



## Verifikasi Otomatis Bukti Pembayaran SPP Berbasis OCR pada Sistem Informasi Manajemen Sekolah

Dadan Nuh Faturahman<sup>a</sup>, Achmad Lutfi Fuadi<sup>b</sup>

<sup>a b</sup>Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, Tangerang Selatan, Indonesia

### Article Info

#### Keywords:

Deep learning  
Management information  
system  
OCR  
PaddleOCR  
School fee payment  
Web

### ABSTRACT

This study develops a web-based School Management Information System (SIMS) equipped with a *deep learning* Optical Character Recognition (OCR) module that extracts data from tuition payment receipts at SMK BIT Bina Aulia, Bogor. The system aims to accelerate transaction verification, reduce manual input errors, and improve administrative transparency. The Research and Development method was applied, with the Waterfall model used to construct the product. The OCR module was built on PaddleOCR PP-OCRv4 with DBNet text detection and SVTR\_LCNet text recognition using a CTC decoder, fine tuned on 384 receipt images collected from 14 payment channels and augmented into 14,824 training crops. The best training checkpoint reached 79.04% exact match accuracy with a normalized edit distance of 0.9563 at epoch 90. Evaluated on 940 text crops, the deployed service achieved 94.79% character accuracy, a 5.21% Character Error Rate, a 25.67% Word Error Rate, and 76.60% exact match accuracy, rising to 86.49% when spacing differences are ignored. Fine tuning improved exact match accuracy by 4.05 percentage points, and the proposed model outperformed Tesseract OCR 5 and EasyOCR on every metric. Black box testing of 63 test items and white box basis path testing of 53 independent paths passed without failure.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



### Corresponding Author:

Dadan Nuh Faturahman  
Program Studi Teknik Informatika  
Universitas Pamulang  
Jl. Raya Puspatek No. 46, Buaran, Serpong, Tangerang Selatan, Banten 15310  
Email: [masdadan322@gmail.com](mailto:masdadan322@gmail.com)

## 1. INTRODUCTION

Perkembangan kecerdasan artifisial pada bidang *computer vision* dan *deep learning* telah mengubah cara dokumen berbasis citra diolah [1], [2]. Salah satu turunannya yang berkembang pesat adalah *Optical Character Recognition* (OCR) berbasis *deep learning*, yang mampu mengekstraksi teks dari citra dengan akurasi tinggi meskipun pencahayaan kurang baik, sudut pengambilan tidak ideal, atau format dokumennya tidak terstruktur [3], [4]. Kemampuan tersebut menjadikan OCR modern relevan bagi pekerjaan administratif yang sebelumnya bergantung pada pembacaan dan pengetikan manual.

Penerapan OCR berbasis *deep learning* pada dokumen transaksi telah dibuktikan pada beberapa domain. Otomatisasi pengolahan *invoice* dan struk ritel menunjukkan bahwa mesin OCR modern sanggup mengekstraksi nama vendor, tanggal, item, kuantitas, dan harga secara presisi [5]. Ekstraksi data farmasi dari resep medis memperlihatkan kemampuan yang sama pada dokumen yang memuat teks cetak sekaligus tulisan tangan [6]. Pada konteks keuangan usaha, ekstraksi tanggal dan jumlah transaksi dari citra struk terbukti mengurangi kesalahan input manual sekaligus menghemat waktu pengelolaan data [7]. Ketiga temuan tersebut mempunyai benang merah yang sama, yaitu OCR bekerja paling bermanfaat pada dokumen bervolume tinggi dengan struktur yang berulang.

Karakteristik tersebut ditemukan pada administrasi pembayaran SPP di SMK BIT Bina Aulia, sekolah menengah kejuruan swasta di Jl. Letda Nasir No. 582, Desa Bojong Kulur, Kecamatan Gunung Putri, Kabupaten Bogor. Sekolah ini berada di bawah Yayasan Sa'adatut Da'ian, berakreditasi A, dan memiliki sekitar 500 peserta didik pada kompetensi keahlian Teknik Komputer dan Jaringan, Teknik Bisnis Sepeda Motor, serta Pemasaran. Setiap bulan sekolah menerima bukti pembayaran dalam bentuk struk ATM, bukti transfer bank, dan tangkapan layar mobile banking dengan volume yang cukup tinggi. Variasi format dokumen dan meningkatnya jumlah transaksi menyebabkan verifikasi manual berjalan lambat, rentan kesalahan pencatatan, dan menyulitkan staf administrasi dalam menjamin transparansi rekapitulasi keuangan. Pencatatan yang masih dilakukan pada buku atau lembar spreadsheet juga membuat data pembayaran tidak tersedia secara terpusat dan seketika.

Solusi teknologi untuk masalah tersebut menghadapi persoalan pemilihan mesin OCR. OCR konvensional seperti Tesseract memiliki akurasi yang lebih rendah dibandingkan pendekatan berbasis *deep learning* pada pengenalan teks struk, sebagaimana ditunjukkan melalui benchmarking terhadap Tesseract, EasyOCR, dan Google Vision API [3]. Layanan OCR komersial memang berakurasi tinggi, tetapi menuntut koneksi internet yang stabil dan skema berlangganan sehingga kurang praktis untuk penerapan mandiri berskala sekolah. PaddleOCR menawarkan jalan tengah berupa akurasi tinggi, dukungan pelatihan ulang, serta performa yang relatif stabil pada dokumen tidak terstruktur, dan tersedia sebagai pustaka terbuka yang dapat dijalankan di perangkat lokal [8].

Pada sisi sistem informasi, sistem informasi manajemen yang dirancang dengan baik terbukti meningkatkan efisiensi dan akurasi pengelolaan data organisasi [9]. Pada lingkup sekolah, sistem administrasi pembayaran berbasis *web* dengan *framework* Laravel telah dibuktikan mempercepat rekapitulasi dan menurunkan kesalahan pencatatan dibandingkan prosedur manual [10]. Penerapan OCR pada sistem informasi persuratan berbasis *web* juga menunjukkan bahwa modul pengenalan teks dapat menyatu dengan aplikasi *web* institusional [11], sedangkan pemodelan sistem monitoring pembayaran SPP telah dirumuskan melalui pendekatan Unified Modeling Language [12]. Meskipun demikian, sistem administrasi pembayaran sekolah pada penelitian sebelumnya umumnya berhenti pada pencatatan transaksi dan pelaporan, tanpa memanfaatkan OCR untuk memverifikasi bukti pembayaran secara otomatis.

