0,308	0,225	0,41
6	0,01	90:10	0,410	0,69	0,428	0,238	0,49
7	0,001	70:30	0,825	0,52	0,289	0,232	0,38
8	0,001	80:20	0,727	0,49	0,315	0,233	0,40
<b>9</b>	<b>0,001</b>	<b>90:10</b>	<b>0,580</b>	<b>0,66</b>	<b>0,455</b>	<b>0,261</b>	<b>0,49</b>
10	0,0001	70:30	0,752	0,11	0,276	0,077	0,13
11	0,0001	80:20	0,568	0,19	0,267	0,079	0,13
12	0,0001	90:10	0,722	0,33	0,283	0,163	0,29

### B. Analisis Klasifikasi dan Visualisasi

Evaluasi klasifikasi dilakukan menggunakan *confusion matrix* untuk melihat interaksi prediksi antar kelas: *Narrow Word Spacing* (NWS), *Medium Word Spacing* (MWS), dan *Wide Word Spacing* (WWS). Berikut Gambar 2 merupakan hasil visualisasi dari pelatihan model YOLOv11.



Gambar 2. Hasil Pada Percobaan ke-9: (a) Coofusion Matrix (b) Confusion Matrix Normalized

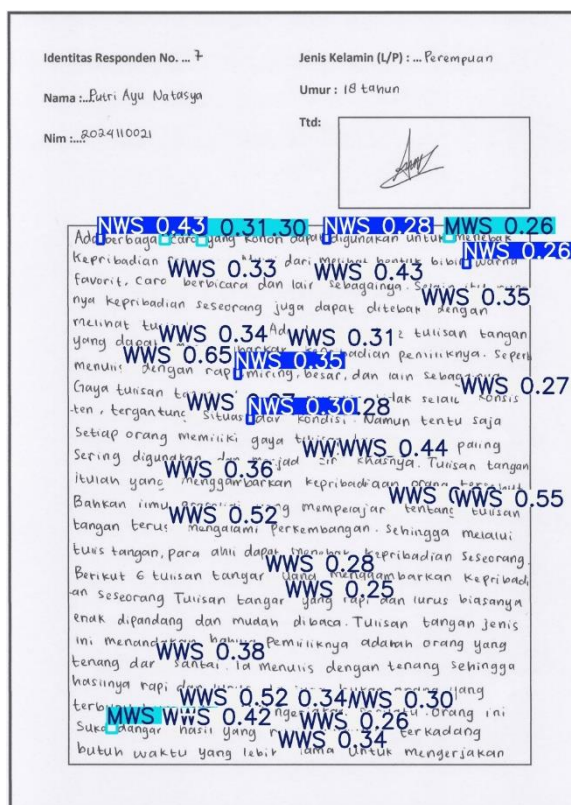
Hasil analisis menunjukkan bahwa model memiliki akurasi yang tinggi dalam mendeteksi kelas NWS dan WWS. Namun, kelas MWS seringkali mengalami *misclassification*, di mana objek tersebut terdeteksi sebagai NWS atau dianggap sebagai latar belakang (*background*). Hal ini disebabkan oleh ambang batas visual yang sangat tipis antara jarak spasi sedang dan sempit dalam tulisan tangan asli. Meski demikian, secara visual, *bounding box* yang dihasilkan oleh YOLOv11 mampu melokalisasi zona spasi dengan presisi spasial yang baik.

### C. Pengujian Model YOLOv11

Tahap pengujian dilakukan untuk mengevaluasi kemampuan generalisasi model terbaik (Percobaan ke-9: *learning rate* 0,001; *split data* 90:10) menggunakan data uji yang tidak terlibat dalam proses pelatihan maupun validasi. Data uji terdiri atas 15 citra tulisan tangan dengan total 536 objek spasi antarkata yang terdistribusi ke dalam kelas NWS (188 objek), MWS (171 objek), dan WWS (177 objek). Pengujian dilakukan menggunakan fungsi *validation* pada *framework* YOLOv11 untuk menghasilkan metrik evaluasi komprehensif.

