

Optimasi Ekstraksi Fitur Citra Karakter Font Menggunakan Algoritma Support Vector Machines (SVM) untuk Klasifikasi Tipografi

Zumhur Alamin^{1*}, Sutriawan¹, Siti Mutmainah¹, Muhammad Hayun²

¹Universitas Muhammadiyah Bima

²Universitas Nusa Cendana Kupang

* Email Korespondensi: zumhur@umbima.ac.id

Abstrak: Klasifikasi tipografi berbasis citra karakter merupakan salah satu tantangan penting dalam bidang pengenalan pola dan pengolahan citra digital, terutama dalam konteks digitalisasi dokumen dan sistem OCR (Optical Character Recognition). Penelitian ini bertujuan untuk mengoptimalkan proses ekstraksi fitur citra karakter font dengan memanfaatkan kombinasi beberapa teknik fitur serta algoritma Support Vector Machines (SVM) untuk klasifikasi. Metode yang digunakan melibatkan preprocessing citra karakter, ekstraksi fitur menggunakan Histogram of Oriented Gradients (HOG), Local Binary Pattern (LBP), dan Zoning, serta pelatihan model SVM dengan kernel Radial Basis Function (RBF). Dataset yang digunakan terdiri dari 2.600 citra karakter dalam format grayscale yang berasal dari lima jenis font populer. Dataset ini dibagi menjadi data latih dan data uji untuk keperluan pelatihan dan evaluasi model. Hasil eksperimen menunjukkan bahwa kombinasi fitur HOG dan Zoning menghasilkan akurasi klasifikasi tertinggi sebesar 94,6%, mengungguli teknik fitur tunggal maupun kombinasi dua fitur lainnya. Temuan ini menunjukkan bahwa pemilihan dan penggabungan teknik ekstraksi fitur yang tepat secara signifikan meningkatkan performa klasifikasi tipografi citra karakter. Penelitian ini memberikan kontribusi dalam pengembangan sistem klasifikasi font yang lebih akurat dan efisien, serta membuka peluang aplikasi lebih lanjut dalam digital forensik, sistem pencarian berbasis citra, dan digitalisasi arsip.

Kata Kunci: Klasifikasi Tipografi, Citra Karakter, Ekstraksi Fitur, SVM, OCR

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).



1. Pendahuluan

Digitalisasi informasi telah menjadi kebutuhan dalam berbagai bidang, mulai dari pendidikan, perkantoran, hingga industri kreatif. Dalam proses digitalisasi tersebut, sistem pengenalan karakter optik atau Optical Character Recognition (OCR) berperan penting dalam mentransformasikan dokumen cetak menjadi data digital yang dapat diproses secara otomatis [1], [2], [3], [4]. Salah satu aspek penting dalam sistem OCR dan pengolahan dokumen digital adalah kemampuan untuk mengenali dan mengklasifikasikan jenis font atau tipografi yang digunakan dalam teks [3], [5], [6]. Informasi mengenai font tidak hanya memiliki nilai estetika, melainkan juga dapat merepresentasikan konteks, gaya, bahkan orisinalitas dokumen tertentu [5].

Meski terlihat sederhana, klasifikasi font karakter merupakan tantangan tersendiri dalam bidang *image processing* dan *image mining*. Hal ini disebabkan oleh tingginya variasi bentuk huruf, ketebalan garis, serta kemiripan struktur antar-font yang sering kali membuat proses identifikasi menjadi kompleks [7], [8].

Untuk mengatasi permasalahan tersebut, diperlukan pendekatan cerdas berbasis kecerdasan buatan yang mampu mengenali dan membedakan pola-pola visual secara halus dan akurat [9], [10]. Dalam konteks ini, *image mining* menjadi salah satu pendekatan yang menjanjikan, karena mampu menggabungkan teknik ekstraksi fitur dengan algoritma pembelajaran mesin (*machine learning*) untuk menemukan pola-pola tersembunyi dalam data visual secara otomatis dan efisien.

Salah satu algoritma yang terbukti andal dalam menyelesaikan masalah klasifikasi adalah *Support Vector Machines* (SVM) yang merupakan metode pembelajaran terawasi terkemuka yang banyak digunakan untuk tugas klasifikasi, terutama efektif di ruang dimensi tinggi dan dengan kumpulan data terbatas, membuatnya cocok untuk aplikasi seperti klasifikasi font [11], [12]. SVM beroperasi dengan membangun hyperplane optimal yang secara maksimal memisahkan kelas yang berbeda, sehingga memastikan margin yang jelas di antara mereka [13]. Kinerja algoritma secara signifikan dipengaruhi oleh kualitas representasi fitur yang berasal dari data input, karena SVM bergantung pada fungsi kernel untuk memproyeksikan data ke dimensi yang lebih tinggi di mana pemisahan linier dapat dicapai [11], [14]. Ketahanan dan kemampuan beradaptasi SVM menjadikannya alat standar dalam pembelajaran mesin dan penambahan data [12]. Namun demikian, performa SVM sangat bergantung pada kualitas representasi fitur yang dihasilkan dari citra.