Celah tersebut menjadi dasar penelitian ini. Belum ditemukan penelitian yang secara khusus melakukan pelatihan ulang model PaddleOCR untuk memverifikasi bukti pembayaran SPP di dalam sebuah Sistem Informasi Manajemen Sekolah, dengan karakteristik bukti pembayaran yang berasal dari beragam kanal pembayaran digital di Indonesia. Kontribusi penelitian ini ada tiga. Pertama, penyusunan dataset bukti pembayaran SPP dari 14 kanal pembayaran beserta pelatihan ulang model PP-OCrv4 di atasnya. Kedua, pengukuran performa model pada layanan yang benar-benar terpasang di perangkat berspesifikasi rendah, bukan hanya pada lingkungan pelatihan berakselerasi GPU, dilengkapi uji ablasi untuk memisahkan kontribusi pelatihan ulang dari kemampuan awal model dasar. Ketiga, integrasi model tersebut ke dalam sistem informasi manajemen sekolah berbasis *web* yang telah diuji secara fungsional dan struktural.

## 2. RESEARCH METHOD

### 2.1 Tahapan Penelitian


Penelitian ini menggunakan metode Research and Development (R&D), yaitu metode penelitian yang ditujukan untuk menghasilkan produk baru atau menyempurnakan produk yang sudah ada sehingga efektivitasnya meningkat dan dapat dipertanggungjawabkan [13], [14]. Metode ini dipilih karena luaran penelitian berupa produk, yakni Sistem Informasi Manajemen Sekolah beserta modul OCR di dalamnya. Tahapan R&D pada penelitian ini meliputi kajian awal dan identifikasi kebutuhan, pengembangan produk, pengujian, serta revisi berdasarkan hasil pengujian.

Data kebutuhan dihimpun melalui tiga teknik. Observasi dilakukan langsung terhadap proses administrasi pembayaran di SMK BIT Bina Aulia. Wawancara dilakukan kepada staf administrasi dan siswa yang terlibat langsung dalam proses pembayaran untuk memperoleh masukan mengenai kegunaan dan kendala yang dihadapi. Studi pustaka dilakukan untuk mendalami konsep sistem informasi, teknologi *web*, *deep learning*, dan OCR.

Pengembangan produk menggunakan model Waterfall, yaitu model pengembangan perangkat lunak sekuensial yang menuntut setiap tahap diselesaikan sepenuhnya sebelum berpindah ke tahap berikutnya [15]. Model ini dipilih karena kebutuhan sistem telah teridentifikasi sejak awal penelitian sehingga tahapan kerja dapat disusun berurutan. Lima tahap yang dijalankan mengacu pada penerapan Waterfall untuk pengembangan aplikasi berbasis kebutuhan operasional [16], yaitu analisis kebutuhan, desain, pengkodean, pengujian, dan pemeliharaan.

## 2.2 Perancangan sistem dan basis data

Sistem dirancang untuk tiga aktor dengan hak akses yang berbeda, yaitu Kepala Sekolah, Admin Tata Usaha, dan Siswa. Kepala Sekolah dapat masuk ke sistem, menambahkan akun pengguna, mengelola data siswa, mengelola data keuangan siswa, mengelola informasi sekolah, dan keluar dari sistem. Admin Tata Usaha memiliki kewenangan yang sama kecuali penambahan akun pengguna. Siswa dapat mengelola data pribadinya, mengelola data keuangan pribadinya termasuk mengunggah bukti pembayaran, serta menampilkan informasi sekolah. Pembagian hak akses ditampilkan pada Gambar 1, disusun dengan notasi *Unified Modeling Language* versi 2.5.1 [17].




Gambar 1 Use case diagram SIMS

Basis data dirancang dengan pendekatan relasional [18] yang terdiri atas tujuh entitas utama, yaitu users, students, spp\_tariffs, spp\_invoices, payments, ocr\_payment\_receipts, dan information. Entitas users menyimpan akun pengguna beserta perannya. Entitas students menyimpan data siswa dan berelasi dengan users sebagai pemilik akun. Setiap siswa dapat memiliki banyak tagihan pada entitas spp\_invoices dengan nominal yang mengacu pada entitas spp\_tariffs. Setiap tagihan yang dibayar dicatat pada entitas payments, dan hasil ekstraksi OCR atas bukti pembayarannya disimpan pada entitas ocr\_payment\_receipts. Entitas information menyimpan pengumuman sekolah. Relasi antarentitas dirumuskan melalui Entity Relationship Diagram [19], kemudian ditransformasikan menjadi Logical Record Structure dan dinormalisasi hingga bentuk normal kedua untuk menghindari redundansi data [20].

## 2.3 Persiapan dataset

Data awal berupa 384 citra bukti pembayaran yang dihimpun dari 14 kanal pembayaran berbeda, mencakup tangkapan layar transaksi mobile banking, struk ATM fisik, dan bukti transfer dompet digital. Penghimpunan dari 14 kanal ditujukan untuk memastikan ketangguhan model terhadap variasi tata letak dan jenis huruf antar institusi keuangan.

Anotasi dilakukan menggunakan perangkat PPOCRLabel [21] dengan mendefinisikan bounding box pada area teks yang memuat informasi penting, yaitu nominal, tanggal, nama pengirim, nama bank, dan nomor referensi. Hasil anotasi memotong citra asli menjadi potongan teks spesifik sebagai satuan pelatihan model pengenalan. Contoh hasil anotasi ditampilkan pada Gambar 2(a).



Gambar 2 Contoh (a) anotasi bukti transfer dan (b) hasil augmentasi citra

Dataset awal dibagi menjadi 80% data latih sebanyak 307 citra dan 20% data uji sebanyak 77 citra. Data uji dipertahankan murni tanpa augmentasi agar performa model dapat dievaluasi secara objektif. Anotasi terhadap 307 citra data latih menghasilkan 1.853 potongan teks, kemudian delapan variasi augmentasi diterapkan sehingga menjadi 14.824 potongan teks siap latih. Variasi augmentasi meliputi penambahan derau, penyesuaian kecerahan, dan manipulasi kontras, sebagaimana dicontohkan pada Gambar 2(b), dengan tujuan mencegah overfitting sekaligus meningkatkan ketahanan model terhadap citra yang buram atau kurang cahaya. Anotasi terhadap 77 citra data uji menghasilkan 940 potongan teks yang menjadi satuan evaluasi pada seluruh pengujian akurasi. Rincian transformasi dataset ditampilkan pada Tabel 1.

