

# Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi)

DOI: <https://doi.org/10.35870/jtik.v10i1.4700>

## Sistem Pengenalan Citra Dokumen Teks Terdistorsi menjadi Teks Menggunakan Metode *Deep Learning*

Talenta Teholi Zalukhu<sup>1\*</sup>, Agustinus Rudatyo Himamunanto<sup>2</sup>, Haeni Budiati<sup>3</sup>

<sup>1\*,2,3</sup> Program Studi Informatika, Fakultas Sains & Komputer, Universitas Kristen Immanuel, Kabupaten Sleman, Daerah Istimewa Yogyakarta, Indonesia.

### article info

#### Article history:

Received 30 June 2025

Received in revised form

20 July 2025

Accepted 10 September 2025

Available online January

2026.

#### Keywords:

OCR; DnCNN; Tesseract;  
Deblurring; Blurred Image;  
Deep Learning; Image  
Enhancement.

#### Kata Kunci:

OCR; DnCNN; Tesseract;  
Deblurring; Citra Blur; Deep  
Learning; Peningkatan  
Gambar.

### abstract

A common issue in document image processing is the inability of OCR systems to accurately read text from blurred images. This study aims to develop a deep learning-based OCR pipeline capable of recognizing text in blurred document images. The process begins with image enhancement using the DnCNN model for deblurring, followed by character segmentation and classification of A-Z characters using a CNN trained on the EMNIST Letters dataset. The recognized characters are then reconstructed into complete text. Experiments were conducted on 300 blurred images with varying levels of blur (low, medium, and high). Evaluation using PSNR and SSIM metrics showed improvements in image quality, with an average PSNR of 29,56 dB and SSIM of 0.89. Furthermore, the character classification accuracy reached 95,64%. Compared to the baseline (direct Tesseract OCR without deblurring), the proposed system showed a significant improvement in text readability. These results demonstrate the effectiveness of CNN-based approaches in enhancing OCR performance on blurred document images.

### abstract

Permasalahan umum dalam pemrosesan citra dokumen adalah ketidakmampuan sistem OCR membaca teks dari citra yang blur. Penelitian ini bertujuan untuk mengembangkan pipeline OCR berbasis deep learning yang mampu mengenali teks dari citra dokumen blur. Proses dimulai dengan peningkatan kualitas citra menggunakan model DnCNN untuk deblurring, dilanjutkan segmentasi karakter, serta klasifikasi huruf A-Z menggunakan CNN yang telah dilatih pada dataset EMNIST Letters. Hasil klasifikasi karakter kemudian direkonstruksi menjadi teks utuh. Pengujian dilakukan terhadap 300 citra blur dengan tingkat keburaman bervariasi (ringan, sedang, dan berat). Evaluasi menggunakan metrik PSNR dan SSIM menunjukkan peningkatan kualitas citra setelah deblurring, dengan rata-rata PSNR sebesar 29,56 dB dan SSIM sebesar 0.89. Selain itu, akurasi klasifikasi karakter mencapai 95,64%. Dibandingkan baseline (menggunakan Tesseract langsung tanpa deblurring), sistem menunjukkan peningkatan keterbacaan teks yang signifikan. Hasil ini membuktikan bahwa pendekatan berbasis CNN efektif untuk meningkatkan performa OCR pada citra dokumen blur.

\*Corresponding Author. Email: [talenta.teholi.z@mail.ukrim.ac.id](mailto:talenta.teholi.z@mail.ukrim.ac.id) <sup>1\*</sup>.

Copyright 2026 by the authors of this article. Published by Lembaga Otonom Lembaga Informasi dan Riset Indonesia (KITA INFO dan RISET). This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License. 

## 1. Pendahuluan

Pengenalan teks pada citra dokumen sering kali menghadapi kendala serius, terutama ketika citra tersebut memiliki kualitas yang buruk, seperti pada citra buram atau tidak fokus. Kondisi ini menghambat kemampuan manusia untuk membaca teks dengan akurat, serta memperburuk hasil pengolahan citra oleh sistem OCR. Oleh karena itu, langkah pertama yang perlu dilakukan adalah meningkatkan kualitas citra melalui proses deblurring, yang bertujuan untuk mengurangi keburaman dan memperjelas elemen-elemen penting dalam gambar. Selanjutnya, teknologi *Deep Learning* dapat dimanfaatkan untuk mengonversi gambar yang telah diperbaiki menjadi teks yang dapat dibaca. Dengan kemajuan dalam bidang *Deep Learning*, ada potensi besar untuk mengatasi tantangan-tantangan yang berkaitan dengan akurasi dan efisiensi dalam pengenalan gambar dan teks secara lebih efektif (Fadjeri *et al.*, 2022). *Optical Character Recognition* (OCR) adalah teknologi yang digunakan untuk mengubah teks yang terdapat pada gambar menjadi teks digital. Namun, dalam praktiknya, kualitas gambar yang buruk seperti adanya blur, noise, atau perbedaan pencahayaan sering menyebabkan kesalahan dalam proses pengenalan teks (A. W. Nugroho, 2024). Penelitian ini mengusulkan penggunaan model *Deep Learning* DnCNN untuk mengatasi permasalahan tersebut, khususnya pada citra yang buram.

Proses deblurring menggunakan DnCNN bertujuan untuk meningkatkan kualitas citra sebelum diteruskan ke engine OCR, Tesseract, untuk melakukan ekstraksi teks. Dataset yang digunakan dalam penelitian ini berupa citra teks berbahasa Indonesia yang sengaja diburamkan dengan menggunakan filter Gaussian dan motion blur (Mohsenzadegan *et al.*, 2022). Sejumlah penelitian terkait telah menunjukkan bahwa sistem pengenalan citra teks yang dapat menghasilkan output teks secara otomatis dapat dikembangkan menggunakan kecerdasan buatan (AI), terutama melalui penerapan teknik-teknik canggih seperti *Convolutional Neural Networks* (CNN) dan OCR (Wijaya & Lubis, 2022). Tujuan utama dari penelitian ini adalah untuk merancang sistem pengenalan objek yang mampu membaca teks dalam dokumen, khususnya teks

berbahasa Indonesia, dengan tingkat akurasi yang tinggi (Nasional Fortei Regional *et al.*, 2021). Pengolahan citra dokumen yang berkualitas rendah, terutama citra yang buram, telah menjadi tantangan besar dalam dunia OCR (Kumar Siliwangi & Prabowo, 2022). Oleh karena itu, penelitian ini mengusulkan pipeline otomatis yang menggabungkan metode deblurring CNN (DnCNN) dan klasifikasi karakter berbasis CNN untuk meningkatkan hasil OCR pada citra yang buram. Permasalahan utama dalam sistem OCR adalah rendahnya akurasi pengenalan teks pada citra dokumen yang mengalami blur. Hal ini sering terjadi ketika teks dalam citra tidak terbaca dengan jelas akibat kondisi pencahayaan yang buruk, gerakan kamera, atau kualitas pemindaian yang rendah. Tesseract OCR, yang digunakan sebagai baseline dalam penelitian ini, memiliki keterbatasan dalam mengekstrak teks dari citra buram tanpa adanya pra-pemrosesan khusus, seperti deblurring (Hengaju & Krishna Bal, 2020). Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi pipeline OCR berbasis deep learning guna mengatasi masalah pembacaan teks pada citra dokumen yang buram. Secara spesifik, tujuan penelitian ini mencakup implementasi model DnCNN untuk deblurring citra dokumen buram, segmentasi karakter dari citra deblur untuk klasifikasi per huruf, serta pembangunan dan pelatihan model CNN untuk klasifikasi huruf A-Z menggunakan dataset *EMNIST Letters*.

