

Analisis Performa Model TrOCR dalam mengenali Tulisan Tangan pada Catatan Transaksi Manual

^{1*}Ahmad Maulana, ²Daniel Swanjaya, ³Resty Wulanningrum

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹molanaahmad011@gmail.com, ²daniel@unpkediri.ac.id, ³restyw@unpkdr.ac.id

Penulis Korespondensi : Ahmad Maulana

Abstrak— Pencatatan transaksi secara manual pada usaha kecil seringkali menghadapi kendala dalam kecepatan pencarian data dan akurasi input digital. Penelitian ini bertujuan untuk menganalisis performa model TrOCR (*Transformer-based Optical Character Recognition*) dalam mendigitalisasi tulisan tangan pada catatan transaksi manual. Metode eksperimen dilakukan melalui proses *fine-tuning* pada model *pretrained* microsoft/tocr-base-handwritten dengan dataset sebanyak 666 citra yang telah melalui tahapan *preprocessing* seperti *resize*, *augmentasi*, *grayscale*, dan *adaptive threshold*. Evaluasi model dilakukan menggunakan metode *5-Fold Cross Validation* dengan metrik *Character Error Rate* (CER) dan *Word Error Rate* (WER). Hasil penelitian menunjukkan bahwa model mampu mengenali tulisan tangan dengan sangat baik, di mana performa terbaik dicapai pada *Fold 3* dengan nilai CER 2,71%, WER 12,42%, dan akurasi karakter sebesar 97,29%. Temuan ini mengindikasikan bahwa model TrOCR memiliki potensi besar untuk diimplementasikan dalam sistem otomatisasi administrasi transaksi berbasis tulisan tangan.

Kata Kunci— Adaptive Threshold, Catatan Transaksi, Deep Learning, TrOCR, Tulisan Tangan.

Abstract— *Manual transaction recording in small businesses often faces challenges related to data retrieval speed and the accuracy of digital data entry. This study aims to analyze the performance of the TrOCR (Transformer-based Optical Character Recognition) model in digitizing handwritten text from manual transaction records. The experimental method was conducted through a fine-tuning process using the pretrained microsoft/tocr-base-handwritten model with a dataset consisting of 666 images that had undergone several preprocessing stages, including resize, grayscale, and adaptive threshold. Model evaluation was carried out using the 5-Fold Cross Validation method with Character Error Rate (CER) and Word Error Rate (WER) as evaluation metrics. The results showed that the model was able to recognize handwritten text effectively, where the best performance was achieved in Fold 3 with a CER value of 2.71%, a WER value of 12.42%, and a character accuracy of 97.29%. These findings indicate that the TrOCR model has strong potential to be implemented in handwritten-based transaction administration automation systems.*

Keywords— Adaptive Threshold, Transaction Records, Deep Learning, TrOCR, Handwriting Recognition.

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Pencatatan transaksi secara manual masih sering digunakan dalam kegiatan administrasi sederhana, seperti koperasi [1], sekolah [2], warung [3], maupun usaha kecil. Pada umumnya data transaksi ditulis langsung menggunakan tulisan tangan karena dianggap lebih praktis dalam proses pencatatan harian. Namun, penggunaan catatan secara manual memiliki beberapa

kekurangan dan kendala, terutama proses pencarian transaksi menjadi lebih lambat [4], ketidakakuratan input data ulang ke dalam bentuk digital dan keterlambatan input data ulang [5].

Permasalahan tersebut menjadi salah satu pentingnya proses digitalisasi data tulisan tangan. Akan tetapi, perubahan tulisan tangan menjadi teks digital bukan hal yang mudah, Variasi tulisan tangan dapat terjadi antar individu maupun pada individu yang sama dalam kondisi penulisan yang berbeda.. Perbedaan itulah yang menyebabkan proses pengenalan tulisan tangan menjadi lebih kompleks dibandingkan teks cetak biasa.

Dalam beberapa tahun terakhir, metode berbasis *deep learning* mulai banyak digunakan untuk mengatasi permasalahan pengenalan tulisan tangan [6]. Salah satunya yaitu model yang cukup berkembang adalah TrOCR (*Transformer Optical Character Recognition*)[7]. Model ini menggunakan arsitektur *transformer* yang mampu mempelajari pola dan visual hubungan antar karakter[8] sehingga dapat menghasilkan prediksi teks yang lebih baik [9]. TrOCR juga telah banyak digunakan dalam penelitian pengenalan tulisan tangan karena memiliki kemampuan yang cukup baik dalam membaca karakter dan pola visual.