Dalam proses klasifikasi berbasis citra, teknik ekstraksi fitur memainkan peran krusial dalam mereduksi dimensi data mentah menjadi representasi bermakna yang menggambarkan karakteristik penting seperti bentuk, tekstur, dan distribusi spasial [15]. Tiga teknik yang umum digunakan dalam domain ini adalah Histogram of Oriented Gradients (HOG), Local Binary Pattern (LBP), dan Zoning. HOG efektif dalam menangkap orientasi kontur serta informasi tepi dan gradien [16], [17], menjadikannya sangat cocok untuk mendeteksi arah objek [18]; LBP unggul dalam menggambarkan tekstur lokal melalui perbandingan intensitas piksel [19], [20], sehingga mampu mengatasi variasi pencahayaan dan transformasi [21], [22]; sementara Zoning membagi citra ke dalam grid untuk menghitung kepadatan piksel pada tiap zona [23], yang berkontribusi terhadap pemetaan spasial fitur. Kombinasi teknik-teknik ini dipercaya dapat memperkaya informasi fitur yang digunakan dalam pelatihan model klasifikasi [15], [22], [23]. Integrasi HOG dan LBP, misalnya, telah terbukti meningkatkan performa klasifikasi dengan menggabungkan informasi tekstur lokal dan global, yang sangat berguna dalam mengenali pola kompleks [21]. Selain itu, penelitian menunjukkan bahwa penerapan teknik ekstraksi fitur ini bersama dengan pengklasifikasi seperti Support Vector Machines (SVM) dapat menghasilkan akurasi tinggi dalam berbagai aplikasi [24].

Penelitian terdahulu menunjukkan bahwa kombinasi antara teknik ekstraksi fitur dan algoritma klasifikasi dapat menghasilkan model yang kuat. Dalal et al. [25] menunjukkan bahwa fitur HOG yang dikombinasikan dengan SVM dapat meningkatkan akurasi kinerja deteksi pejalan kaki, mencapai “pemisahan yang hampir sempurna pada basis data pejalan kaki MIT yang asli”. Sementara itu, Darwish dan Elzoghaly [26] menekankan pentingnya teknik pra-pemrosesan dan pemilihan fitur dalam meningkatkan akurasi klasifikasi font dalam bahasa Arab. Meskipun demikian, kajian mendalam mengenai optimasi kombinasi teknik ekstraksi fitur khusus untuk klasifikasi font karakter berbasis citra masih terbatas, terutama dalam konteks tipografi huruf Latin digital yang banyak digunakan saat ini.

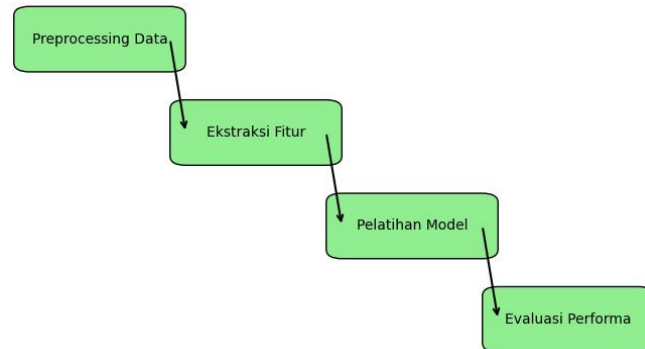
Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengevaluasi performa beberapa teknik ekstraksi fitur populer dalam pengolahan citra karakter font, mengukur akurasi klasifikasi font menggunakan algoritma SVM dengan konfigurasi kernel optimal, serta mengidentifikasi kombinasi fitur terbaik yang mampu menghasilkan klasifikasi tipografi yang akurat dan efisien. Hasil dari penelitian ini diharapkan dapat berkontribusi dalam pengembangan sistem klasifikasi font otomatis yang lebih cerdas, cepat, dan presisi, serta membuka peluang aplikasi di bidang pencarian dokumen, digital forensik, dan sistem pengarsipan berbasis konten visual.