Tabel 1 Rincian transformasi dan distribusi dataset

| Tahap                   | Jumlah          | Keterangan                                         |
|-------------------------|-----------------|----------------------------------------------------|
| Data awal               | 384 citra       | Bukti pembayaran asli dari 14 kanal                |
| Data latih              | 307 citra       | 80% dari total dataset awal                        |
| Data uji                | 77 citra        | 20% dari total dataset, murni tanpa augmentasi     |
| Ekstraksi anotasi latih | 1.853 potongan  | Hasil potong teks, rata-rata 6 informasi per bukti |
| Augmentasi data latih   | 14.824 potongan | Delapan variasi atas 1.853 potongan teks           |
| Ekstraksi anotasi uji   | 940 potongan    | Seluruh baris teks dari 77 citra data uji          |

## 2.4 Arsitektur model dan konfigurasi pelatihan ulang

Modul OCR dibangun di atas PaddleOCR PP-OCRv4 yang memisahkan dua tahap kerja, yaitu deteksi teks dengan algoritma DBNet untuk menentukan lokasi baris teks pada citra [22] dan pengenalan teks untuk mengubah setiap potongan menjadi karakter digital [23]. Model dasar yang dipakai pada tahap pengenalan adalah en\_PP-OCRv4\_mobile\_rec yang mengimplementasikan algoritma SVTR\_LCNet dengan backbone PPLCNetV3 dan decoder Connectionist Temporal Classification. Arsitektur ini menggabungkan kekuatan Convolutional Neural Network dalam mengekstraksi fitur spasial [24] dengan pendekatan model visual tunggal untuk pengenalan teks sekuensial [25].

Pelatihan ulang dijalankan pada lingkungan Kaggle [26] dengan akselerasi GPU Tesla T4. Hyperparameter yang dipakai ditampilkan pada Tabel 2. Citra masukan diubah ukurannya menjadi matriks 3 x 48 x 320 piksel. Bobot terbaik hasil pelatihan kemudian diekspor dari format pelatihan menjadi format inference model agar dapat dilayankan tanpa membawa kerangka pelatihan.

Tabel 2 Konfigurasi hyperparameter pelatihan ulang


| Parameter            | Nilai                                                                      |
|----------------------|----------------------------------------------------------------------------|
| Model dasar          | en_PP-OCrv4_mobile_rec<br>(SVTR_LCNet, <i>backbone</i><br>PPLCNetV3)       |
| Jumlah <i>epoch</i>  | 100                                                                        |
| <i>Batch size</i>    | 32 per <i>card</i>                                                         |
| <i>Learning rate</i> | 0,0005 dengan <i>cosine decay</i><br>dan <i>warmup</i> 5 <i>epoch</i> awal |
| <i>Optimizer</i>     | Adam, beta1 0,9 dan beta2<br>0,999                                         |
| Regularisasi         | L2 dengan <i>factor</i> 3e-05                                              |

## 2.5 Integrasi modul OCR ke dalam sistem

Model statis hasil ekspor dilayankan melalui backend FastAPI [27] sebagai layanan terpisah bernama ocr-service, sedangkan aplikasi web dibangun dengan framework Laravel [28] dan basis data MySQL [29]. Pemisahan ini dipilih agar beban komputasi pengenalan teks tidak mengganggu proses aplikasi web, dan agar model dapat diperbarui tanpa menyentuh kode aplikasi.

Keluaran model berupa raw text yang belum terstruktur, sehingga dibutuhkan tahap pascapemrosesan. Karena sistem menerima bukti dari 14 kanal pembayaran dengan tata letak yang berbeda, ekstraksi entitas dilakukan menggunakan Regular Expression pada sisi backend. Pola yang diterapkan mencakup tiga kelompok. Pertama, ekstraksi nominal yang mengenali variasi penulisan angka bersimbol mata uang dan pemisah ribuan seperti Rp600.000, Rp. 600,000, atau IDR 600000, kemudian membersihkan karakter nonnumerik sehingga diperoleh nilai bilangan bulat yang dapat diverifikasi silang dengan nominal tagihan. Kedua, ekstraksi tanggal transaksi yang menangkap format numerik seperti DD/MM/YYYY dan MM-DD-YYYY maupun format alfanumerik seperti 11 Jan 2021. Ketiga, ekstraksi nama bank, nama pengirim, dan nomor referensi yang memanfaatkan kata kunci pemicu seperti PENGIRIM:, Nama:, atau Ke:, serta batasan panjang karakter tertentu.

Hasil penguraian tersebut menjadi objek JSON dengan medan *amount*, *date*, *sender\_name*, dan *reference\_no*, yang selanjutnya dibandingkan dengan data tagihan pada basis data untuk menentukan status verifikasi. Alur lengkap proses OCR pada sistem ditampilkan pada Gambar 3.



Gambar 3 Flowchart proses OCR pada verifikasi pembayaran

## 2.6 Skenario dan metrik pengujian

Pengujian dilakukan pada tiga lapis yang saling melengkapi.

Lapis pertama adalah pengujian fungsional dengan metode black box menggunakan teknik Equivalence Partitioning [30] dan Boundary Value Analysis [31]. Equivalence Partitioning diterapkan dengan membagi kemungkinan masukan setiap modul menjadi kelas valid dan kelas tidak valid, kemudian mengambil satu data perwakilan tiap kelas sebagai kasus uji. Boundary Value Analysis diterapkan pada masukan bernilai batas, yaitu nominal pembayaran yang sama dengan tagihan, lebih kecil dari tagihan, dan lebih besar dari tagihan. Pengujian mencakup tujuh kelas uji, yaitu Login, Data Siswa, Data Keuangan, Data Laporan, Verifikasi Pembayaran Sistem OCR, Data Informasi, dan Logout.