Meskipun itu, hasil pengenalan tulisan tangan tetap dipengaruhi dari kualitas citra [10] yang digunakan. Tulisan yang kurang jelas, pencahayaan gambar, tulisan tipis, maupun *noise* pada citra dapat mempengaruhi performa model [11] dalam melakukan prediksi. Pada penelitian ini digunakan beberapa tahapan *preprocessing*, yaitu *resize* [12], augmentasi [13], *grayscale* [14], dan *adaptive threshold* [15] untuk membantu memperjelas karakter tulisan.

Penelitian ini berfokus pada analisis performa model TrOCR dalam mengenali tulisan tangan pada catatan transaksi manual. Dataset penelitian terdiri dari citra tulisan tangan yang berisi nama barang, jumlah barang, dan total transaksi. Proses pelatihan model dilakukan menggunakan metode *K-fold cross validation* agar evaluasi dapat dilakukan secara lebih merata pada seluruh dataset [16]. Pengujian dilakukan menggunakan CER (*Character Error Rate*) dan WER (*Word Error Rate*) [17] untuk mengetahui tingkat kesalahan hasil prediksi terhadap teks asli.

II. METODE


Penelitian ini menggunakan metode eksperimen untuk menganalisis performa model *Handwritten Text Recognition* (HTR) berbasis *deep learning* dalam mengenali tulisan tangan pada catatan transaksi manual. Model yang dipakai adalah TrOCR (*Transformer Optical Character Recognition*) yang dikembangkan oleh Microsoft dan telah dilatih (*Pre-Trained*) sebelumnya pada ribuan dataset tulisan tangan. Fokus utama penelitian ini diarahkan pada pengukuran tingkat akurasi model menggunakan evaluasi *Character Error Rate* (CER) dan *Word Error Rate* (Wer).

2.1 Tahapan Penelitian

Tahapan Penelitian dilakukan secara bertahap mulai dari pengumpulan dataset hingga evaluasi model. Alur penelitian terdiri dari beberapa proses utama yaitu pengumpulan data

tulisan tangan, *preprocessing* citra, pelatihan model TrOCR, proses validasi menggunakan *K-fold cross validation*, dan evaluasi hasil prediksi model menggunakan CER dan WER.

Pada tahap awal, dataset tulisan tangan dibuat dengan gaya tulisan yang berbeda guna meningkatkan kemampuan model dalam mengenali karakter tulisan tangan yang mungkin berbeda gaya setiap waktunya. Selanjutnya dilakukan *preprocessing* citra agar kualitas gambar menjadi lebih baik sebelum masuk ke tahap peletihan model.



Gambar 1. Diagram Alir Penelitian

2.2 Dataset Penelitian

Dataset yang digunakan pada penelitian ini berupa citra tulisan tangan transaksi manual yang menyerupai pembelian pada koperasi kampus. Dataset terdiri dari teks transaksi yang memuat nama barang, jumlah, total harga, kalimat yang berhubungan dengan koperasi serta angka dan huruf untuk melatih model untuk mengenali tulisan tangan tersebut.

Pada tahap awal, jumlah dataset yang digunakan sebanyak 230 data tulisan tangan yang berhubungan dengan koperasi kampus. Namun jumlah data tersebut dinilai masih kurang untuk proses pelatihan model *deep learning* sehingga dilakukan penambahan dataset menjadi 666 citra. Penambahan dataset dilakukan secara manual dengan membuat variasi tulisan tangan menggunakan beberapa penulis yang berbeda.

2.3 Preprocessing Citra

2.3.1 Resize

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas citra sebelum digunakan pada proses pelatihan model. Seluruh citra diubah terlebih dahulu menjadi 512 x 128 piksel agar sesuai dengan ukuran input model TrOCR. Ukuran tersebut dipilih karena dianggap mampu mempertahankan detail karakter tulisan tangan sekaligus menjaga efisiensi komputasi selama proses pelatihan model.

2.3.2 Augmentasi

Penelitian ini juga menerapkan augmentasi ringan berupa perubahan *brightness* dan *Gaussian blur* untuk meningkatkan variasi data pelatihan sehingga model dapat memiliki kemampuan untuk mengenali karakter tulisan tangan dengan baik

2.3.3 Grayscale

Selanjutnya citra diubah menjadi *grayscale* untuk menyederhanakan informasi warna dan memperjelas karakter tulisan tangan.