2. Metode

2.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan tujuan mengevaluasi efektivitas berbagai teknik ekstraksi fitur citra dalam klasifikasi font karakter menggunakan algoritma Support Vector Machines (SVM). Eksperimen dilakukan melalui serangkaian proses yang melibatkan preprocessing data, ekstraksi fitur, pelatihan model, dan evaluasi performa klasifikasi. Model SVM

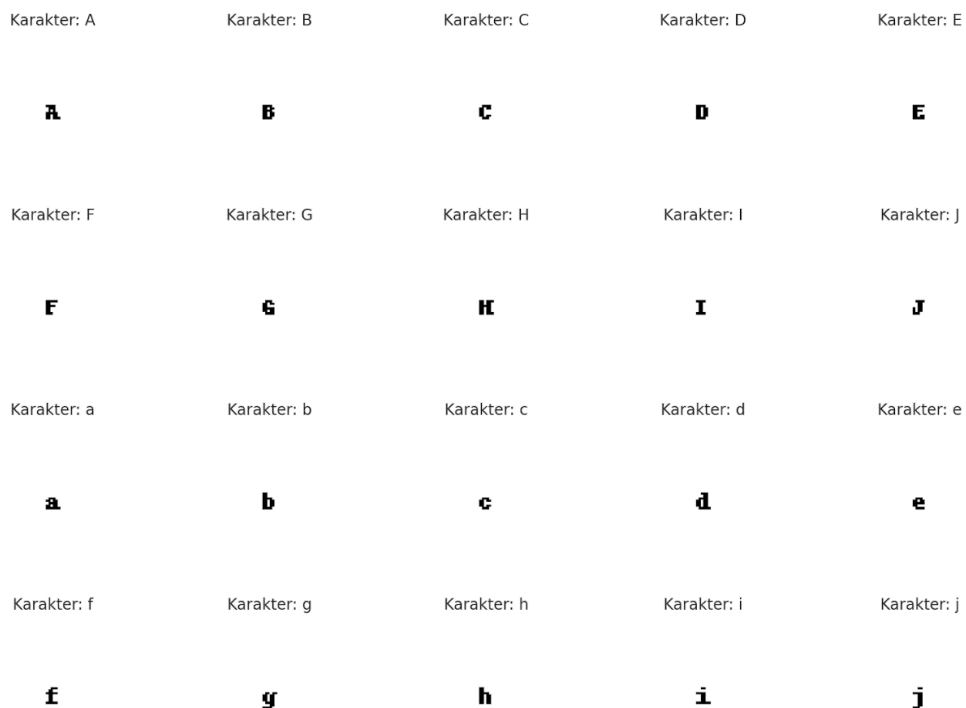
diterapkan dengan kernel Radial Basis Function (RBF), karena kernel ini dikenal efektif untuk masalah non-linear. Model dilatih menggunakan 80% data, dan 20% sisanya digunakan sebagai data uji. Berikut ini merupakan representasi dari tahapan eksperimen yang dilakukan dalam penelitian ini. Proses eksperimen yang ditampilkan dalam Gambar 1 terdiri dari empat tahap utama yang saling berurutan, dimulai dari *preprocessing* data hingga evaluasi performa model klasifikasi.



Gambar 1. Tahapan Eksperimen Klasifikasi Citra Karakter Font Menggunakan SVM

2.2. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 2.600 citra karakter alfabet dalam format grayscale, yang dihasilkan dari lima jenis font populer, yaitu Arial, Times New Roman, Courier New, Calibri, dan Verdana. Setiap font mencakup seluruh karakter alfabet huruf besar (A–Z) dan huruf kecil (a–z), dengan masing-masing karakter direpresentasikan dalam citra beresolusi tetap 64×64 piksel. Dataset ini dikembangkan secara manual menggunakan perangkat lunak pembuat font, kemudian diproses secara otomatis menggunakan bahasa pemrograman Python untuk memastikan konsistensi dan efisiensi dalam pengolahan data. Proses *preprocessing* yang dilakukan mencakup normalisasi nilai piksel ke dalam rentang [0, 1], penyesuaian ukuran gambar, serta segmentasi karakter individual untuk memastikan setiap citra hanya berisi satu karakter. Gambar 2 berikut menyajikan contoh representasi karakter dari font Arial yang digunakan sebagai data uji.



Gambar 2. Contoh Karakter Uji (Font Arial)

2.3. Preprocessing Citra

Proses *preprocessing* citra dilakukan untuk memastikan kualitas data input yang optimal sebelum digunakan dalam pelatihan dan pengujian model. Tahapan pertama adalah konversi seluruh citra ke dalam format skala abu-abu (*grayscale*), yang bertujuan untuk menyederhanakan informasi warna sekaligus mengurangi kompleksitas komputasi. Selanjutnya, metode *Otsu Thresholding* diterapkan untuk memisahkan objek utama (karakter) dari latar belakang secara otomatis berdasarkan nilai ambang optimal. Setelah itu, seluruh citra dinormalisasi ukurannya menjadi 64×64 piksel guna menjaga konsistensi dimensi input. Terakhir, untuk mengurangi gangguan visual pada citra, diterapkan filter median sebagai teknik penghilangan noise (*noise removal*) tanpa mengorbankan detail penting pada karakter.