Lapis kedua adalah pengujian struktural dengan metode white box menggunakan teknik Basis Path Testing [32], [33]. Alur logika setiap fungsi dipetakan menjadi flowgraph, kemudian tingkat kompleksitasnya dihitung melalui Cyclomatic Complexity dengan dua rumus sebagaimana ditampilkan pada (1) dan (2), yang hasilnya harus sama agar flowgraph dinyatakan konsisten.

$$V(G) = E - N + 2 \quad (1)$$

$$V(G) = P + 1 \quad (2)$$

E adalah jumlah edge, N adalah jumlah node, dan P adalah jumlah node predikat pada flowgraph. Nilai  $V(G)$  menyatakan jumlah jalur independen yang harus dieksekusi minimal satu kali. Pengujian dilakukan terhadap tujuh fungsi inti, yaitu autentikasi pengguna, pemrosesan pembayaran SPP, verifikasi bukti pembayaran melalui layanan OCR, penambahan data siswa, pembuatan laporan keuangan, pengelolaan informasi sekolah, serta logout dan pengelolaan session, dan dieksekusi menggunakan PHPUnit.

Lapis ketiga adalah pengujian akurasi modul OCR terhadap 940 potongan teks dari 77 citra data uji, yang mencakup 11.546 karakter dan 1.570 kata, dengan acuan kebenaran berupa hasil anotasi manual. Distribusi data uji per kanal pembayaran dan kondisi citra ditampilkan pada Tabel 3. Format citra yang didukung adalah PNG dan JPG. Pengujian dijalankan pada laptop dengan prosesor AMD 3020e berkecepatan 1,20 GHz dan RAM 8 GB tanpa akselerasi GPU, agar hasil pengukuran merepresentasikan perangkat yang tersedia di sekolah.

Tabel 3 Distribusi data uji berdasarkan kanal pembayaran

| No    | Kanal pembayaran | Jumlah citra | Kondisi citra              |
|-------|------------------|--------------|----------------------------|
| 1     | Bank BCA         | 8            | Normal, screenshot, miring |
| 2     | Bank BRI         | 8            | Normal, screenshot, miring |
| 3     | Bank Mandiri     | 7            | Normal, screenshot, miring |
| 4     | Bank BNI         | 7            | Normal, screenshot, miring |
| 5     | Bank BSI         | 6            | Normal, screenshot         |
| 6     | GoPay            | 6            | Normal, screenshot         |
| 7     | DANA             | 5            | Normal, screenshot         |
| 8     | OVO              | 5            | Normal, screenshot         |
| 9     | ShopeePay        | 5            | Normal, screenshot         |
| 10    | Bank BJB         | 4            | Normal, screenshot         |
| 11    | SeaBank          | 4            | Normal, screenshot         |
| 12    | Flip             | 4            | Normal, screenshot         |
| 13    | LinkAja          | 4            | Normal, screenshot         |
| 14    | Bank DKI         | 4            | Normal, miring             |
| Total |                  | 77           |                            |

Metrik yang digunakan dihitung dengan algoritma Levenshtein Distance. Character Error Rate dirumuskan pada (3) dan Word Error Rate pada (4).

$$CER = \frac{S + D + I}{N} \times 100\% \quad (3)$$

$$WER = \frac{Sw + Dw + Iw}{Nw} \times 100\% \quad (4)$$


S, D, dan I adalah jumlah operasi substitusi, penghapusan, dan penyisipan pada tingkat karakter, N adalah total karakter acuan, sedangkan notasi bersubskrip w menyatakan operasi dan satuan yang sama pada tingkat kata. Akurasi karakter dihitung sebagai 1 dikurangi CER. *Normalized Edit Distance* dihitung sebagai 1 dikurangi rata-rata *Levenshtein Distance* antara teks prediksi dan teks acuan yang dinormalisasi terhadap panjang teks terpanjang di antara keduanya, sehingga nilai yang mendekati satu menyatakan kemiripan karakter yang tinggi.

Pengukuran dijalankan pada dua mode. Mode STRICT memperlakukan spasi sebagai karakter yang harus sama persis dengan teks acuan. Mode IGNORE SPACE mengabaikan perbedaan penempatan spasi, dan disertakan karena pada verifikasi pembayaran, perbedaan spasi pada nama pengirim atau nama bank tidak memengaruhi keabsahan data yang diekstraksi. Untuk memisahkan kontribusi pelatihan ulang dari kemampuan awal model dasar, dilakukan uji ablasi yang membandingkan en\_PP-OCRv4\_mobile\_rec sebelum pelatihan ulang dengan model hasil pelatihan ulang, memakai data uji, kamus karakter, algoritma perhitungan, kode evaluasi, dan perangkat yang identik. Sebagai pembanding eksternal, dilakukan pengujian terhadap Tesseract OCR 5 yang mewakili OCR konvensional berbasis Long Short Term Memory tanpa backbone CNN, dan EasyOCR yang memakai CNN ResNet dengan Bidirectional LSTM dan decoder CTC, pada data, metrik, dan perangkat yang sama, dengan setiap model hanya menjalankan tahap pengenalan teks.

### 3. RESULTS AND DISCUSSION

#### 3.1 Implementasi sistem

Sistem berhasil diimplementasikan sebagai aplikasi web dengan tiga tampilan utama sesuai peran pengguna. Perangkat lunak yang digunakan mencakup Laravel dan PHP untuk aplikasi web, Python dan PaddleOCR untuk modul OCR, FastAPI untuk layanan OCR, MySQL untuk basis data, serta Laragon sebagai local web server. Halaman kelola keuangan siswa menampilkan seluruh tagihan SPP bulanan beserta aksi pratinjau, cetak, dan hapus untuk setiap bulan. Ketika siswa atau Admin Tata Usaha mengunggah bukti pembayaran melalui tombol Bayar, sistem mengekstraksi nominal, tanggal transaksi, data pengirim, data penerima, dan nomor referensi dari bukti tersebut, kemudian mencocokkan nominal hasil OCR dengan nominal tagihan. Apabila seluruh elemen tersebut cocok, modal menampilkan status VALID beserta tingkat *confidence* pengenalannya, sebagaimana ditampilkan pada Gambar 4. Pengguna kemudian menekan tombol Simpan Pembayaran agar data pembayaran tercatat ke dalam basis data, namun pencatatan tersebut masih berstatus menunggu peninjauan Admin Tata Usaha, yang melakukan verifikasi akhir atau penolakan dengan merujuk pada hasil ekstraksi OCR yang telah tersedia, sehingga proses peninjauan manual menjadi lebih terbantu dan tidak lagi dimulai dari nol.