2.3.4 Adaptive Threshold

Setelah itu diterapkan metode *adaptive threshold* untuk meningkatkan kontras tulisan terhadap latar belakang serta mengurangi *noise* pada citra.

2.4 Model TrOCR

Model yang digunakan dalam penelitian ini adalah TrOCR (*Transformer Optical Character Recognition*) berbasis arsitektur *Transformer* yang dikembangkan oleh Microsoft. Model TrOCR merupakan model *pretrained* yang sebelumnya telah dilatih menggunakan dataset tulisan tangan dengan jumlah besar. Pada penelitian ini digunakan model *microsoft/trocr-base-handwritten* yang kemudian dilakukan proses *fine-tuning* menggunakan dataset tulisan tangan transaksi yang sudah disiapkan. Model TrOCR dipilih karena memiliki kemampuan yang cukup baik dalam mengenali tulisan tangan dibandingkan OCR konvensional

2.5 Pelatihan Model

Pelatihan model dilakukan menggunakan metode *5-Fold Cross Validation*. Dataset dibagi menjadi lima bagian data, kemudian setiap bagian digunakan secara bergantian sebagai data validasi dan pelatihan.

$$Data = Train Set + Validation Set$$

Konfigurasi pelatihan menggunakan *learning rate* sebesar $3e-5$, *batch size* 4, *weight decay* 0.01, dan jumlah *epoch* 5. Proses pelatihan dilakukan menggunakan GPU pada *Google Colab* untuk mempercepat proses komputasi. Kemudian model terbaik disimpan berdasarkan nilai CER terendah yang diperoleh selama proses validasi.

2.6 Evaluasi Model

Evaluasi model dilakukan menggunakan metrik *Character Error Rate* (CER) dan *Word Error Rate* (WER). CER digunakan untuk mengukur tingkat kesalahan karakter hasil prediksi model terhadap label sebenarnya, sedangkan WER digunakan untuk mengukur tingkat kesalahan kata.

2.6.1 CER (*Character Error Rate*)

Rumus CER digunakan untuk mengukur tingkat kesalahan karakter hasil prediksi model terhadap teks sebenarnya

$$CER = \frac{S+D+I}{N} \quad (1)$$

S = jumlah substitusi karakter
D = jumlah penghapusan karakter
I = jumlah penambahan karakter
N = jumlah total karakter referensi

2.6.2 WER (Word Error Rate)

WER digunakan untuk mengukur tingkat kesalahan kata

$$WER = \frac{S+D+I}{N} \quad (2)$$

S = substitution
D = deletion
I = insertion
N = jumlah kata referensi

Semakin kecil nilai CER dan WER, maka performa model semakin baik dalam mengenali tulisan tangan. Selain itu, penelitian juga menghitung akurasi karakter berdasarkan nilai CER untuk mengetahui tingkat keberhasilan model dalam mengenali karakter tulisan tangan.

III. HASIL DAN PEMBAHASAN


3.1 Dataset Penelitian

Dataset yang digunakan pada penelitian ini berupa citra tulisan tangan manual yang telah dikumpulkan dan dilabeli secara manual. Data terdiri dari nama barang, jumlah pembelian, total harga, dan kalimat yang berhubungan dengan koperasi kampus. Data ditulis di kertas menggunakan pena dan dicrop otomatis untuk dilakukan *training*.

Pada awal penelitian jumlah dataset yang digunakan sebanyak 230 data. Namun untuk meningkatkan variasi tulisan tangan dan membantu model mempelajari pola tulisan tangan dan mengurangi *overfitting*, dataset kemudian ditambah menjadi 666 data citra tulisan tangan. Berikut merupakan contoh dataset tulisan tangan yang digunakan.



Gambar 2. Dataset Penelitian



Gambar 3. Dataset Penelitian


Dataset yang digunakan memiliki variasi bentuk tulisan, gaya, serta ketebalan tulisan yang berbeda-beda. Seperti yang terlihat pada Gambar 2 dan Gambar 3. Variasi tersebut bertujuan untuk model mengenali pola tulisan tangan yang kemungkinan muncul saat proses pengujian. Selain itu setiap citra pada dataset telah diberi label sesuai isi tulisan yang

terdapat pada gambar. Label tersebut digunakan data acuan untuk proses pelatihan model TrOCR.

3.2 Preprocessing Data


Pada tahap *preprocessing* data dilakukan beberapa proses untuk meningkatkan kualitas citra sebelum digunakan untuk pelatihan model. Tahapan *preprocessing* terdiri dari *resize*, *grayscale*, dan *adaptive threshold*.