2.4. Teknik Ekstraksi Fitur

Penelitian ini menggunakan tiga teknik utama ekstraksi fitur:

1. **Histogram of Oriented Gradients (HOG):** Digunakan untuk menangkap orientasi tepi dan bentuk lokal karakter. Fitur HOG efektif dalam pengenalan pola berbasis bentuk [27].
2. **Local Binary Pattern (LBP):** Digunakan untuk menangkap tekstur lokal dari citra karakter, yang sering kali membedakan satu font dari yang lain [28].
3. **Zoning:** Citra dibagi menjadi grid 4×4, dan jumlah piksel hitam dihitung di setiap zona sebagai representasi spasial distribusi piksel.

Setiap fitur diekstraksi secara individu dan dalam kombinasi (misal: HOG+LBP, HOG+Zoning, dll) untuk mengevaluasi kontribusi masing-masing terhadap akurasi klasifikasi.

2.5. Tools dan Lingkungan Eksperimen

Eksperimen dalam penelitian ini dilakukan menggunakan perangkat lunak Python versi 3.10 dengan memanfaatkan sejumlah pustaka utama yang mendukung proses pengolahan dan analisis data. Pustaka *scikit-learn* digunakan untuk implementasi algoritma Support Vector Machine (SVM) serta evaluasi performa model. Proses *preprocessing* citra dilakukan menggunakan *OpenCV*, sementara *matplotlib* dimanfaatkan untuk keperluan visualisasi data. Selain itu, *numpy* dan *pandas* digunakan dalam proses manipulasi dan pengelolaan data numerik maupun tabular. Seluruh proses pengujian dijalankan pada laptop dengan spesifikasi perangkat keras berupa prosesor Intel Core i7, RAM 16GB, serta sistem operasi Windows 11 64-bit.

2.6. Evaluasi dan Validasi

Evaluasi kinerja model dilakukan dengan menggunakan beberapa metrik klasifikasi untuk memastikan akurasi dan keandalan hasil prediksi. Metrik utama yang digunakan meliputi akurasi, yaitu proporsi klasifikasi yang benar terhadap total data uji, serta *precision*, *recall*, dan *F1-score* yang dihitung untuk setiap kelas dan dirata-ratakan secara makro guna memperoleh gambaran menyeluruh terhadap performa model. Selain itu, *confusion matrix* dimanfaatkan untuk menganalisis kesalahan klasifikasi secara lebih mendalam. Untuk memastikan generalisasi model dan mengurangi risiko *overfitting*, validasi performa dilakukan menggunakan metode *k-fold cross validation* dengan nilai *k* sebesar 5. Metode ini memungkinkan model diuji secara menyeluruh pada berbagai subset data.

3. Hasil dan Pembahasan

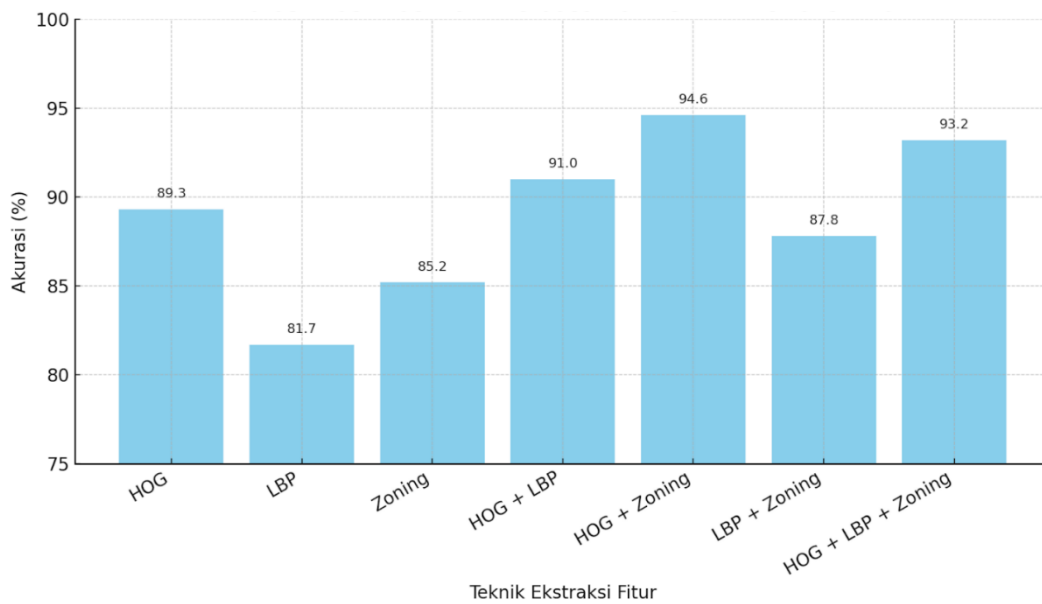
3.1 Kinerja Akurasi Berdasarkan Teknik Ekstraksi Fitur