Penelitian ini juga bertujuan untuk mengukur peningkatan kualitas citra hasil deblurring dengan menggunakan metrik PSNR dan SSIM, serta mengevaluasi hasil pembacaan teks sistem OCR berbasis DnCNN + CNN dibandingkan dengan baseline *Tesseract OCR* tanpa deblurring. Hasil akhir penelitian akan disimpan dalam bentuk file teks atau dokumen Word untuk kepentingan digitalisasi arsip dokumen teks berbahasa Indonesia. Batasan masalah dalam penelitian ini antara lain mencakup jenis citra yang hanya berupa dokumen teks berbahasa Indonesia dengan efek blur sintetik, jumlah data uji yang dibatasi sebanyak 300 gambar dengan variasi tingkat keburaman ringan, sedang, dan berat, serta format dan ukuran citra yang diubah menjadi grayscale dengan dimensi  $1600 \times 400$  piksel. Penelitian ini juga membatasi pada penggunaan font standar (misalnya *Times New Roman*, *Arial*), tidak mendukung huruf kapital, angka, tanda baca, atau simbol khusus,

serta menggunakan model DnCNN sebagai satu-satunya metode deblurring. Segmentasi karakter dilakukan per huruf dan hanya cocok untuk teks dengan jarak antar huruf yang cukup terpisah. Evaluasi performa sistem dilakukan menggunakan metrik PSNR, SSIM, dan akurasi karakter, serta akurasi teks akhir (*word accuracy*). Manfaat penelitian ini dibagi menjadi dua aspek utama: teoretis dan praktis. Secara teoretis, penelitian ini berkontribusi terhadap pengembangan metode OCR berbasis deep learning dengan memperkenalkan model DnCNN untuk deblurring citra dokumen dan CNN untuk klasifikasi karakter. Penelitian ini juga memvalidasi efektivitas arsitektur DnCNN dalam meningkatkan akurasi sistem OCR di domain citra dokumen, serta menawarkan struktur pipeline OCR yang dapat dijadikan referensi untuk pengembangan metode serupa di masa mendatang. Secara praktis, penelitian ini diharapkan dapat meningkatkan keterbacaan dokumen digital yang buram, memberikan solusi bagi digitalisasi dokumen berbahasa Indonesia, serta mempermudah pengolahan data teks dari citra dalam berbagai bidang, termasuk pendidikan, perpajakan, pelayanan publik, dan hukum. Dengan kemampuan memproses hingga dua citra per detik dan akurasi baca mencapai sekitar 93% setelah deblurring, sistem ini diharapkan dapat mempercepat proses konversi dokumen cetak menjadi teks digital yang dapat diedit atau disimpan.

## 2. Metodologi Penelitian

Tahapan penelitian ini mencakup serangkaian langkah sistematis yang dirancang untuk mencapai tujuan utama, yaitu mengembangkan dan mengevaluasi pipeline OCR berbasis deep learning. Setiap tahap dilakukan dengan memperhatikan aspek teknis dan metodologis yang diperlukan untuk memproses citra dokumen buram, mulai dari pengumpulan dataset, pelatihan model deblurring DnCNN, hingga segmentasi dan klasifikasi karakter menggunakan CNN. Seluruh proses ini bertujuan untuk meningkatkan akurasi pengenalan teks pada citra yang terdistorsi, sehingga hasilnya dapat digunakan untuk digitalisasi dokumen teks dengan kualitas yang lebih baik.



Gambar 1. Flowchart System

### Pengumpulan dan Persiapan Dataset

Tahap awal penelitian dimulai dengan pengumpulan dataset yang terdiri dari 300 citra dokumen blur dalam format JPEG. Citra-citra ini diperoleh dari folder *Dataset Blur Citra Dok Teks* yang disimpan di Google Drive. Setiap citra merupakan dokumen yang berisi teks berbahasa Indonesia dengan variasi konten, panjang teks, dan tingkat keburaman yang bervariasi (low, medium, high blur). Gambar-gambar tersebut dikumpulkan menggunakan teknik purposive sampling, bertujuan untuk mewakili berbagai tingkat keburaman yang umum ditemui pada dokumen hasil pemindaian atau foto yang tidak fokus. Dimensi citra dalam dataset bervariasi, mulai dari ukuran  $256 \times 256$  piksel,  $512 \times 512$  piksel, hingga ukuran yang mendekati ukuran A4 (sekitar  $800 \times 1100$  piksel), menyesuaikan dengan resolusi dokumen asli. Pemilihan 300 gambar dilakukan untuk menjaga keseimbangan antara jumlah data dan kelayakan proses pelatihan serta pengujian pada lingkungan komputasi yang terbatas, seperti yang digunakan dalam Google Colab.

Untuk pelatihan model CNN dalam klasifikasi karakter, digunakan dataset *EMNIST Letters* yang berisi citra karakter huruf A-Z (26 kelas). Model CNN yang dikembangkan berfungsi untuk mengenali karakter hasil segmentasi dari citra dokumen. Dataset *EMNIST Letters* terdiri dari gambar karakter huruf A-Z (total 26 kelas) dalam format grayscale dengan ukuran  $28 \times 28$  piksel (Baldominos *et al.*, 2019). Meskipun *EMNIST* awalnya dikembangkan untuk bahasa Inggris, karakter alfabet yang digunakan dalam bahasa Indonesia identik, yaitu A sampai Z tanpa karakter tambahan seperti umlaut atau aksen khusus. Oleh karena itu, tidak diperlukan penyesuaian atau modifikasi karakter dari dataset *EMNIST* untuk

digunakan dalam pengenalan huruf dalam dokumen berbahasa Indonesia (Edelbert Strago Giamiko & Tjiong, 2024). Adaptasi dilakukan secara kontekstual, bukan struktural, dengan memastikan bahwa setiap huruf dalam teks Indonesia yang diekstraksi dari citra dokumen termasuk dalam 26 huruf Latin standar. Proses segmentasi karakter juga diarahkan untuk menghasilkan potongan huruf yang valid sesuai dengan kelas-kelas yang telah dikenali oleh model CNN yang dilatih dengan *EMNIST Letters*. Dengan demikian, meskipun tidak dilakukan penyesuaian eksplisit terhadap konten dataset, *EMNIST Letters* sudah memadai sebagai basis pelatihan model untuk OCR dokumen berbahasa Indonesia (Pratiwi *et al.*, 2021).