Proses *resize* dilakukan dengan mengubah ukuran citra menjadi 512x128 piksel agar seluruh data memiliki ukuran yang seragam.



Gambar 4. Dataset Resize

Pada tahap berikutnya adalah augmentasi ringan dilakukan perubahan *brightness*, penambahan blur sederhana. Tujuannya adalah menambah variasi data sehingga model tidak hanya belajar dari kondisi gambar yang terlalu ideal dan lebih adaptif.



Gambar 5. Dataset Augmentasi

Setelah dilakukan augmentasi, berikutnya dilakukan konversi gambar menjadi *grayscale*. Pada tahap ini citra RGB diubah menjadi satu kanal warna abu-abu. Penggunaan *grayscale* bertujuan untuk menyederhanakan citra, sehingga model dapat lebih fokus pada bentuk dan karakter.



Gambar 6. Dataset Grayscale

Tahap terakhir yaitu menerapkan *adaptive threshold*. Metode ini digunakan untuk mengubah citra *grayscale* menjadi citra biner hitam putih. *Adaptive threshold* membantu memperjelas tulisan dan memisahkan objek tulisan dari background gambar. Penggunaan *adaptive threshold* dipilih karena mampu menangani pencahayaan yang tidak merata pada citra sehingga pola dan karakter menjadi lebih jelas dan mudah dikenali oleh model HTR.




Gambar 7. Dataset Adaptive Threshold

3.3 Pembagian Dataset menggunakan *K-fold cross validation*


Pada penelitian ini digunakan metode *5-Fold Cross Validation* untuk melakukan evaluasi model secara lebih menyeluruh. Dataset dibagi menjadi lima bagian, dimana pada

setiap *fold* Sebagian data digunakan sebagai data *training* dan Sebagian lainnya sebagai data validasi.

Penggunaan metode *K-Fold* bertujuan agar seluruh data memiliki kesempatan menjadi data validasi sehingga hasil evaluasi model menjadi lebih stabil dan tidak bergantung pada satu pembagian data saja sehingga tahu mana yang terbaik.



Gambar 8. Akurasi Karakter per *Fold*



Gambar 9. CER per *Fold*


Berdasarkan hasil pengujian menggunakan *5-Fold Cross Validation*, model TrOCR memperoleh performa terbaik pada *Fold* 3 dengan nilai CER paling rendah yaitu 2,71% dan akurasi karakter sebesar 97,29% terlihat pada Gambar 8 dan Gambar 9. Hasil tersebut menunjukkan bahwa model mampu mengenali karakter tulisan tangan dengan tingkat kesalahan yang relatif rendah.

3.4 Pelatihan Model TrOCR

Model yang digunakan pada penelitian ini adalah TrOCR berbasis *deep learning* dengan model dasar *microsoft/trocr-base-handwritten*. Proses pelatihan dilakukan di lingkungan *Google Colab* dengan dukungan GPU.

Pada tahap pelatihan digunakan konfigurasi parameter antara lain *Learning rate* sebesar $3e-5$, *Batch size* sebesar 4, Jumlah *epoch* sebanyak 5, Serta evaluasi menggunakan CER dan WER

Selama proses pelatihan, model mempelajari pola dan karakter tulisan tangan berdasarkan variasi dataset yang telah dipersiapkan sebelumnya.



Gambar 10. Proses dan Hasil Training

3.5 Evaluasi Model

Evaluasi model dilakukan menggunakan *Character Error Rate* (CER) dan *Word Error Rate* (WER). CER digunakan untuk mengukur tingkat kesalahan karakter, sedangkan WER digunakan untuk mengukur tingkat kesalahan kata hasil prediksi.

Berdasarkan pengujian menggunakan *5-Fold Cross Validation* diperoleh hasil evaluasi sebagai berikut.

Tabel 1. Hasil Evaluasi model menggunakan *5-Fold Cross Validation*

Fold	CER (%)	WER (%)	Akurasi Karakter (%)
<i>Fold 1</i>	4.09%	10.40%	95.91%
<i>Fold 2</i>	4.81%	12.55%	95.19%
<i>Fold 3</i>	2.71%	12.42%	97.29%
<i>Fold 4</i>	4.02%	14.62%	95.98%
<i>Fold 5</i>	3.59%	11.44%	96.41%

Berdasarkan hasil pengujian menggunakan metode *5-Fold Cross Validation*, model TrOCR memperoleh performa terbaik pada *Fold 3* dengan nilai CER sebesar 2,71% dan akurasi karakter sebesar 97,29%. Hasil tersebut menunjukkan bahwa model mampu mengenali karakter tulisan tangan dengan tingkat kesalahan yang relatif rendah.