Evaluasi awal difokuskan pada analisis performa klasifikasi berdasarkan berbagai teknik ekstraksi fitur tunggal maupun kombinasi. Tiga teknik utama yang digunakan dalam penelitian ini meliputi Histogram of Oriented Gradients (HOG), Local Binary Pattern (LBP), dan metode Zoning. Setiap teknik diuji secara individual dan dikombinasikan untuk mengevaluasi dampaknya terhadap akurasi klasifikasi karakter font menggunakan algoritma Support Vector Machines (SVM). Eksperimen dilakukan pada kombinasi teknik ekstraksi fitur menggunakan model klasifikasi SVM dengan kernel RBF. Tabel 1 menyajikan akurasi klasifikasi untuk masing-masing teknik dan kombinasi teknik yang digunakan dalam proses ekstraksi fitur.

Tabel 1. Akurasi Klasifikasi Font Berdasarkan Teknik Ekstraksi Fitur

Teknik Ekstraksi Fitur	Akurasi (%)
HOG	89,3
LBP	81,7
Zoning	85,2
HOG + LBP	91,0
HOG + Zoning	94,6
LBP + Zoning	87,8
HOG + LBP + Zoning	93,2

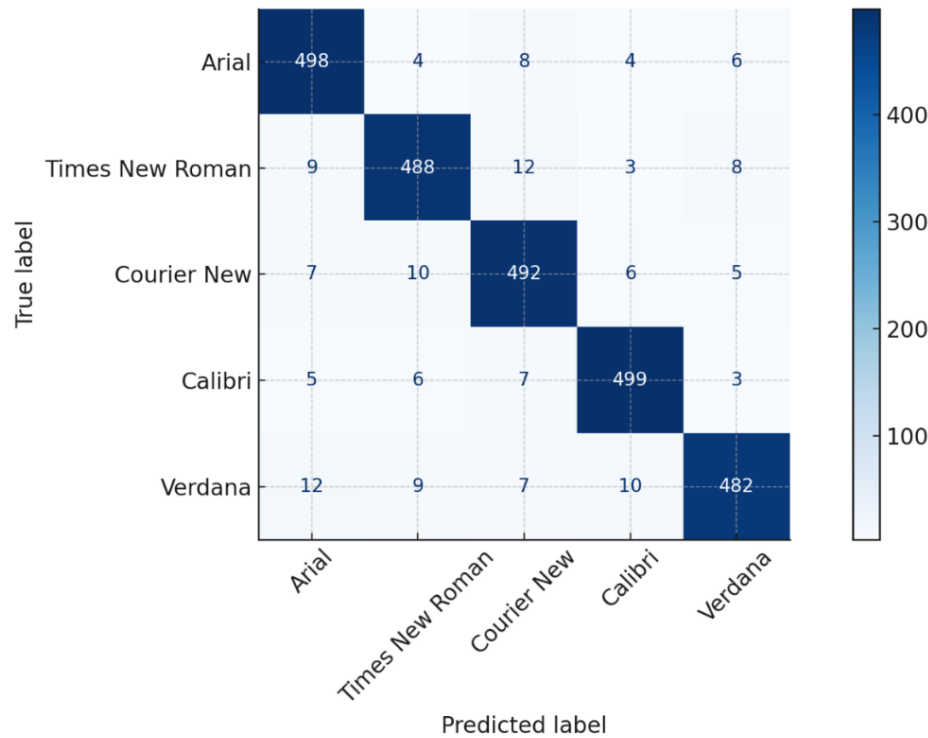
Hasil penelitian menunjukkan bahwa kombinasi teknik ekstraksi fitur HOG + Zoning menghasilkan akurasi tertinggi sebesar 94,6%, disusul oleh kombinasi tiga teknik (HOG + LBP + Zoning) dengan akurasi 93,2%. Temuan ini menegaskan keunggulan fitur spasial dari Zoning yang mampu menangkap distribusi karakter secara global, serta kontribusi HOG yang sensitif terhadap kontur dan bentuk lokal huruf. Agar lebih memperjelas hasil ini, berikut visualisasi grafik pada Gambar 3 memperlihatkan tren peningkatan akurasi seiring dengan penggabungan teknik ekstraksi fitur