### **Model DnCNN untuk Deblurring**

Setelah dataset disiapkan, tahap berikutnya adalah pelatihan model *DnCNN* (Denoising Convolutional Neural Network) untuk menghilangkan efek blur pada citra dokumen. *DnCNN* merupakan arsitektur CNN yang dikembangkan khusus untuk mempelajari pola residual noise (seperti blur atau noise) dan menguranginya dari citra input, menghasilkan citra yang lebih tajam dan bersih. Dalam penelitian ini, model *DnCNN* dibangun menggunakan framework *TensorFlow* dan dilatih dari awal. Gambar-gambar input terlebih dahulu dikonversi ke skala keabuan (grayscale) dan diubah ukurannya menjadi  $1600 \times 400$  piksel untuk memastikan keseragaman dimensi input ke dalam jaringan. Pada tahap deblurring, model *DnCNN* digunakan untuk menghilangkan noise atau blur dari citra dokumen (B. Nugroho & Puspaningrum, 2021). Model ini memanfaatkan pendekatan pembelajaran residual, di mana jaringan dilatih untuk mempelajari perbedaan (residu) antara citra blur dan citra tajam, dan kemudian residu tersebut dikurangi dari citra input untuk menghasilkan citra yang lebih bersih. Arsitektur model *DnCNN* yang digunakan terdiri dari beberapa lapisan konvolusi, antara lain:

- 1) Lapisan awal *Conv2D* dengan aktivasi *ReLU*.
- 2) 15 lapisan *Conv2D* (hidden) dengan padding “same”, batch normalization, dan aktivasi *ReLU*.
- 3) 1 lapisan output *Conv2D linear* untuk menghasilkan citra hasil deblurring.

Model *DnCNN* terdiri dari 17 lapisan konvolusi, di mana setiap lapisan menggunakan kernel  $3 \times 3$  dengan

padding ‘same’. Aktivasi menggunakan *ReLU* (kecuali lapisan terakhir), tanpa operasi pooling, dan output model berupa residual image (pola blur) yang akan dikurangi dari citra input. Parameter pelatihan model *DnCNN* menggunakan framework *TensorFlow*, dengan spesifikasi berikut:

- 1) Optimizer: *Adam*
- 2) Loss function: Mean Squared Error (MSE)
- 3) Epoch: 10 (eksperimen awal)
- 4) Batch size: 32
- 5) Learning rate: 0.001 (dengan learning rate decay)
- 6) Validation split: 20% dari data pelatihan
- 7) Input Shape:  $1600 \times 400$  piksel (grayscale)
- 8) Framework: *TensorFlow / Keras*

Dataset pelatihan berisi pasangan citra blur dan citra tajam yang dibentuk melalui augmentasi patch citra. Proses preprocessing mencakup konversi citra ke grayscale dan normalisasi piksel ke rentang [0,1]. Dataset yang digunakan untuk pelatihan *DnCNN* terdiri dari citra teks yang telah diburamkan menggunakan metode Gaussian blur dan motion blur sintetis. Karena dataset utama (300 citra) digunakan untuk pengujian sistem, pelatihan *DnCNN* dilakukan menggunakan pasangan citra tajam dan blur hasil augmentasi internal (misalnya dari dataset dokumen tambahan atau hasil buatan sendiri). Hal ini memastikan bahwa model dapat belajar dari berbagai pola blur yang terjadi pada dokumen nyata. Selama pelatihan, dilakukan evaluasi validasi di setiap epoch menggunakan subset data validasi (20%). Performa model dinilai menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM) untuk memastikan bahwa model tidak mengalami overfitting dan mampu meningkatkan kualitas visual citra. Output dari model *DnCNN* berupa citra hasil deblurring yang memiliki ketajaman lebih tinggi, yang kemudian digunakan sebagai input untuk tahap segmentasi karakter dan pengenalan huruf. Untuk mengevaluasi hasil deblurring, dua metrik utama digunakan:

- 1) PSNR (*Peak Signal-to-Noise Ratio*): Metrik kuantitatif yang menunjukkan rasio antara sinyal asli dan noise dalam gambar. Nilai PSNR yang lebih tinggi menunjukkan kualitas citra yang lebih baik. Hasil rata-rata: 29.56 dB.
- 2) SSIM (*Structural Similarity Index*): Metrik struktural yang membandingkan pola spasial citra hasil dan

citra acuan. Nilai yang mendekati 1 menunjukkan kemiripan yang tinggi. Hasil rata-rata: 0.89.

Nilai-nilai ini mengindikasikan bahwa hasil deblurring cukup optimal untuk dilanjutkan ke tahap ekstraksi teks OCR.

## Proses OCR

Gambar yang sudah tidak blur kemudian dibaca teksnya menggunakan *Tesseract OCR*, yaitu alat open-source untuk membaca teks dari gambar dengan bahasa yang digunakan adalah bahasa Indonesia (Fadjeri *et al.*, 2022). Hasilnya berupa teks digital yang diekstraksi dari gambar dokumen (Septiarini, 2012).

## Evaluasi dan Pembahasan

Hasil gambar yang sudah dideblur dan teks yang berhasil dibaca akan diuji kualitasnya. Untuk mengevaluasi hasil deblurring, digunakan metrik PSNR dan SSIM. Setelah teks berhasil direkonstruksi, sistem akan menyimpan hasilnya ke dalam format dokumen Word (.docx) secara otomatis.

Tabel 1. PSNR dan SSIM

Nama	PSNR	SSIM
blur_001.jpg	28.12	0.892
blur_002.jpg	30.45	0.901
blur_003.jpg	27.89	0.875
...	...	...
Rata-rata	29.56	0.893

## Bahan dan Alat

Penelitian ini menggunakan bahan berupa gambar dokumen blur yang berisi teks berbahasa Indonesia. Beberapa alat dan perangkat lunak yang digunakan antara lain: *Google Colab* sebagai platform untuk pengkodean dan pelatihan model, *TensorFlow* dan *Keras* untuk membangun model *DnCNN*, *OpenCV* dan *PIL* untuk memproses gambar, *Tesseract OCR* untuk membaca teks dari gambar, serta *Google Drive* untuk menyimpan data dan file hasil.

## Rancangan Percobaan

Penelitian ini menggunakan metode eksperimen. Setiap gambar yang diuji akan diproses dengan *DnCNN*, kemudian teksnya dibaca menggunakan OCR. Hasil dari proses OCR akan dibandingkan dengan gambar asli dan hasil deblurring yang

dihasilkan oleh *DnCNN*. Pipeline sistem terdiri dari tahapan berikut:

- 1) Deblurring  
Menggunakan model *DnCNN* untuk meningkatkan kualitas citra blur.
- 2) Segmentasi Karakter  
Memisahkan setiap huruf dalam citra dokumen.
- 3) Klasifikasi Karakter  
Menggunakan CNN dengan output 26 kelas (huruf A-Z).
- 4) Rekonstruksi Tekst  
Hasil prediksi karakter digabungkan menjadi kalimat (Manurung *et al.*, 2011).
- 5) Evaluasi  
Menggunakan metrik PSNR, SSIM untuk deblurring, dan akurasi untuk klasifikasi OCR.

## Teknik Pengambilan Sampel

Gambar-gambar dipilih menggunakan teknik *purposive sampling*, yaitu gambar yang memang blur dan memiliki variasi tingkat keburaman (dari yang ringan hingga berat). Sampel uji dipilih secara acak dari dataset untuk diuji performa modelnya.