Tabel 4. Hasil Pengujian Model menggunakan Data Uji

Kelas	Jumlah Objek	Precision	Recall	mAP@50	mAP@50-95
NWS	188	0,638	0,319	0,468	0,252
MWS	171	0,556	0,177	0,326	0,205
WWS	177	0,642	0,345	0,463	0,310
<b>Total/Rata-rata</b>	<b>536</b>	<b>0,612</b>	<b>0,260</b>	<b>0,419</b>	<b>0,256</b>



Gambar 3. Salah Satu Contoh Hasil Pengujian Model pada Data Uji

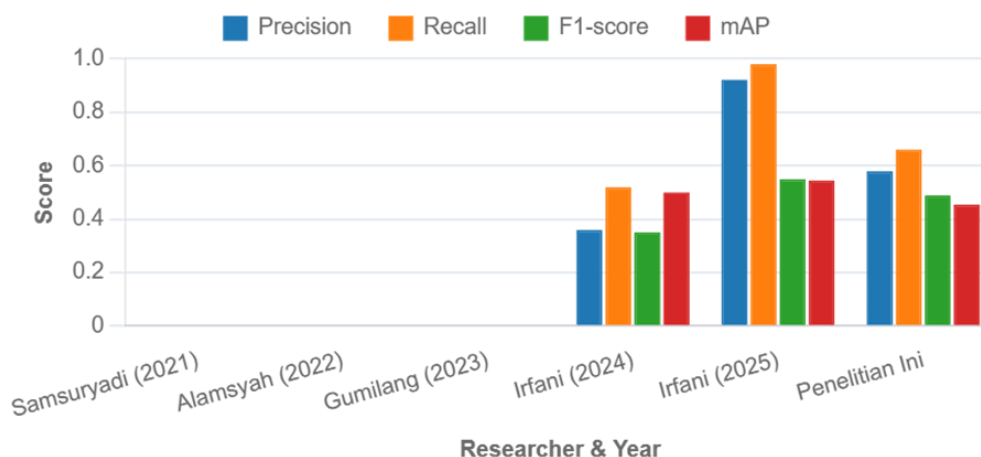
Hasil pengujian secara kuantitatif menunjukkan nilai rata-rata *Precision* sebesar 0,612, *Recall* 0,260, *mAP@50* sebesar 0,419, dan *mAP@50-95* sebesar 0,256. Secara rinci, model memberikan performa deteksi paling stabil pada kelas WWS dengan *Precision* tertinggi sebesar 0,642, disusul kelas NWS sebesar 0,638. Kelas MWS menunjukkan tingkat kesulitan deteksi paling tinggi dengan nilai *Recall* terendah (0,177), yang mengindikasikan banyaknya objek pada kelas ini yang luput dari deteksi model.

Berdasarkan analisis *confusion matrix*, model mampu mengenali objek pada diagonal matriks dengan cukup baik, terutama untuk kelas NWS dan WWS. Namun, terdapat kecenderungan di mana sejumlah objek spasi salah diklasifikasikan sebagai *background*, atau sebaliknya. Hal ini menunjukkan bahwa batas visual antara zona spasi kosong dan area non-objek (seperti tepian huruf atau derau pada kertas) masih memiliki kemiripan fitur yang tinggi. Meskipun demikian, secara kualitatif, visualisasi *bounding box* hasil prediksi menunjukkan bahwa YOLOv11 secara konsisten mampu melokalisasi area spasi antarkata pada berbagai variasi karakteristik tulisan tangan mahasiswa. Secara keseluruhan, hasil ini membuktikan bahwa konfigurasi model yang dipilih memiliki kemampuan deteksi yang cukup baik dan relevan untuk digunakan dalam analisis struktur tulisan tangan.