**Gambar 3.** Akurasi Klasifikasi Font Berdasarkan Teknik Ekstraksi Fitur

Gambar 3 memvisualisasikan perbandingan kinerja masing-masing teknik, baik tunggal maupun kombinasi fitur, dalam meningkatkan akurasi klasifikasi font. Kombinasi HOG + Zoning menghasilkan akurasi tertinggi sebesar 94,6%. Hasil ini menunjukkan bahwa Zoning sebagai teknik spasial sederhana mampu meningkatkan kinerja model secara signifikan saat dikombinasikan dengan teknik berbasis gradien seperti HOG. Sebaliknya, kontribusi LBP sebagai fitur tekstur lokal kurang optimal jika berdiri sendiri.

3.2 Confusion Matrix dan Evaluasi Kinerja Model

Untuk memverifikasi detail performa model terbaik (HOG + Zoning), dilakukan evaluasi lanjutan menggunakan confusion matrix dan metrik evaluasi lainnya. Gambar 4 memperlihatkan confusion matrix untuk klasifikasi 2.600 data uji dengan 520 sampel untuk masing-masing dari lima kelas font: Arial, Times New Roman, Courier New, Calibri, dan Verdana.



Gambar 4. Confusion Matrix Klasifikasi Font (HOG + Zoning)

Gambar 4 menampilkan Confusion Matrix Klasifikasi Font dengan menggunakan kombinasi fitur HOG + Zoning, berdasarkan pengujian terhadap 2.600 sampel data uji, di mana masing-masing kelas font terdiri dari 520 sampel. Model menunjukkan performa yang sangat baik dengan akurasi sebesar 94,6%, yang setara dengan sekitar 2.460 prediksi benar dan hanya 140 prediksi salah. Sebagian besar prediksi berada pada diagonal confusion matrix, yang mengindikasikan klasifikasi yang tepat untuk sebagian besar data uji. Namun, masih terdapat beberapa kesalahan klasifikasi, terutama antara font Calibri dan Verdana, serta Times New Roman dan Arial. Kesalahan ini kemungkinan disebabkan oleh kemiripan visual antar karakter pada font-font tersebut, yang membuat model sedikit kesulitan membedakannya secara konsisten. Kemiripan tersebut terutama terlihat pada bentuk huruf-huruf seperti “a”, “e”, dan “s”, yang secara visual cukup sulit dibedakan.

3.3 Evaluasi Metrik Performa Klasifikasi

Evaluasi performa model tidak hanya dilakukan dengan mengukur akurasi secara keseluruhan, tetapi juga melalui tiga metrik utama lainnya: precision, recall, dan F1-score. Ketiga metrik ini memberikan gambaran yang lebih komprehensif terhadap kinerja model Support Vector Machines (SVM) dalam mengklasifikasikan karakter berdasarkan font yang berbeda. Tabel 2 menampilkan hasil evaluasi klasifikasi untuk lima kelas font menggunakan kombinasi fitur HOG dan Zoning. Dataset uji terdiri dari 2.600 sampel karakter, masing-masing kelas berisi 520 sampel.

Tabel 2. Hasil Evaluasi Precision, Recall, dan F1-Score Per Kelas Font

Kelas Font	Precision	Recall	F1-Score	Support
Arial	0.927	0.948	0.937	520
Times New Roman	0.959	0.937	0.947	520
Courier New	0.944	0.944	0.944	520
Calibri	0.952	0.948	0.950	520
Verdana	0.948	0.952	0.950	520

Hasil analisis menunjukkan bahwa nilai precision tertinggi diperoleh oleh font Times New Roman dengan skor 0.959, menandakan bahwa model memiliki tingkat ketepatan yang sangat tinggi dalam memprediksi karakter dari font ini. Sementara itu, recall tertinggi dicapai oleh font Arial (0.948) dan Verdana (0.952), yang menunjukkan bahwa model sangat andal dalam mengenali karakter-karakter dari kedua font tersebut, meskipun tidak selalu menghasilkan prediksi yang paling presisi. Nilai F1-score, sebagai harmonisasi antara precision dan recall, tertinggi pada Times New Roman (0.947) serta Verdana dan Calibri (0.950), yang mengindikasikan konsistensi model dalam mengenali pola visual dari karakter-karakter font tersebut. Secara keseluruhan, rata-rata makro dari ketiga metrik evaluasi berada pada angka 0.946, mencerminkan performa yang sangat baik dan seimbang di seluruh kelas font yang diuji. Evaluasi ini memperkuat temuan sebelumnya bahwa kombinasi teknik ekstraksi fitur HOG dan Zoning mampu menangkap karakteristik struktural dan spasial dari citra karakter dengan sangat baik. Selain itu, stabilitas nilai metrik yang konsisten di atas 0.94 pada semua kelas font menunjukkan bahwa model SVM berhasil membangun decision boundary yang efektif antar kelas tipografi, meskipun masih terdapat tantangan pada beberapa kelas seperti Courier New dan Arial yang memiliki kemiripan visual pada bentuk karakter tertentu.