**Kesehatan mental sama pentingnya dengan kesehatan fisik.**

**Disiplin adalah jembatan antara tujuan dan pencapaian.**

**Buku adalah jendela dunia yang membuka cakrawala pengetahuan.**

Gambar 2. Blur sebagai input

Penelitian ini menggunakan teknik *sampling purposive*, yang berarti pemilihan sampel dilakukan secara sengaja berdasarkan pertimbangan tertentu yang relevan dengan tujuan penelitian. Teknik ini dipilih karena penelitian ini tidak memerlukan data yang diambil secara acak, melainkan data yang memenuhi kriteria khusus, yaitu:

- 1) Citra dokumen yang blur: Gambar yang dipilih adalah dokumen digital yang mengalami blur nyata, baik akibat *motion blur* maupun *Gaussian blur*, untuk mensimulasikan kondisi nyata pada pengambilan gambar dokumen dengan kamera ponsel atau hasil scan yang tidak sempurna.
- 2) Berisi teks bahasa Indonesia: Seluruh citra harus mengandung teks berbahasa Indonesia agar sesuai dengan target sistem OCR yang dikembangkan.
- 3) Variasi tingkat blur: Dataset mencakup tingkat keburaman yang berbeda (ringan, sedang, berat), agar sistem diuji pada kondisi visual yang bervariasi.

- 4) Panjang teks bervariasi ( $\geq 2$  baris): Citra dipilih agar mengandung cukup banyak kata, bukan hanya 1–2 baris, guna menguji kemampuan sistem dalam mengenali struktur kalimat dan konteks.
- 5) Format dan ukuran citra: Gambar yang dipilih adalah dalam format .jpg dan beresolusi umum seperti  $256 \times 256$ ,  $512 \times 512$ , hingga ukuran mendekati A4 (contoh:  $800 \times 1100$  px).

Sebanyak 300 citra blur dipilih dari *Google Drive* pada folder *Dataset Blur Citra Dok Teks*. Pemilihan ini bertujuan untuk mengevaluasi secara menyeluruh efektivitas pipeline OCR berbasis deep learning pada berbagai jenis degradasi blur dokumen. Dengan kriteria tersebut, sebanyak 300 citra dokumen blur dipilih dari folder "Dataset Blur Citra Dok Teks" di *Google Drive* untuk dijadikan sampel pengujian dalam penelitian ini. Dalam penelitian ini, model CNN untuk klasifikasi karakter huruf A-Z dilatih menggunakan dataset *EMNIST Letters*. Dataset ini sudah secara resmi terbagi menjadi data pelatihan (*training set*) dan data validasi (*test set*) yang umum digunakan dalam pelatihan *supervised learning*. Total data *EMNIST Letters* secara default menyediakan  $\sim 124.800$  citra untuk *training* dan  $\sim 20.800$  citra untuk *testing*.

Data *training* tidak dibagi ulang secara manual karena sudah memiliki struktur pelatihan dan pengujian terpisah. Selama pelatihan model CNN, dilakukan validasi menggunakan 10% data dari *training set* untuk mengukur performa model di luar data yang sedang dipelajari. Hal ini diatur melalui parameter *validation\_split=0.1* saat menjalankan *model.fit()* di *TensorFlow/Keras*. Setelah model selesai dilatih, dilakukan evaluasi terhadap *test set* untuk mengukur generalisasi model terhadap data baru yang belum

pernah dilihat. Hasil evaluasi akhir menunjukkan akurasi validasi sebesar 91,78% dan akurasi pelatihan mencapai 95,64%, yang menunjukkan tidak terjadi *overfitting* signifikan. Penelitian ini tidak menggunakan teknik *k-fold cross-validation* secara eksplisit karena struktur dataset *EMNIST* sudah dipisahkan secara standar. Namun, metode *validation split* tetap menjamin keandalan model secara umum.

### Rencana Pengujian

Tujuan utama dari pengujian ini adalah untuk menilai kualitas citra hasil deblurring menggunakan metrik PSNR dan SSIM, mengukur akurasi pembacaan teks oleh sistem OCR berbasis CNN, serta membandingkan hasil OCR CNN dengan hasil dari *Tesseract OCR* sebagai baseline. Selain itu, penelitian ini juga akan menganalisis jenis kesalahan yang paling sering terjadi pada proses segmentasi maupun klasifikasi huruf. Jumlah citra uji: 300 gambar blur dalam format JPG, berisi teks berbahasa Indonesia. Citra memiliki tingkat blur sedang hingga tinggi (*Gaussian* dan *motion blur*). Pengujian dilakukan dalam beberapa tahap, yaitu:

- 1) Input: Gambar blur dimasukkan ke sistem.
- 2) Deblurring: Gambar diproses menggunakan model *DnCNN*.
- 3) Segmentasi karakter: Tiap huruf dipotong dari hasil deblurring.
- 4) Klasifikasi karakter: Tiap karakter diprediksi menggunakan CNN.
- 5) Rekonstruksi teks: Karakter disusun kembali menjadi teks (OCR).
- 6) Perbandingan dengan *Tesseract* (baseline): Hasil akhir dinilai dengan PSNR, SSIM, dan akurasi OCR.

Tabel 2. PNR, SSIM, dan akurasi OCR

Komponen	Alat Ukur	Tujuan
Hasil deblurring	SSIM mencapai 0,89	Menilai seberapa tajam hasil perbaikan gambar.
Hasil OCR	Akurasi huruf	Mengukur keberhasilan sistem dalam membaca karakter.
Hasil OCR	Perbandingan dengan ground truth atau <i>Tesseract</i>	Visual inspection untuk memastikan apakah tiap huruf berhasil diambil.

Alat yang Digunakan:

- 1) *Google Colab* (untuk pemrosesan dan pelatihan model).

- 2) *Python* dengan pustaka: *Keras*, *OpenCV*, *Tesseract*, *Matplotlib*, dll.

- 3) Dataset *EMNIST Letters* (untuk pelatihan CNN klasifikasi huruf).
- 4) *Microsoft Word* (penyimpanan output teks OCR).

Hasil evaluasi menunjukkan bahwa model *DnCNN* yang digunakan dalam pipeline mampu secara efektif meningkatkan kualitas citra blur ke tingkat yang layak untuk tahap segmentasi karakter dan *OCR*.


### Analisis Data

Setelah gambar dokumen blur diproses menggunakan model *DnCNN*, terjadi peningkatan kualitas citra yang signifikan. Proses deblurring ini bertujuan untuk mengembalikan detail struktur teks agar dapat dikenali oleh sistem *OCR*. Evaluasi kualitas citra hasil deblurring dilakukan menggunakan dua metrik utama: *PSNR* (Peak Signal-to-Noise Ratio) dan *SSIM* (Structural Similarity Index). *PSNR* mengukur perbedaan antara gambar hasil deblurring dan citra referensi tajam. Rata-rata nilai *PSNR* yang diperoleh adalah 29,56 dB, yang menunjukkan bahwa citra hasil deblurring memiliki kualitas yang cukup mendekati gambar ideal. Sedangkan *SSIM* menilai kesamaan struktur dan tekstur antara citra hasil deblurring dan gambar referensi. Rata-rata nilai *SSIM* mencapai 0,89, yang menunjukkan bahwa model *DnCNN* mampu memulihkan struktur penting dari citra, terutama bentuk huruf dan kontur teks. Hasil ini membuktikan bahwa model *DnCNN* yang digunakan dalam pipeline mampu secara efektif meningkatkan kualitas citra blur ke tingkat yang cukup baik untuk dilanjutkan ke tahap segmentasi karakter dan *OCR*. Evaluasi dilakukan terhadap 300 gambar dengan tingkat keburaman yang bervariasi (ringan hingga berat). Sistem ini menunjukkan konsistensi dalam kinerjanya, dengan model CNN yang digunakan untuk membaca karakter memberikan hasil yang memadai pada berbagai tingkat keburaman. Hasil *OCR* menunjukkan akurasi yang tinggi dalam membaca karakter dan membandingkan hasilnya dengan ground truth atau *Tesseract OCR*.