C. Perbandingan dengan Penelitian Terdahulu

Hasil penelitian ini menunjukkan bahwa performa YOLOv11 pada konfigurasi terbaik (Percobaan ke-9) memberikan capaian yang kompetitif dibandingkan studi-studi terdahulu yang berfokus pada deteksi fitur tulisan tangan. Berdasarkan metrik *Recall*, penelitian ini mencapai nilai 0,66 (66%), melampaui hasil penelitian Irfani dkk. (2024) yang menggunakan YOLOv8 dengan *Recall* sebesar 0,52 (52%). Meskipun penelitian Irfani dkk. (2025) mencatatkan *Recall* sangat tinggi sebesar 0,98, nilai *F1-Score* yang rendah

(0,55) mengindikasikan ketidakseimbangan performa akibat tingginya angka *false positives*. Sebaliknya, penelitian ini menawarkan keseimbangan yang lebih stabil dengan nilai  $mAP@50$  sebesar 0,455, yang merupakan salah satu capaian terbaik dalam kelompok metode berbasis YOLO yang dibandingkan.



Gambar 4. Grafik Perbandingan Penelitian

Perbandingan komprehensif metrik evaluasi disajikan pada Gambar 4. Berbeda dengan pendekatan CNN tradisional untuk klasifikasi citra seperti pada penelitian Samsuryadi dkk. (2021) [3] Alamsyah dkk. (2022) [2] dan Gumilang dkk. (2023) [15] yang tidak menyertakan metrik deteksi objek secara lengkap, penggunaan YOLOv11 dalam studi ini terbukti lebih unggul dalam memetakan fitur spasial seperti spasi antarkata secara presisi. Hal ini menegaskan bahwa konfigurasi *learning rate* dan skema anotasi yang diterapkan mampu meningkatkan kualitas deteksi sekaligus memberikan kontribusi signifikan terhadap pengembangan sistem analisis tulisan tangan yang lebih adaptif.

## V. SIMPULAN

Metode CNN dengan framework YOLOv11 terbukti efektif dalam mendeteksi dan mengklasifikasikan tiga jenis spasi antarkata (Narrow, Medium, Wide) melalui alur kerja yang sistematis. Berdasarkan eksperimen, variasi learning rate dan rasio pembagian data sangat memengaruhi stabilitas model, di mana konfigurasi paling optimal ditemukan pada learning rate 0,001 dengan rasio data 90:10 (Percobaan ke-9). Hasil ini menjawab rumusan masalah dengan raihan  $mAP@50$  sebesar 0,455 dan F1-Score 0,49, yang menunjukkan bahwa volume data latih yang maksimal serta laju pembelajaran yang tepat krusial dalam menangani variasi gaya tulisan tangan pada dataset terbatas.

Untuk pengembangan selanjutnya, disarankan agar dilakukan peningkatan jumlah dan variasi gaya tulisan pada dataset serta penyempurnaan konsistensi anotasi bounding box agar model dapat belajar lebih representatif. Selain itu, eksplorasi parameter pelatihan seperti variasi ukuran citra dan penggunaan arsitektur YOLO dengan skala lebih besar perlu dilakukan untuk meningkatkan akurasi pada objek berukuran kecil. Pengembangan sistem ini diharapkan dapat diintegrasikan ke dalam aplikasi analisis tulisan tangan otomatis sehingga dapat diterapkan secara langsung dalam bidang pendidikan maupun analisis dokumen digital.

## VI. DAFTAR PUSTAKA

- [1] O. Sudana, I. W. Gunaya, And I. K. G. Darma Putra, "Handwriting Identification Using Deep Convolutional Neural Network Method," *Telkomnika (Telecommunication Computing Electronics And Control)*, Vol. 18, No. 4, Pp. 1934–1942, Aug. 2020, Doi: 10.12928/Telkomnika.V18i4.14864.
- [2] D. Alamsyah, Samsuryadi, W. Widhiarso, And S. Hasan, "Handwriting Analysis For Personality Trait Features Identification Using Cnn," In *2022 International Conference On Data Science And Its Applications (Icodsa)*, Ieee, Jul. 2022, Pp. 232–238. Doi: 10.1109/Icodsa55874.2022.9862910.
- [3] S. Samsuryadi, R. Kurniawan, And F. Susilawati Mohamad, "Automated Handwriting Analysis Based On Pattern Recognition: A Survey," *Indonesian Journal Of Electrical Engineering And Computer Science*, Vol. 22, No. 1, Pp. 196–206, Apr. 2021, Doi: 10.11591/Ijeecs.V22.I1.Pp196-206.