Gambar 4 Formulir verifikasi OCR pada halaman kelola keuangan

#### 3.2 Hasil Pelatihan ulang model

Pelatihan dijalankan selama 100 epoch. Nilai MultiLoss yang meliputi CTC Loss dan NRTRLoss menurun konsisten dari 7,93 pada epoch awal menjadi 1,67 pada akhir pelatihan, sebagaimana ditampilkan

pada Gambar 5(a). Penurunan yang stabil tanpa kenaikan pada data uji menunjukkan model mencapai konvergensi tanpa indikasi overfitting.

Evaluasi terhadap data uji dilakukan setiap sepuluh epoch dengan hasil pada Gambar 5(b). Performa terbaik tercatat pada epoch ke-90 dengan akurasi kecocokan penuh 79,04% dan NED 0,9563, pada kecepatan inferensi 172,99 FPS di lingkungan GPU. Nilai NED yang mendekati satu menunjukkan bahwa meskipun sebagian hasil pengenalan tidak identik dengan teks acuan, tingkat kemiripan karakternya sangat tinggi sehingga selisihnya hanya berupa kesalahan pada sedikit karakter. Bobot pada epoch ke-90 tersebut yang kemudian diekspor dan diintegrasikan ke dalam layanan ocr-service.



Gambar 5 Hasil pelatihan ulang PP-OCrv4: (a) kurva MultiLoss dan (b) akurasi serta NED pada data uji

### 3.3 Akurasi sistem OCR terpasang

Pengujian menyeluruh terhadap 940 potongan teks pada layanan yang telah terpasang menghasilkan metrik sebagaimana ditampilkan pada Tabel 4. Pada mode STRICT, sistem mencapai akurasi karakter 94,79% dengan CER 5,21%, WER 25,67%, NED 0,9511, dan akurasi kecocokan penuh 76,60%. Pada mode IGNORE SPACE, akurasi kecocokan penuh meningkat menjadi 86,49% dan akurasi karakter menjadi 95,98% dengan CER 4,02%.

Tabel 4 Hasil pengukuran metrik sistem OCR terpasang pada 940 potongan teks

| Metrik                   | STRICT | IGNORE SPACE |
|--------------------------|--------|--------------|
| Akurasi kecocokan penuh  | 76,60% | 86,49%       |
| Akurasi karakter         | 94,79% | 95,98%       |
| Character Error Rate     | 5,21%  | 4,02%        |
| Word Error Rate          | 25,67% | -            |
| Normalized Edit Distance | 0,9511 | -            |

Selisih antara akurasi kecocokan penuh 76,60% dan akurasi karakter 94,79% menunjukkan bahwa mayoritas kesalahan bukan kegagalan pengenalan menyeluruh, melainkan kesalahan pada satu atau dua karakter dalam satu potongan teks. Kenaikan akurasi menjadi 86,49% pada mode IGNORE SPACE memperkuat pembacaan tersebut, karena berarti hampir sepuluh poin persentase kesalahan pada mode STRICT semata-mata bersumber dari perbedaan penempatan spasi, bukan dari kesalahan pengenalan bentuk karakter.

Kecepatan pengenalan pada perangkat tanpa GPU tercatat 0,2255 detik per potongan teks atau setara 4,43 FPS, dengan nilai median 0,1509 detik per potongan teks. Terdapat perbedaan besar antara 172,99 FPS pada GPU saat pelatihan dan 4,43 FPS pada CPU saat sistem terpasang. Meskipun demikian, kecepatan tersebut masih memadai untuk kebutuhan operasional sekolah karena satu bukti pembayaran memerlukan waktu pemrosesan di bawah tiga detik dan verifikasi tidak dilakukan secara massal pada waktu bersamaan.

Pengujian pada empat skenario representatif menunjukkan tingkat confidence 94,38% pada bukti transfer mobile banking kondisi normal, 98,47% pada kondisi screenshot, 99,59% pada struk ATM kondisi normal, dan 88,57% pada struk ATM kondisi miring. Hasil terbaik diperoleh pada citra berkondisi normal dan berkualitas baik, sedangkan pada citra miring terjadi penurunan confidence disertai kegagalan ekstraksi sebagian medan. Pada struk ATM kondisi normal, nama pengirim tidak berhasil diekstraksi, dan pada struk ATM kondisi miring, nomor referensi tidak berhasil diekstraksi.

### 3.4 Uji ablasi kontribusi pelatihan ulang

Hasil uji ablasi ditampilkan pada Tabel 5. Pada mode STRICT, pelatihan ulang meningkatkan akurasi kecocokan penuh sebesar 4,05 poin persentase, dari 72,55% menjadi 76,60%, menurunkan WER sebesar 2,04 poin persentase, dari 27,71% menjadi 25,67%, menurunkan CER sebesar 0,39 poin persentase, dan menaikkan NED sebesar 0,0095.

Tabel 5 Hasil uji ablasi model sebelum dan sesudah pelatihan ulang

| Metrik                                 | Pra pelatihan ulang | Pasca pelatihan ulang | Selisih |
|----------------------------------------|---------------------|-----------------------|---------|
| Akurasi kecocokan penuh (STRICT)       | 72,55%              | 76,60%                | 4,05    |
| CER (STRICT)                           | 5,60%               | 5,21%                 | -0,39   |
| WER (STRICT)                           | 27,71%              | 25,67%                | -2,04   |
| NED (STRICT)                           | 0,9416              | 0,9511                | 0,0095  |
| Akurasi kecocokan penuh (IGNORE SPACE) | 86,49%              | 86,49%                | 0       |
| CER (IGNORE SPACE)                     | 3,88%               | 4,02%                 | 0,14    |

Temuan yang perlu dikemukakan secara terbuka adalah bahwa peningkatan tersebut hanya terjadi pada mode STRICT. Pada mode IGNORE SPACE, akurasi kecocokan penuh kedua model identik pada 86,49%, dan CER model hasil pelatihan ulang justru sedikit lebih tinggi, yaitu 4,02% berbanding 3,88%. Pola ini menunjukkan bahwa yang dipelajari model selama pelatihan ulang bukan pengenalan bentuk karakter baru, melainkan konvensi penempatan spasi dan tata letak yang khas pada bukti pembayaran perbankan di Indonesia.