### Hasil *OCR*: Akurasi Huruf

Evaluasi terhadap akurasi huruf yang dibaca oleh sistem menunjukkan hasil yang signifikan, dengan model CNN mampu membaca karakter secara konsisten meskipun gambar mengalami berbagai tingkat keburaman. Perbandingan hasil *OCR* juga

menunjukkan peningkatan kualitas yang signifikan dibandingkan dengan baseline. Secara keseluruhan, hasil analisis menunjukkan bahwa pipeline yang dikembangkan, termasuk model *DnCNN* untuk deblurring dan model CNN untuk klasifikasi karakter, mampu meningkatkan kualitas citra dan akurasi pembacaan teks secara efektif dalam kondisi citra blur.



Gambar 3. PSNR dan SSIM hasil deblurring dengan dan tanpa DnCNN

Grafik menunjukkan rata-rata kualitas gambar setelah proses deblurring menggunakan model *DnCNN*. *PSNR* (Peak Signal-to-Noise Ratio) mencapai 29,56 dB, menandakan bahwa hasil citra mendekati kualitas gambar tajam. *SSIM* (Structural Similarity Index) sebesar 0,89 menunjukkan bahwa struktur gambar hasil deblur sangat mirip dengan gambar acuan. Setelah gambar diperjelas (deblur), dilakukan segmentasi karakter dan klasifikasi huruf A-Z menggunakan model CNN yang telah dilatih dengan dataset *EMNIST Letters*. Evaluasi hasil *OCR* dilakukan dengan membandingkan hasil teks yang diperoleh menggunakan *Tesseract OCR* dari gambar yang sama.

Dari analisis, ditemukan bahwa model CNN lebih unggul dalam mengenali huruf hasil segmentasi, terutama pada gambar yang awalnya blur. CNN juga lebih stabil dalam membaca huruf kapital, sedangkan *Tesseract* sering salah membaca huruf mirip seperti "I" dan "l", atau "O" dan "0". Model CNN diuji menggunakan data validasi dan menghasilkan akurasi pelatihan sekitar 95% setelah 10–15 epoch. Akurasi validasi stabil di atas 92%, menandakan bahwa model tidak mengalami *overfitting* yang signifikan. Model CNN mampu mengenali huruf secara individual dengan cukup baik. Namun, keberhasilan rekonstruksi teks juga bergantung pada segmentasi karakter yang tepat dan citra hasil deblurring. Beberapa faktor kesalahan ditemukan selama

pengujian: pada citra dengan blur berat, meskipun sudah dideblur, hasilnya masih sulit terbaca. Selain itu, segmentasi karakter yang rapat (huruf yang saling menempel) sulit dipisahkan, dan kesalahan klasifikasi huruf mirip (misalnya huruf "I" yang terkadang dikenali sebagai "l") masih terjadi. Meskipun demikian, sistem masih mampu mengenali sebagian besar isi teks dokumen, terutama jika blur tidak terlalu berat.

### Prosedur Pengujian Sistem

Pengujian dilakukan melalui beberapa tahapan untuk menilai efektivitas sistem dalam membaca teks dari citra dokumen blur. Tahapan tersebut adalah:

- 1) Input Dataset Blur: Sebanyak 300 citra blur dimasukkan ke sistem. Dataset memiliki variasi tingkat blur (ringan, sedang, berat).
- 2) Proses Deblurring: Setiap gambar diproses menggunakan model *DnCNN* untuk menghasilkan citra hasil deblur.
- 3) Segmentasi Karakter: Hasil deblur kemudian diproses untuk memotong tiap karakter huruf secara otomatis dari baris teks.
- 4) Klasifikasi Karakter: Tiap potongan karakter dikenali menggunakan model CNN huruf a-z yang telah dilatih dari *EMNIST Letters*.
- 5) Rekonstruksi Karakter: Karakter hasil prediksi digabungkan kembali menjadi teks lengkap, membentuk kalimat utuh.
- 6) Evaluasi Kualitas Citra: Perbandingan antara citra blur dan hasil deblur dihitung menggunakan metrik: *PSNR* (Peak Signal-to-Noise Ratio) dan *SSIM* (Structural Similarity Index).
- 7) Evaluasi Akurasi Teks: Teks hasil OCR dibandingkan dengan teks asli (ground truth) menggunakan metrik: Akurasi Karakter (*Character Accuracy*) dan Akurasi Kata (*Word Accuracy*).
- 8) Perbandingan Baseline: Untuk melihat efektivitas sistem, dilakukan perbandingan dengan hasil OCR langsung (tanpa deblurring) menggunakan *Tesseract OCR*.

### Etika Penelitian

Penelitian ini telah mempertimbangkan prinsip-prinsip etika yang berlaku dalam kegiatan penelitian ilmiah, khususnya dalam konteks pengolahan data dan penggunaan teknologi kecerdasan buatan:

### 1) Penggunaan Dataset Aman dan Bebas Identitas Pribadi

Seluruh citra dokumen yang digunakan dalam penelitian merupakan hasil simulasi atau dikumpulkan tanpa mengandung informasi identitas pribadi atau data sensitif. Tidak ada dokumen resmi yang bersifat privat atau rahasia yang digunakan, sehingga tidak melanggar hak privasi individu atau lembaga.

### 2) Transparansi dan Reproduksibilitas

Penelitian ini dirancang agar dapat direplikasi oleh pihak lain. Seluruh langkah mulai dari preprocessing, pelatihan model, hingga evaluasi dilakukan secara sistematis dan transparan, menggunakan dataset yang tersedia atau dapat direproduksi secara teknis (misalnya, *EMNIST Letters*).

### 3) Penggunaan Teknologi dengan Tujuan Akademik

Model *DnCNN* dan CNN karakter yang dikembangkan hanya digunakan untuk kepentingan akademik dan pengembangan sistem pembaca dokumen (OCR). Tidak ada tujuan komersial, manipulatif, atau diskriminatif yang menyertai pengembangan sistem ini.

### 4) Kepatuhan terhadap Lisensi dan Sumber Terbuka

Seluruh perangkat lunak, pustaka (library), dan dataset yang digunakan tunduk pada lisensi sumber terbuka (*open source*). Pustaka seperti *TensorFlow*, *OpenCV*, dan *pytesseract* digunakan sesuai dengan ketentuan lisensi penggunaannya.

### 5) Kredibilitas dan Kejujuran Akademik

Hasil evaluasi, akurasi, grafik, serta tabel yang disajikan merupakan hasil dari proses komputasi dan pengujian aktual. Tidak ada manipulasi data atau hasil yang bertujuan menyesatkan. Setiap sumber pustaka dikutip secara layak sesuai kaidah akademik.

## 3. Hasil dan Pembahasan

### Hasil

#### Hasil Pengujian

Pengujian dilakukan pada 300 citra dokumen blur berbahasa Indonesia dengan tingkat blur yang bervariasi. Proses dimulai dengan deblurring menggunakan model *DnCNN*, diikuti dengan tahap OCR berbasis segmentasi karakter dan klasifikasi

huruf A–Z menggunakan CNN yang telah dilatih dengan dataset *EMNIST Letters*. Pipeline yang diterapkan dalam penelitian ini menunjukkan peningkatan kualitas keterbacaan teks secara signifikan. Proses deblurring berhasil meningkatkan ketajaman citra yang sebelumnya kabur, memungkinkan sistem OCR untuk mengenali teks

dengan lebih akurat. Dengan menggunakan CNN untuk segmentasi dan klasifikasi karakter, sistem dapat secara efektif mengenali huruf dan menghasilkan teks digital yang lebih dapat dibaca, bahkan pada citra dengan tingkat keburaman yang tinggi.