Nilai WER yang lebih tinggi dibanding CER menunjukkan bahwa model masih mengalami kesalahan dalam mengenali kata secara utuh meskipun Sebagian besar karakter berhasil diprediksi dengan benar. Kesalahan kecil pada satu atau dua karakter dapat menyebabkan seluruh kata dianggap salah dalam perhitungan WER. Hal ini umumnya terjadi pada tulisan tangan yang memiliki jarak antar karakter terlalu dekat, bentuk huruf tidak konsisten, atau kualitas citra yang kurang jelas.

3.6 Analisis Prediksi Model


Berdasarkan pengujian yang dilakukan, model mampu mengenali sebagian besar tulisan tangan dengan baik, terutama pada tulisan tangan yang memiliki bentuk karakter yang jelas dan konsisten. Namun pada beberapa kondisi, data masih ditemukan kesalahan prediksi pada karakter tertentu.

Kesalahan prediksi umumnya terjadi pada tulisan tangan yang kurang rapi, terlalu tipis, atau memiliki karakter yang saling dekat. Selain itu beberapa karakter memiliki bentuk yang hampir serupa juga terkadang menghasilkan prediksi yang kurang tepat.

Berikut merupakan hasil prediksi benar dan salah pada suatu data.




Gambar 11. Data Asli Sebelum Prediksi




```
HASIL PREDIKSI :  
8. Roti coklat 2 8000  
=====
```

Gambar 12. Hasil Prediksi

Pada gambar 11 dan 12 menampilkan data asli dan prediksi tulisan tangan, dimana hasilnya cukup baik dalam mengenali pola dan karakter tulisan tangan.



Gambar 13. Data Asli Sebelum Prediksi



```
HASIL PREDIKSI :  
A. Teh botol 1 pcs : 6000  
=====
```

Gambar 14. Hasil Prediksi

Pada gambar 13 dan gambar 14 masih terdapat karakter yang masih keliru diprediksi. Hal tersebut karena tulisan yang kurang jelas, tidak konsisten dan terlalu banyak *noise*, sehingga butuh penyesuaian atau *fine-tuning* lebih lanjut untuk data seperti itu. Namun secara keseluruhan model sudah bekerja dengan cukup baik dalam mengenali pola dan karakter tulisan tangan.

IV. KESIMPULAN

Berdasarkan hasil eksperimen dan analisis yang telah dilakukan, dapat disimpulkan bahwa implementasi model TrOCR berbasis arsitektur *Transformer* sangat efektif dalam mengenali karakter tulisan tangan pada dokumen transaksi manual. Penggunaan teknik *preprocessing* citra yang tepat dan validasi melalui *5-Fold Cross Validation* terbukti menghasilkan performa yang stabil, dengan tingkat akurasi karakter tertinggi mencapai 97,29% dan tingkat kesalahan karakter (CER) serendah 2,71%.

Namun, penelitian ini juga mencatat bahwa performa model cenderung menurun pada citra dengan kualitas tulisan yang tidak konsisten, terlalu tipis, atau memiliki gangguan (*noise*) yang berlebih. Hasil ini memberikan implikasi penting bagi pengembangan sistem administrasi digital pada UMKM atau koperasi untuk meningkatkan efisiensi pengolahan data transaksi.

Untuk penelitian selanjutnya, disarankan melakukan optimasi lebih lanjut melalui penambahan variasi dataset yang lebih ekstrem serta eksplorasi teknik *fine-tuning* pada lapisan *decoder* untuk menekan nilai *Word Error Rate* (WER) agar identifikasi kata menjadi lebih presisi.