Temuan tersebut dapat dijelaskan secara teoretis. Model dasar en\_PP-OCRv4\_mobile\_rec telah dilatih pada korpus besar berisi karakter Latin dan angka, sehingga kemampuan mengenali bentuk huruf dan angka pada bukti transfer sudah memadai sejak awal. Dengan demikian, kontribusi pelatihan ulang pada penelitian ini terletak pada peningkatan konsistensi keluaran teks mentah, bukan pada peningkatan kemampuan pengenalan karakter secara fundamental. Konsistensi tersebut tetap bernilai operasional karena keluaran yang lebih seragam mempermudah kerja pola Regular Expression pada tahap pascapemrosesan.

### 3.5 Perbandingan dengan model OCR lain

Hasil perbandingan terhadap dua model pembanding eksternal ditampilkan pada Tabel 6, yaitu Tesseract OCR 5 yang memakai LSTM tanpa *backbone* CNN dan EasyOCR yang memakai CNN ResNet dengan BiLSTM dan *decoder* CTC, terhadap model yang diusulkan dengan CNN PPLCNetV3, SVTR, dan *decoder* CTC. Model yang diusulkan unggul pada seluruh metrik dan pada kedua mode pengukuran. Pada mode STRICT, akurasi kecocokan penuhnya 76,60% berbanding 62,34% pada Tesseract OCR 5 dan 55,00% pada EasyOCR, dengan CER 5,21% berbanding 11,71% dan 15,84%. Urutan peringkat tidak berubah pada mode IGNORE SPACE, sehingga kesimpulan mengenai model terbaik tidak bergantung pada perlakuan terhadap spasi.

Tabel 6 Perbandingan performa model OCR pada data uji yang sama

| Model           | Kecocokan penuh STRICT | Akurasi karakter STRICT | CER STRI CT | WER STRI CT | NED STRI CT | Kecocokan penuh IGNORE SPACE | Akurasi karakter IGNORE SPACE | CER IGNORE SPACE |
|-----------------|------------------------|-------------------------|-------------|-------------|-------------|------------------------------|-------------------------------|------------------|
| Tesseract OCR 5 | 62,34%                 | 88,29%                  | 11,71%      | 46,94%      | 0,8822      | 73,30%                       | 90,68%                        | 9,32%            |
| EasyOCR         | 55,00%                 | 84,16%                  | 15,84%      | 56,31%      | 0,8391      | 62,77%                       | 86,64%                        | 13,36%           |
| PP-OCRv4        | 76,60%                 | 94,79%                  | 5,21%       | 25,67%      | 0,9511      | 86,49%                       | 95,98%                        | 4,02%            |

Satu hasil yang perlu dijelaskan adalah EasyOCR yang justru kalah dari Tesseract, padahal EasyOCR memakai CNN sedangkan Tesseract tidak. Penyebabnya terletak pada domain data latih masing-masing model. EasyOCR dilatih untuk scene text, yaitu teks pada papan nama dan rambu jalan, sehingga terbiasa dengan bentuk huruf dan latar yang beragam. Bukti pembayaran SPP justru menyerupai dokumen cetak dengan huruf beraturan dan latar bersih, dan itu wilayah kekuatan Tesseract. Dengan demikian, keunggulan arsitektur berbasis CNN [24] baru terasa apabila domain data latihnya sesuai dengan data yang diproses, dan syarat tersebut dipenuhi oleh PP-OCRv4. Temuan ini sejalan dengan penelitian yang melaporkan bahwa pendekatan berbasis *deep learning* mengungguli Tesseract dan EasyOCR pada citra struk tercetak [3], sekaligus menegaskan bahwa kecocokan domain lebih menentukan daripada kompleksitas arsitektur semata.

Hasil ini juga sebanding dengan penelitian terdahulu pada domain dokumen keuangan lain. Penerapan PaddleOCR pada otomatisasi invoice melaporkan CER dan WER yang rendah pada citra invoice dan struk ritel [5], sedangkan pelatihan ulang model Transformer pada formulir keuangan melaporkan penurunan CER yang signifikan setelah dikombinasikan dengan pra-pemrosesan citra [4]. Penelitian ini memperluas temuan tersebut ke ranah bukti pembayaran pendidikan dari 14 kanal pembayaran digital di Indonesia, sekaligus melaporkan performanya pada perangkat tanpa akselerasi GPU.

### 3.6 Hasil pengujian fungsional dan struktural

Pengujian black box terhadap tujuh kelas uji menghasilkan 63 butir uji yang seluruhnya berstatus diterima, mencakup 8 butir pada modul Login, 7 butir pada Data Siswa, 5 butir pada Data Keuangan, 6 butir pada Verifikasi Pembayaran Sistem OCR, 16 butir pada Data Laporan, 11 butir pada Data Informasi, dan 10 butir pada Logout. Pada modul verifikasi OCR, sistem terbukti menerima pembayaran ketika nominal pada bukti transfer sesuai tagihan, menampilkan notifikasi ketidaksesuaian ketika nominal atau nama pengirim berbeda dari data sistem, dan tetap memproses pengajuan dengan status menunggu verifikasi manual ketika layanan OCR tidak berjalan.

Pengujian white box dengan Basis Path Testing terhadap tujuh fungsi inti menghasilkan 53 jalur independen sebagaimana ditampilkan pada Tabel 7. Perhitungan Cyclomatic Complexity pada setiap fungsi menggunakan (1) dan (2) menghasilkan nilai yang identik, sehingga flowgraph yang disusun terbukti konsisten. Seluruh jalur yang dapat dicapai telah dieksekusi menggunakan PHPUnit melalui 43 kasus uji dengan 160 asersi, dan seluruhnya menghasilkan keluaran yang sesuai harapan tanpa satu pun kegagalan. Fungsi verifikasi bukti pembayaran melalui layanan OCR memiliki kompleksitas tertinggi dengan V(G) sebesar 13, yang wajar karena fungsi tersebut menangani pemanggilan layanan eksternal, penguraian hasil ekstraksi, pencocokan terhadap data tagihan, sekaligus penanganan kegagalan layanan.