Tabel 3. Contoh Hasil

Nama Gambar	Hasil OCR Sebelum Deblur (Tesseract)	Hasil OCR Setelah Deblur (DnCNN + Tesseract)
blur_224.jpg	(buram/tidak terbaca)	Kesehatan mental sama
blur_225.jpg	(buram/tidak terbaca)	Pentingnya dengan kesehatan fisik.
blur_226.jpg	(buram/tidak terbaca)	Membuka cakrawala pengetahuan.

Visualisasi citra sebelum dan sesudah deblurring menunjukkan bahwa teks yang sebelumnya tidak terbaca menjadi lebih jelas dan terbaca dengan baik setelah diproses menggunakan *DnCNN*. Pipeline yang diterapkan dalam penelitian ini secara konsisten meningkatkan *Word Accuracy* dari rata-rata 54,7% menjadi 93,1%, yang dihitung dengan membandingkan hasil teks yang diperoleh dengan referensi manual (*ground truth*). Sistem ini menunjukkan kemampuan yang baik dalam memproses seluruh dataset yang berisi 300 gambar dalam waktu sekitar 2,5 menit, dengan kecepatan rata-rata 2 citra per detik. Model CNN untuk klasifikasi karakter menunjukkan akurasi validasi sebesar 95,64%. Namun, beberapa kesalahan masih ditemukan pada karakter hasil segmentasi yang terlalu kabur atau tidak sempurna bentuknya. Kesalahan ini umumnya terjadi pada citra dengan tingkat keburaman yang tinggi, di mana proses segmentasi dan pengenalan karakter menjadi lebih menantang. Meskipun demikian, sistem tetap menunjukkan kinerja yang baik dan mampu mengenali sebagian besar karakter, bahkan pada citra dengan kualitas yang kurang optimal.

Hasil ini menegaskan bahwa pipeline yang dikembangkan sangat efektif—gambar blur yang sebelumnya tidak terbaca berhasil dikenali dengan sangat baik setelah diproses dengan *DnCNN*. Konsistensi akurasi tinggi ini menunjukkan bahwa pendekatan deblurring sebelum OCR memiliki dampak yang signifikan terhadap keterbacaan teks dokumen blur.

### Skenario Pengujian


Pengujian dilakukan untuk mengevaluasi seberapa efektif sistem yang dikembangkan dalam mengenali teks dari gambar dokumen yang mengalami blur. Pengujian dibagi ke dalam dua skenario utama:

#### 1) Pengujian Tanpa DnCNN (Baseline OCR)

Pada skenario ini, gambar blur langsung diproses oleh *Tesseract* OCR tanpa melalui proses deblurring. Hasil teks yang diekstrak digunakan sebagai acuan awal untuk mengetahui kemampuan dasar OCR terhadap gambar dokumen teks blur.

#### 2) Pengujian Dengan DnCNN (OCR Setelah Deblur)

Pada skenario ini, gambar blur terlebih dahulu diproses menggunakan model *DnCNN* untuk memperbaiki kualitas citra (deblurring). Setelah itu, citra yang sudah dideblur dimasukkan ke *Tesseract* OCR. Hasil OCR ini dibandingkan dengan skenario pertama untuk melihat apakah ada peningkatan kualitas pembacaan teks.



Gambar 4. Grafik akurasi OCR terhadap 300 gambar

Setiap pengujian dilakukan pada dataset yang berisi 300 gambar blur dengan tingkat keburaman yang bervariasi (ringan hingga berat). Hasilnya dianalisis berdasarkan tingkat keterbacaan teks serta kesalahan

baca. Pembagian dataset dilakukan dengan mempertimbangkan variasi tingkat keburaman untuk memastikan bahwa sistem diuji pada kondisi visual yang berbeda-beda.

### Tahap Pelatihan (Training)

Model CNN dikembangkan untuk melakukan klasifikasi karakter huruf A–Z dari citra hasil segmentasi. Dataset yang digunakan adalah *EMNIST Letters*, yaitu dataset standar yang berisi gambar karakter huruf kecil berukuran  $28 \times 28$  piksel dalam format grayscale. Dataset ini dipilih karena sesuai dengan kebutuhan pengenalan karakter individual dari dokumen teks berbahasa Indonesia. Pada tahap pelatihan, model CNN dirancang dengan beberapa lapisan konvolusi (*Conv2D*), *ReLU*, dan *MaxPooling*, diakhiri dengan lapisan *Dense* yang memiliki 26 output sesuai jumlah huruf alfabet. Proses pelatihan dilakukan menggunakan optimasi *Adam* dan fungsi loss *categorical\_crossentropy*. Selama proses *training*, digunakan parameter berikut:

- 1) Epoch: 20
- 2) Batch size: 128
- 3) Learning rate awal: 0.001
- 4) Pelatihan dilakukan menggunakan *TensorFlow* dan *Keras*.

### Pengujian Model (Testing)

Tahapan pengujian meliputi beberapa langkah:

- 1) Deblurring gambar menggunakan model *DnCNN*.
- 2) Segmentasi karakter per huruf dari hasil deblurring.
- 3) Klasifikasi karakter A–Z menggunakan model CNN.
- 4) Rekonstruksi teks: Hasil prediksi karakter digabungkan menjadi teks lengkap (OCR).
- 5) Evaluasi: Hasil OCR dibandingkan dengan teks referensi (ground truth), dan akurasi dihitung berdasarkan *Word Accuracy* (%).

Selain itu, untuk mengevaluasi kualitas hasil deblurring secara kuantitatif, digunakan dua metrik utama:

- 1) PSNR (*Peak Signal-to-Noise Ratio*): Digunakan untuk mengukur kualitas citra hasil deblurring dibandingkan dengan citra referensi tajam (*ground*

*truth*). Semakin tinggi nilai PSNR, semakin baik kualitas hasil restorasi. Rata-rata PSNR dari 300 citra: 29,56 dB.

- 2) SSIM (*Structural Similarity Index Measure*): Mengukur kemiripan struktur antara citra hasil deblurring dan citra referensi tajam. Nilai SSIM berada pada rentang 0–1; semakin mendekati 1, semakin mirip. Rata-rata SSIM dari 300 citra: 0,893.

Untuk mengevaluasi kebenaran pembacaan teks oleh OCR, digunakan metrik *Word Accuracy*, yang dihitung dengan rumus:

$$\text{Word Accuracy} = \left( \frac{\text{Jumlah Kata yang Sesuai}}{\text{Jumlah Total Kata Referensi}} \right) \times 100\%$$

Baseline (tanpa deblur): 54,7%

Setelah deblur (DnCNN): 93,1%

### Character Recognition Accuracy (CNN):

- 1) Mengukur akurasi model klasifikasi karakter A–Z hasil segmentasi dari citra deblur.
- 2) Model CNN (EMNIST Letters): 95,64%

Hasil ini menunjukkan bahwa penerapan model *DnCNN* untuk deblurring secara signifikan meningkatkan akurasi pembacaan teks, dengan peningkatan *Word Accuracy* yang tajam dari 54,7% menjadi 93,1%. Selain itu, akurasi karakter yang diperoleh dari model CNN dalam klasifikasi karakter A–Z setelah deblurring mencapai 95,64%, menandakan kemampuan model dalam mengenali huruf secara efektif, bahkan dalam citra yang sebelumnya kabur.