DAFTAR PUSTAKA

- [1] R. A. Pebriani, T. Yustini, R. Sari, and N. Kholis, "Smart Cooperative: Pelatihan implementasi aplikasi digital untuk meningkatkan efektivitas pengelolaan koperasi," *J. Abdimas Ekon. Dan Bisnis*, vol. 5, no. 1, pp. 58–65, 2025.
- [2] A. B. Setiawan and M. Firmansyah, "Pengembangan Aplikasi Sederhana Pencatatan Keuangan untuk Meningkatkan Efisiensi Administrasi di SMK Al-Khaeriyah Pengampelan," *NuCSJo Nusantara. Community Serv. J.*, vol. 2, no. 2, pp. 136–140, 2025.
- [3] E. Maulidia, S. Wasiyanti, and K. Miharja, "Perbandingan pencatatan keuangan manual dengan menggunakan zahir accounting pada Warung Kopi Rakjat," *Artik. Ilm. Sist. Inf. Akunt.*, vol. 3, no. 2, pp. 97–102, 2023.
- [4] M. R. Firmansyah, A. C. Santoso, A. Farah, U. Monalissa, and M. R. Adiyanto, "Pengaruh pencatatan akuntansi manual dengan pencatatan digital di era globalisasi dalam suatu usaha Snack Rehan Demangan Bangkalan," *J. Media Akad.*, vol. 2, no. 7, 2024.
- [5] K. Christianto, Y. Purnomo, F. S. Lee, J. G. E. Putri, R. Comeron, and A. W. Putri, "RANCANG BANGUN APLIKASI PENCATATAN TRANSAKSI KEUANGAN PADA UMKM KEJUMPA," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 10, no. 2, pp. 3433–3440, 2026.
- [6] L. Abdiansah, S. Sumarno, A. Eviyanti, and N. L. Azizah, "Penerapan Algoritma Convolutional Neural Networks untuk Pengenalan Tulisan Tangan Aksara Jawa: Implementation of Convolutional Neural Networks Algorithm for Javanese Handwriting Recognition," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 2, pp. 496–504, 2025.
- [7] E. Meoded, "Handwritten text recognition of historical manuscripts using transformer-based models," *arXiv Prepr. arXiv2508.11499*, 2025.
- [8] L. Rahmawati, W. T. Atmojo, E. P. Cynthia, M. M. Cynthia, and D. N. Cynthia, "Pembandingan Arsitektur Transformer dan CNN untuk Pengolahan Data Non-Visual," *J. Ilmu Komput. dan Tek. Inform.*, vol. 2, no. 1, pp. 8–14, 2026.
- [9] F. Safira, "Studi Komparatif Model OCR Berbasis AI untuk Dokumen Cetak dan Tulisan Tangan," *Int. J. Informatics*, vol. 1, no. 1, 2025.
- [10] S. B. Bhaskoro, R. A. Pratama, and S. A. H. Darmawan, "Deteksi dan Interpretasi Tulisan Tangan Bahasa Indonesia melalui Pemrosesan Citra dan Optical Character Recognition (OCR)," *JTRM (Jurnal Teknol. dan Rekayasa Manufaktur)*, vol. 7, no. 1, pp. 48–64, 2025.
- [11] M. R. Anggraeni and B. S. W. Poetro, "Penerapan Deep Convolutional Autoencoder dengan Skip Connection Untuk Menghilangkan Derau pada Citra Digital," *Bridg. J. Publ. Sist. Inf. dan Telekomun.*, vol. 4, no. 1, pp. 10–28, 2026.
- [12] H. Zhang, E. Whittaker, and I. Kitagishi, "Extending TrOCR for text localization-free OCR of full-page scanned receipt images," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2023, pp. 1479–1485.
- [13] D. Anggreani and L. Lukman, "Peningkatan metode YOLOv7 dengan proses augmentasi image pada klasifikasi jenis kupu-kupu," *J. Teknol. Sist. Inf.*, vol. 4, no. 2, pp. 243–253, 2023.
- [14] R. A. Tavares, "Comparison of image preprocessing techniques for vehicle license plate

recognition using ocr: Performance and accuracy evaluation,” *arXiv Prepr. arXiv2410.13622*, 2024.

- [15] D. Situmorang, J. Lumban-Gaol, and E. Tambunan, “DETEKSI TUMPAHAN MINYAK MENGGUNAKAN METODE ADAPTIVE THRESHOLD PADA CITRA SATELIT SENTINEL-1A DI PERAIRAN UTARA KARAWANG,” *J. Rekayasa Tek. Sipil dan Lingkungan-CENTECH*, vol. 6, no. 1, pp. 28–36, 2025.
- [16] W. Wijiyanto, A. I. Pradana, S. Sopingi, and V. Atina, “Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa,” *J. Algoritm.*, vol. 21, no. 1, pp. 239–248, 2024.
- [17] S. Ouzerrout, “OCER and OCWER: Integrating Visual Similarity and Segmentation in OCR Evaluation,” in *Second Workshop on Language Models for Underserved Communities (LM4UC)*, 2026.