Tabel 7 Hasil pengujian white box dengan Basis Path Testing

| No                     | Fungsi                                          | E  | N  | P  | V(G) |
|------------------------|-------------------------------------------------|----|----|----|------|
| 1                      | Autentikasi login                               | 26 | 20 | 7  | 8    |
| 2                      | Proses pembayaran SPP                           | 36 | 27 | 10 | 11   |
| 3                      | Verifikasi bukti pembayaran melalui layanan OCR | 37 | 26 | 12 | 13   |
| 4                      | Tambah data siswa                               | 20 | 17 | 4  | 5    |
| 5                      | Tambah laporan keuangan                         | 23 | 18 | 6  | 7    |
| 6                      | Tambah informasi sekolah                        | 26 | 20 | 7  | 8    |
| 7                      | Logout dan pengelolaan session                  | 5  | 6  | 0  | 1    |
| Total jalur independen |                                                 |    |    |    | 53   |

## 4. CONCLUSION

Penelitian ini menghasilkan Sistem Informasi Manajemen Sekolah berbasis web dengan modul OCR berbasis *deep learning* untuk memverifikasi bukti pembayaran SPP di SMK BIT Bina Aulia, Bogor. Tujuan yang dinyatakan pada bagian pendahuluan tercapai pada keempat butirnya. Otomatisasi verifikasi terwujud melalui integrasi model PP-OCRv4 hasil pelatihan ulang ke dalam layanan FastAPI, dengan waktu pengenalan 0,2255 detik per potongan teks pada perangkat tanpa GPU. Pengurangan kesalahan input tercapai melalui ekstraksi berbasis Regular Expression di atas keluaran model yang berakurasi karakter 94,79% dengan CER 5,21%. Peningkatan akurasi dan ketepatan waktu rekapitulasi tercapai melalui basis data relasional tujuh entitas yang menyimpan seluruh transaksi secara terpusat, dan kebenaran logikanya diverifikasi melalui 53 jalur independen yang lolos pada 43 kasus uji dengan 160 asersi tanpa kegagalan. Pengelolaan data yang terpusat dan seketika terwujud pada satu alur kerja unggah, ekstraksi, validasi, penyimpanan, dan penyajian informasi yang seluruh butir uji fungsionalnya diterima.

Temuan yang paling perlu dicatat adalah bahwa pelatihan ulang meningkatkan akurasi kecocokan penuh sebesar 4,05 poin persentase pada mode STRICT, tetapi tidak mengubah akurasi pada mode IGNORE SPACE. Kontribusi pelatihan ulang karenanya terletak pada konsistensi penempatan spasi dan tata letak keluaran, bukan pada kemampuan pengenalan bentuk karakter yang sudah dimiliki model dasar. Model yang diusulkan tetap mengungguli Tesseract OCR 5 dan EasyOCR pada seluruh metrik dan pada kedua mode pengukuran.

Pengembangan lanjutan disarankan pada empat arah. Pertama, perluasan dataset ke arah karakteristik yang benar-benar berbeda dari data latih model dasar, khususnya tulisan tangan, resolusi rendah, dan pencahayaan buruk, karena uji ablasi menunjukkan penambahan data yang karakteristiknya serupa hanya memberi peningkatan terbatas. Kedua, penambahan pembayaran daring langsung agar pembayaran dan verifikasi berada pada satu platform. Ketiga, penguatan keamanan melalui enkripsi data dan autentikasi berlapis. Keempat, pengukuran tingkat penerimaan pengguna melalui kuesioner terhadap kepala sekolah, staf

tata usaha, dan siswa, agar efektivitas sistem dinilai tidak hanya dari akurasi teknis tetapi juga dari kemudahan penggunaan.