Gambar 5. Hasil Perbandingan

Tabel 4. Perbandingan

Metrik Evaluasi	Tanpa DnCNN	Dengan DnCNN
PSNR (dB)	24.31	29.56 (lebih tinggi)
SSIM	0.71	0.89 (lebih baik)
Word Accuracy (%)	93.00%	Jauh lebih tinggi

## Pengujian Antarmuka

Pengujian sistem dilakukan melalui antarmuka berbasis Google Colab yang berfungsi mengonversi citra blur menjadi teks digital. Antarmuka ini dirancang untuk memfasilitasi evaluasi kinerja pipeline OCR yang dikembangkan secara efisien dan terstruktur. Proses pengujian mencakup dua skenario utama: pertama, pemrosesan citra blur secara langsung menggunakan Tesseract tanpa tahap deblurring; kedua, pemrosesan citra blur yang telah melalui tahap deblurring dengan model DnCNN, kemudian dilanjutkan dengan segmentasi dan klasifikasi karakter menggunakan model CNN yang mengenali huruf A-Z. Pendekatan ini memungkinkan perbandingan kinerja sistem OCR dengan dan tanpa proses perbaikan kualitas citra.



Gambar 6. Perbandingan Sistem OCR

Visualisasi dalam bentuk grafik batang memperlihatkan perbandingan terstruktur antara metode *baseline* (Tesseract langsung) dan metode yang diusulkan (DnCNN + Tesseract). Perbandingan mencakup tingkat keterbacaan teks, tingkat kesalahan baca, serta rata-rata nilai PSNR dan SSIM.

## Efisiensi Sistem

Sistem yang dikembangkan menunjukkan efisiensi tinggi dalam pemrosesan citra dokumen blur secara masal. Pada pengujian terhadap 300 gambar, pipeline OCR yang terdiri dari proses *deblurring* menggunakan DnCNN, segmentasi karakter, klasifikasi huruf A-Z dengan CNN, serta rekonstruksi dan penyimpanan hasil dalam format dokumen Word, mampu

diselesaikan dalam waktu rata-rata sekitar 2,5 menit, dengan kecepatan pemrosesan mencapai 2 citra per detik. Seluruh tahapan, mulai dari pembacaan citra dari Google Drive, *deblurring*, hingga penyimpanan output teks secara otomatis di Google Colab, berjalan tanpa intervensi manual. Kondisi ini mengindikasikan bahwa sistem dapat diterapkan pada skenario nyata yang membutuhkan pemrosesan cepat dan akurat, seperti digitalisasi arsip, OCR dokumen hasil *scan* dengan kualitas rendah, maupun pengolahan citra dokumen hasil tangkapan kamera. Meskipun demikian, terdapat beberapa keterbatasan pada metode yang dikembangkan:

- 1) Ketergantungan pada Kualitas *Deblur*: Pada citra dengan *blur* berat atau deformasi huruf yang signifikan, model DnCNN mengalami kesulitan dalam memulihkan detail, sehingga hasil OCR menjadi kurang akurat atau tidak terbaca.
- 2) Segmentasi Karakter Kurang Optimal: Pada teks dengan jarak antar huruf yang sangat rapat atau menyatu, proses segmentasi karakter kurang presisi, berpotensi menyebabkan kesalahan klasifikasi atau kegagalan pembacaan.
- 3) Keterbatasan Model CNN: Model hanya dilatih pada dataset EMNIST Letters yang berisi huruf kecil a-z, sehingga tidak mampu mengenali angka, simbol, tanda baca, huruf kapital, atau aksara non-latin. Hal ini dapat menyebabkan interpretasi yang keliru pada teks berbahasa Indonesia yang mengandung unsur tersebut.
- 4) Ketidakmampuan Menangani Layout Kompleks: Pipeline ini hanya sesuai untuk dokumen dengan tata letak sederhana dan teks berbaris lurus. Dokumen dengan format kompleks seperti tabel, paragraf zig-zag, atau multi kolom belum didukung.
- 5) Performa *Baseline* Tesseract Terbatas: Hasil *baseline* menggunakan Tesseract tanpa *deblurring* memang rendah, namun perlu dicatat bahwa Tesseract bukan OCR yang optimal untuk kondisi *blur* ekstrem, sehingga perbandingan lebih bersifat evaluasi terhadap sistem dasar.

- 6) Kebutuhan Waktu dan Sumber Daya: Pelatihan model DnCNN dan CNN memerlukan sumber daya komputasi yang cukup besar, termasuk penggunaan GPU. Pada perangkat dengan spesifikasi rendah, performa pelatihan dan pemrosesan akan mengalami penurunan signifikan.

## Pembahasan

Penelitian ini berhasil menunjukkan bahwa penerapan model DnCNN untuk deblurring citra dokumen blur secara signifikan meningkatkan kualitas visual gambar, yang dibuktikan dengan nilai rata-rata PSNR sebesar 29,56 dB dan SSIM sebesar 0,89. Peningkatan kualitas citra ini sangat krusial karena sistem OCR sangat bergantung pada ketajaman dan kejelasan karakter agar dapat mengenali teks secara akurat. Setelah proses deblurring, model CNN yang dilatih menggunakan dataset EMNIST Letters mampu mengenali karakter huruf kecil a–z dengan akurasi validasi mencapai 95,64%. Meski demikian, beberapa kesalahan klasifikasi masih terjadi terutama pada huruf yang bentuknya mirip atau ketika segmentasi karakter kurang optimal, menandakan bahwa kualitas segmentasi juga berpengaruh besar terhadap performa keseluruhan sistem. Dibandingkan dengan baseline OCR menggunakan Tesseract tanpa proses deblurring, pipeline yang menggabungkan DnCNN dan CNN menunjukkan peningkatan akurasi pembacaan teks yang signifikan, dengan word accuracy meningkat dari sekitar 55% menjadi 93%.

Temuan ini sejalan dengan penelitian Hengaju & Krishna Bal (2020) yang menekankan pentingnya pra-pemrosesan citra untuk meningkatkan akurasi OCR, serta Mohsenzadegan *et al.* (2022) yang mengaplikasikan deep learning untuk blind enhancement citra dokumen dan mendapatkan hasil peningkatan kualitas yang signifikan. Selain itu, hasil ini konsisten dengan studi Baldominos *et al.* (2019) yang menunjukkan efektivitas CNN dalam klasifikasi karakter menggunakan dataset EMNIST. Sistem yang dikembangkan cukup efisien, mampu memproses 300 gambar dalam waktu sekitar 2,5 menit dengan kecepatan rata-rata 2 citra per detik pada platform Google Colab, meskipun pelatihan model memerlukan sumber daya komputasi yang memadai. Keterbatasan sistem terlihat pada