- [4] K. K. Amend And M. S. Ruiz, *Handwriting Analysis: The Complete Basic Book*, 2020th Ed. Canada: Rww New Page Books, 2020. [Online]. Available: <https://books.google.co.id/books?id=Utr8dwaaqbaj>
- [5] M. H. Irfani And G. Gasim, "Segmentasi Teks Pada Citra Tulisan Tangan Kalimat Menggunakan Metode Median Filtering Dan Otsu," *Teknosains: Media Informasi Sains Dan Teknologi*, Vol. 18, No. 1, Pp. 88–97, Apr. 2024, Doi: 10.24252/Teknosains.V18i1.44307.
- [6] M. A. Liman, A. Josef, And G. P. Kusuma, "Handwritten Character Recognition Using Deep Learning Algorithm With Machine Learning Classifier," *Joiv: International Journal On Informatics Visualization*, Vol. 8, No. 1, Pp. 150–157, Mar. 2024, Doi: 10.62527/Joiv.8.1.1707.
- [7] M. A. Rahmanda And M. H. Irfani, "Deteksi Jarak Spasi Antar Baris Tulisan Tangan Menggunakan Metode Convolutional Neural Network (Cnn) Dengan Framework Yolo," Universitas Indo Global Mandiri, Palembang, 2025.
- [8] H. Mustagfiroh, A. Yuniar Rahman, And R. Pahlevi Putra, "Detection Of Hijaiyah Letters Handwritten In Early Childhood Using Yolov8," *Buana Information Technology And Computer Sciences (Bit And Cs)*, Vol. 6, No. 2, Pp. 92–99, Jul. 2025, Doi: 10.36805/Bitcs.V6i2.10202.
- [9] S. Vinci-Booher And K. H. James, "Protracted Neural Development Of Dorsal Motor Systems During Handwriting And The Relation To Early Literacy Skills," *Front. Psychol.*, Vol. 12, Nov. 2021, Doi: 10.3389/fpsyg.2021.750559.
- [10] M. H. Irfani, Samsuryadi, Abdiansah, And R. Heriansyah, "Hyperparameter Tuning To Improve Object Detection Performance In Handwritten Images," In *2024 International Conference On Intelligent Cybernetics Technology & Applications (Icicyta)*, Ieee, Dec. 2024, Pp. 990–995. Doi: 10.1109/Icicyta64807.2024.10913390.
- [11] Y. B. Gregorius, H. Afrisal, And A. Sofwan, "Perancangan Sistem Deteksi Objek Berbasis Convolutional Neural Network Menggunakan Yolov4 Dan Opencv," *Jurnal Ilmiah Teknik Elektro*, Vol. 11, No. 4, Pp. 2685–0206, Dec. 2022, Doi: <https://doi.org/10.14710>.
- [12] Ultralytics Yolo Docs, "Ultralytics Yolo11," Ultralytics.
- [13] M. H. Irfani, Samsuryadi, Abdiansah, And R. Heriansyah, "Accurate Detection Of Handwriting Features Using Bounding Box Optimization," *Ingénierie Des Systèmes D Information*, Vol. 30, No. 9, Pp. 2499–2509, Sep. 2025, Doi: 10.18280/Isi.300923.
- [14] S. I. Syafi'i, R. T. Wahyuningrum, And A. Muntasa, "Segmentasi Obyek Pada Citra Digital Menggunakan Metode Otsu Thresholding," *Jurnal Informatika*, Vol. 13, No. 1, Pp. 1–8, Feb. 2016, Doi: 10.9744/Informatika.13.1.1-8.
- [15] M. S. Gumilang And D. Avianto, "Recognition Of Real-Time Handwritten Characters Using Convolutional Neural Network Architecture," *Jurnal Teknik Informatika (Jutif)*, Vol. 4, No. 5, Pp. 1143–1150, Oct. 2023, Doi: 10.52436/1.Jutif.2023.4.5.993.