3.4 Diskusi dan Prospek Penelitian

Hasil eksperimen menunjukkan bahwa pemilihan teknik ekstraksi fitur berperan dalam meningkatkan kinerja model klasifikasi tipografi berbasis citra. Kombinasi fitur Histogram of Oriented Gradients (HOG) dan Zoning berhasil mencapai akurasi tertinggi sebesar 94,6%, mengungguli teknik tunggal maupun kombinasi lainnya. Keunggulan HOG terletak pada kemampuannya menangkap informasi kontur dan arah tepi karakter, sedangkan Zoning memberikan informasi spasial lokal yang memperkaya representasi fitur. Sementara itu, metode LBP relatif kurang kompetitif karena hanya menangkap tekstur mikro yang terbatas kontribusinya pada bentuk karakter huruf. Di sisi lain, pemanfaatan algoritma SVM dengan kernel RBF juga berkontribusi terhadap pemisahan kelas font yang memiliki kemiripan visual tinggi. SVM mampu memproyeksikan data fitur ke ruang berdimensi lebih tinggi untuk membentuk hyperplane optimal, sehingga meningkatkan akurasi klasifikasi pada kasus tipografi yang kompleks dan tumpang tindih.

Beberapa penelitian sebelumnya menunjukkan keberhasilan berbagai pendekatan dalam klasifikasi font berbasis citra. Penelitian oleh Alghamdi et al. [29] melaporkan akurasi klasifikasi sebesar 92% dengan memanfaatkan jaringan saraf konvolusi (CNN) menggunakan model pra-terlatih VGG16. Sementara itu, Mohammad et al. [30] menemukan bahwa Support Vector Machine (SVM) mampu mengungguli pengklasifikasi lain dengan akurasi di atas 90%, khususnya saat menggunakan lebih dari 4.000 fitur. Dengan menerapkan kombinasi fitur yang lebih informatif serta tuning parameter yang tepat, penelitian ini mampu meningkatkan akurasi. Hal ini membuktikan bahwa eksplorasi kombinasi fitur dan pendekatan pemodelan yang cermat dapat menghasilkan performa yang kompetitif dalam domain klasifikasi font. Selain itu, hasil ini juga menunjukkan bahwa pemilihan dan integrasi fitur yang tepat memiliki peran penting dalam meningkatkan performa klasifikasi.

Keberhasilan pendekatan ini membuka sejumlah peluang pengembangan lanjutan yang dapat memperluas kontribusi penelitian ini di bidang klasifikasi tipografi berbasis citra, antara lain:

- **Ekspansi Dataset dan Generalisasi Model:** Pengembangan lebih lanjut dapat mencakup peningkatan ukuran dan keragaman dataset, termasuk menambahkan font-font dekoratif, non-Latin, dan tulisan tangan digital, sehingga model menjadi lebih adaptif terhadap variasi tipografi di dunia nyata.
- **Integrasi dengan Model Deep Learning:** Walaupun SVM menunjukkan performa tinggi, eksplorasi terhadap pendekatan berbasis Convolutional Neural Network (CNN) atau Vision Transformer dapat membuka kemungkinan deteksi fitur otomatis yang lebih kaya dan representatif, terutama dalam skenario dengan data dalam jumlah besar.
- **Penerapan Augmentasi dan Noise Robustness:** Mengintegrasikan teknik augmentasi citra seperti rotasi, skala, shear, serta penambahan noise sintesis akan meningkatkan kemampuan model dalam menghadapi variasi input dari kondisi dunia nyata seperti hasil scan dokumen atau foto berkualitas rendah.
- **Optimalisasi Pipeline OCR:** Model klasifikasi font ini dapat dimasukkan sebagai modul pendukung dalam pipeline sistem Optical Character Recognition (OCR) modern. Hal ini akan memperkuat proses identifikasi font secara otomatis sebelum proses ekstraksi teks, sehingga meningkatkan akurasi pembacaan konten dokumen multi-font.
- **Analisis Efisiensi dan Waktu Komputasi:** Arah lain yang dapat dieksplorasi adalah evaluasi terhadap efisiensi waktu pelatihan dan inferensi pada berbagai kombinasi fitur, sehingga dapat diterapkan secara real-time atau pada sistem dengan keterbatasan sumber daya komputasi seperti perangkat mobile.