performa deblurring yang menurun jika citra blur sangat berat, segmentasi karakter yang kurang akurat pada huruf yang rapat atau menyatu, serta pembatasan model hanya pada huruf kecil tanpa dukungan angka, tanda baca, atau huruf kapital. Hal ini membatasi aplikasi sistem pada dokumen dengan format teks kompleks dan layout yang tidak sederhana. Keterbatasan ini juga tercermin dalam penelitian-penelitian sebelumnya yang menggunakan dataset dan model serupa, di mana pengenalan karakter non-alfabet dan layout kompleks masih menjadi tantangan utama (Wijaya & Lubis, 2022; Peryanto *et al.*, 2020). Secara keseluruhan, penelitian ini memperkuat bukti bahwa kombinasi metode deblurring berbasis DnCNN dan klasifikasi karakter menggunakan CNN merupakan pendekatan efektif untuk meningkatkan performa OCR pada citra dokumen blur. Pendekatan ini memberikan kontribusi penting bagi digitalisasi dokumen berbahasa Indonesia dan membuka peluang pengembangan lebih lanjut, seperti memperluas klasifikasi karakter, meningkatkan teknik segmentasi, dan mengadaptasi sistem untuk dokumen dengan tata letak lebih kompleks. Dengan demikian, hasil penelitian ini tidak hanya sejalan dengan temuan sebelumnya, tetapi juga menambah nilai praktis dan teoretis dalam bidang pengolahan citra dan pengenalan karakter.

## 4. Kesimpulan dan Saran

Penelitian ini berhasil mengembangkan pipeline OCR berbasis deep learning yang efektif untuk mengenali teks pada citra dokumen blur. Dengan menggunakan model DnCNN untuk proses deblurring dan CNN untuk klasifikasi karakter, sistem mampu meningkatkan kualitas citra secara signifikan dengan rata-rata PSNR sebesar 29,56 dB dan SSIM sebesar 0,89. Peningkatan kualitas gambar ini berdampak langsung pada akurasi pembacaan teks, di mana word accuracy meningkat dari 55% pada baseline tanpa deblurring menjadi 93% pada metode yang diusulkan. Pengujian dilakukan menggunakan dataset 300 gambar dokumen blur berbahasa Indonesia dan dataset EMNIST Letters untuk pelatihan klasifikasi huruf A–Z. Sistem ini juga menunjukkan efisiensi yang baik dengan kemampuan memproses sekitar 2 gambar per detik dan menyimpan hasil pengenalan secara otomatis dalam file dokumen Word, sehingga

memudahkan proses digitalisasi dokumen. Meskipun hasilnya menjanjikan, penelitian ini masih memiliki beberapa keterbatasan, seperti performa yang menurun pada citra dengan blur sangat berat, segmentasi karakter yang kurang optimal pada huruf yang sangat rapat, serta cakupan klasifikasi yang terbatas pada huruf kecil tanpa dukungan angka, tanda baca, atau huruf kapital.

Oleh karena itu, saran untuk penelitian selanjutnya adalah mengembangkan teknik segmentasi karakter yang lebih robust, memperluas cakupan klasifikasi karakter termasuk angka dan simbol, serta mengadaptasi sistem untuk menangani dokumen dengan tata letak kompleks. Selain itu, peningkatan model deblurring agar mampu mengatasi blur yang lebih ekstrem juga menjadi arah penting untuk meningkatkan keandalan sistem OCR pada berbagai kondisi dokumen nyata. Dengan pengembangan tersebut, diharapkan sistem OCR berbasis deep learning ini dapat lebih optimal dan aplikatif dalam digitalisasi dokumen berbahasa Indonesia maupun bahasa lainnya.

## 5. Daftar Pustaka

- Baldominos, A., Saez, Y., & Isasi, P. (2019). A survey of handwritten character recognition with mnist and emnist. *Applied sciences*, 9(15), 3169.
- Fadjeri, A., Asroriyah, A. M., & Rahmawati, A. (2022). Analisis Teks Bahasa Indonesia Dan Inggris Dari Sebuah Citra Menggunakan Pengolahan Citra Digital. *Jurnal Teknologi Informasi Dan Komunikasi (TIKomSiN)*, 10(2), 42-46.
- Giamiko, E. S., & Tjiong, E. (2024). Pengembangan Aplikasi Pengenalan Tulisan Tangan Abjad dan Angka Berbasis Convolutional Neural Network. *KALBISCIENTIA Jurnal Sains dan Teknologi*, 11(02), 22-30. <https://doi.org/10.53008/kalbiscientia.v11i02.3626>.
- Hengaju, U., & Bal, B. K. (2023). Improving the Recognition Accuracy of Tesseract-OCR Engine on Nepali Text Images via Preprocessing. *Advancement in Image Processing and Pattern Recognition*, 3(2), 3.
- Manurung, I. D. P., Hidayatno, A., & Setiyono, B. (2011). Pengenalan Teks Cetak Pada Citra Tekst Biner. *Universitas Diponegoro, Semarang*.
- Mohsenzadegan, K., Tavakkoli, V., & Kyamakya, K. (2022). Deep neural network concept for a blind enhancement of document-images in the presence of multiple distortions. *Applied Sciences*, 12(19), 9601.
- Nugroho, A. W. (2024). PENGGUNAAN MACHINE LEARNING DALAM PENGENALAN TEKS DARI GAMBAR. *Jurnal Dunia Data*, 1(4).
- Nugroho, B., & Puspaningrum, E. Y. (2021). Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 8(3), 533-538.
- Peryanto, A., Yudhana, A., & Umar, R. (2020). Rancang bangun klasifikasi citra dengan teknologi deep learning berbasis metode convolutional neural network. *Format J. Ilm. Tek. Inform*, 8(2), 138.
- Pratiwi, A., Lestari, Y. D., & Lubis, Y. F. A. (2021, October). Analisis Kombinasi Vertical Projection Profile (VPP) Dan Top Down Profile (TDP) Dalam Segmentasi Karakter Pada Aplikasi OCR. In *SEMINAR NASIONAL TEKNOLOGI INFORMASI & KOMUNIKASI* (Vol. 1, No. 1, pp. 470-478).
- Rizqi, A., & Aziz, I. S. (2019). Rancang Bangun Aplikasi Penerjemah Bahasa Jepang-Indonesia Menggunakan OCR Berbasis Android. *SinarFe7*, 2(1), 276-280.
- Septiarini, A. (2016). Pengenalan Pola Pada Citra Digital Dengan Fitur Momen Invariant. *Informatika Mulawarman: Jurnal Ilmiah Ilmu Komputer*, 7(1), 8-11.

- Shaliniswetha, S., & Mahaboob, S. T. (2022). RESIDUAL LEARNING BASED IMAGE DENOISING AND COMPRESSION USING DNCNN. *ICTACT Journal on Image & Video Processing*, 13(2).
- Siliwangi, A. K., & Prabowo, Y. D. (2022). Pencarian Informasi Berbasis Teks dalam Komik Digital Menggunakan OCR. *KALBISLANA Jurnal Sains, Bisnis dan Teknologi*, 8(2), 1886-1894.
- Sulistiyono, M. F. (2022). *Penerjemah Bahasa Inggris-Indonesia Berbasis Mobile Menggunakan Optical Character Recognition & Text To Speech* (Doctoral dissertation, UBP Karawang).
- Wijaya, I., & Lubis, C. (2022). Pengimplementasian Ocr Menggunakan Cnn Untuk Ekstraksi Teks Pada Gambar. *Jurnal Ilmu Komputer dan Sistem Informasi*, 10(1).  
<https://doi.org/10.24912/jiksi.v10i1.17836>.