## REFERENCES

- [1] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. Cambridge, MA, USA: MIT Press, 2016.
- [2] L. Abdiansah, S. Sumarno, A. Eviyanti, and N. L. Azizah, "Penerapan algoritma convolutional neural networks untuk pengenalan tulisan tangan aksara Jawa," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 2, pp. 496–504, 2025, doi: 10.57152/malcom.v5i2.1814.
- [3] C. Sayallar, A. Sayar, and N. Babalik, "An OCR engine for printed receipt images using *deep learning* techniques," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 2, pp. 833–840, 2023, doi: 10.14569/IJACSA.2023.0140295.
- [4] R. Surya, "Peningkatan akurasi OCR dalam pemrosesan formulir keuangan melalui fine-tuning transformer dan strategi pra-pemrosesan data," *J. Inov. Inform.*, vol. 7, no. 2, pp. 1–12, 2025, doi: 10.51170/jii.v7i2.85.
- [5] J. K. Manipatruni, R. Gnana Sree, R. Padakanti, S. Naroju, and B. K. Depuru, "Leveraging artificial intelligence for simplified invoice automation: Paddle OCR-based text extraction from invoices," *Int. J. Innov. Sci. Res. Technol.*, vol. 8, no. 9, 2023, doi: 10.5281/zenodo.8409861.
- [6] S. Khod, J. Patil, P. Patil, and M. Mali, "Extraction of pharmaceutical data from medical prescriptions using optical character recognition (OCR) model," *Int. J. Multidiscip. Res.*, vol. 6, no. 6, 2024, doi: 10.36948/ijfmr.2024.v06i06.30545.
- [7] L. Khoirani, R. Ariansyah, and S. Supiyandi, "Implementasi algoritma OCR (*optical character recognition*) untuk ekstraksi informasi dari citra struk transaksi keuangan," *Mars J. Tek. Mesin Ind. Elektro Ilmu Komput.*, vol. 2, no. 6, pp. 151–160, 2024, doi: 10.61132/mars.v2i6.537.
- [8] C. Cui et al., "PaddleOCR 3.0 technical report," arXiv:2507.05595, 2025, doi: 10.48550/arXiv.2507.05595.
- [9] K. C. Laudon and J. P. Laudon, *Management Information Systems: Managing the Digital Firm*, 17th ed. Harlow, U.K.: Pearson Education, 2022.
- [10] S. Arifin, Asroni, and A. Kurnianti, "Development of a web-based school payment administration information system using the *Laravel framework*," *Emerg. Inf. Sci. Technol.*, vol. 2, no. 1, pp. 8–15, 2021, doi: 10.18196/eist.v2i1.16857.
- [11] S. N. K. Lisa, F. Santoso, and S. Sunardi, "Implementasi optical character recognition (OCR) pada sistem informasi persuratan berbasis web di Kantor IKSASS Alumni," *Karsanusa*, 2025. [Online]. Available: <https://journalng.uwks.ac.id/karsanusa/article/view/671>
- [12] J. Hendrawan, I. D. Perwitasari, Z. Hasyati, and D. S. Hasanah, "Model UML sistem informasi monitoring pembayaran SPP siswa SMA Negeri 1 Binjai," *J. Minfo Polgan*, vol. 13, no. 2, pp. 1823–1831, 2024, doi: 10.33395/jmp.v13i2.14270.
- [13] A. Rustamana, K. H. Sahl, D. Ardianti, and A. H. S. Solihin, "Penelitian dan pengembangan (research & development) dalam pendidikan," *J. Bima Pusat Publ. Ilmu Pendidik. Bhs. Sastra*, vol. 2, no. 3, pp. 60–69, 2024, doi: 10.61132/bima.v2i3.1014.
- [14] O. Okpatrioka, "Research and development (R&D) penelitian yang inovatif dalam pendidikan," *Dharma Acariya Nusantara. J. Pendidik. Bhs. Budaya*, vol. 1, no. 1, pp. 86–100, 2023. [Online]. Available: <https://e-journal.nalanda.ac.id/index.php/jdan/article/download/154/150>
- [15] T. Pricillia and Zulfachmi, "Perbandingan metode pengembangan perangkat lunak (waterfall, prototype, RAD)," *J. Bangkit Indones.*, vol. 10, no. 1, pp. 6–12, 2021, doi: 10.52771/bangkitindonesia.v10i1.153.
- [16] M. Mailasari, M. N. Winnarto, and A. Purnamawati, "Penerapan metode waterfall dalam pengembangan aplikasi schedule maintenance alat produksi," *Infotek J. Inform. Teknol.*, vol. 7, no. 1, pp. 133–141, 2024, doi: 10.29408/jit.v7i1.24080.
- [17] Object Management Group, "OMG Unified Modeling Language (OMG UML), version 2.5.1," 2017. [Online]. Available: <https://www.omg.org/spec/UML/2.5.1/PDF>
- [18] E. F. Codd, "A relational model of data for large shared data banks," *Commun. ACM*, vol. 13, no. 6, pp. 377–387, Jun. 1970, doi: 10.1145/362384.362685.
- [19] K. Afifah, Z. F. Azzahra, and A. D. Anggoro, "Analisis teknik Entity-Relationship Diagram dalam perancangan database: Sebuah literature review," *INTECH Inform. Teknol.*, vol. 3, no. 2, pp. 70–74, 2022, doi: 10.54895/intech.v3i2.1682.
- [20] S. Suriyati et al., "Implementasi teknik normalisasi basis data untuk menghindari redundansi data pada sistem penjualan," *J. Inf. Syst. Inform. Comput.*, vol. 10, no. 1, pp. 30–35, 2026, doi: 10.52362/jisicom.v10i1.2354.
- [21] PaddleOCR Team, "PPOCRLabel," PaddleOCR official repository, 2026. [Online]. Available: <https://github.com/PaddlePaddle/PaddleOCR/blob/main/PPOCRLabel/README.md>
- [22] PaddleOCR Team, "Text detection module usage guide," PaddleOCR official documentation, 2026. [Online]. Available: [https://paddlepaddle.github.io/PaddleOCR/main/en/version3.x/module\\_usage/text\\_detection.html](https://paddlepaddle.github.io/PaddleOCR/main/en/version3.x/module_usage/text_detection.html)
- [23] PaddleOCR Team, "Text recognition module tutorial," PaddleOCR official documentation, 2026. [Online]. Available: [https://paddlepaddle.github.io/PaddleOCR/main/en/version3.x/module\\_usage/text\\_recognition.html](https://paddlepaddle.github.io/PaddleOCR/main/en/version3.x/module_usage/text_recognition.html)
- [24] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, Nov. 1998, doi: 10.1109/5.726791.
- [25] Y. Du et al., "SVTR: Scene text recognition with a single visual model," arXiv:2205.00159, 2022, doi: 10.48550/arXiv.2205.00159.
- [26] Kaggle, "About Kaggle," 2026. [Online]. Available: <https://www.kaggle.com/about>
- [27] FastAPI Team, "FastAPI," FastAPI official documentation, 2026. [Online]. Available: <https://fastapi.tiangolo.com/>
- [28] Laravel Team, "Installation: Meet Laravel," Laravel official documentation, 2026. [Online]. Available: <https://laravel.com/docs/master>
- [29] Oracle Corporation, "What is MySQL? MySQL 8.4 reference manual," 2026. [Online]. Available: <https://dev.mysql.com/doc/refman/8.4/en/what-is-mysql.html>
- [30] M. Ilham, D. Apriansyah, M. R. Nurhakiki, N. Apriani, and A. Saifudin, "Pengujian black box pada aplikasi ecommerce berbasis website menggunakan teknik equivalence partitions," *OKTAL J. Ilmu Komput. Sci.*, vol. 2, no. 7, pp. 1958–1966, 2023.
- [31] E. Setiana, M. R. Ramadhan, Budiman, and R. Y. Rakhman A., "Pengujian perangkat lunak metode black box pada aplikasi sistem pakar pola latihan dan asupan makanan," *Nuansa Inform.*, vol. 18, no. 1, pp. 68–74, 2024, doi: 10.25134/ilkom.v18i1.67.
- [32] M. G. A. Al Khamaeni, "Implementasi white box testing berbasis path pada aplikasi berbasis web," *J. Siliwangi Seri Sains Teknol.*, vol. 9, no. 1, pp. 8–13, 2023, doi: 10.37058/jssainstek.v9i1.4109.
- [33] H. R. R. Zen and I. Nuryasin, "Penerapan whitebox testing pada pengujian sistem menggunakan teknik basis path," *JOISIE J. Inf. Syst. Inform. Eng.*, vol. 8, no. 1, pp. 101–111, 2024, doi: 10.35145/joisie.v8i1.4229.