Dengan hasil penelitian ini, pengembangan lebih lanjut diharapkan dapat mendorong penerapan sistem klasifikasi font yang lebih luas, akurat, dan andal, khususnya dalam bidang komputasi visual dan digitalisasi dokumen. Berdasarkan capaian yang telah diperoleh serta potensi arah pengembangan ke depan, penelitian ini memberikan kontribusi signifikan terhadap pengembangan metode klasifikasi font berbasis citra, baik dari segi peningkatan akurasi maupun dari sisi penerapannya dalam berbagai sistem cerdas yang membutuhkan identifikasi tipografi secara otomatis dan efisien.

4. Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa kombinasi teknik ekstraksi fitur Histogram of Oriented Gradients (HOG) dan Zoning menghasilkan performa klasifikasi terbaik dengan akurasi mencapai 94,6% dalam mengklasifikasikan citra karakter dari lima jenis font populer menggunakan algoritma Support Vector Machines (SVM). Penelitian ini memberikan kontribusi dalam pengembangan pengetahuan aplikatif di bidang pengolahan citra dan kecerdasan buatan, khususnya dalam peningkatan akurasi sistem klasifikasi tipografi berbasis citra karakter. Temuan ini dapat digunakan sebagai dasar untuk pengembangan sistem Optical Character Recognition (OCR) yang lebih presisi, serta untuk aplikasi digitalisasi dokumen, analisis tipografi, dan pengenalan pola dalam industri desain grafis serta membuka peluang aplikasi lebih lanjut dalam digital forensik, sistem pencarian berbasis citra, dan digitalisasi arsip. Meskipun demikian, penelitian ini memiliki keterbatasan pada jenis font yang terbatas pada lima kategori standar dan kondisi data yang dikendalikan (grayscale dan resolusi seragam). Oleh karena itu, disarankan untuk penelitian selanjutnya agar lebih fokus pada pengujian model terhadap font non-Latin, variasi kondisi pencitraan nyata, serta integrasi dengan pendekatan deep learning untuk mengeksplorasi representasi fitur yang lebih kompleks dan otomatis.

5. References

- [1] Y. Yang and Y. Wang, "Computer and Translation," *J. Phys. Conf. Ser.*, vol. 1646, no. 1, p. 012019, Sep. 2020, doi: 10.1088/1742-6596/1646/1/012019.
- [2] K. Hamad and M. Kaya, "A Detailed Analysis of Optical Character Recognition Technology," *Int. J. Appl. Math. Electron. Comput.*, vol. 4, no. Special Issue-1, pp. 244–244, Dec. 2016, doi: 10.18100/ijamec.270374.
- [3] K. Pakhale, "Comprehensive Overview of Named Entity Recognition: Models, Domain-Specific

- Applications and Challenges,” Sep. 2023, [Online]. Available: <http://arxiv.org/abs/2309.14084>
- [4] E. Borovikov, “A survey of modern optical character recognition techniques,” Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.4183>
- [5] H. Moussaoui, N. El Akkad, and M. Benslimane, “Text extraction and recognition method for license plates,” *E3S Web Conf.*, vol. 469, p. 00069, Dec. 2023, doi: 10.1051/e3sconf/202346900069.
- [6] M. S. Kasem, M. Mahmoud, and H.-S. Kang, “Advancements and Challenges in Arabic Optical Character Recognition: A Comprehensive Survey,” Dec. 2023, [Online]. Available: <http://arxiv.org/abs/2312.11812>
- [7] P. Netinant, S. Phonsawang, and M. Rukhiran, “Evaluating Factors Shaping Real-Time Internet-of-Things-Based License Plate Recognition Using Single-Board Computer Technology,” *Technologies*, vol. 12, no. 7, p. 98, Jul. 2024, doi: 10.3390/technologies12070098.
- [8] B. Celiktas, N. Unlu, and E. Karacuha, “XY Cut Modular approach for Segmenting pages,” *Int. J. Sci. Res. Comput. Sci. Eng.*, vol. 6, no. 2, pp. 1–9, Apr. 2018, doi: 10.26438/ijsrcse/v6i2.19.
- [9] J. E. M. Adriano, K. A. S. Calma, N. T. Lopez, J. A. Parado, L. W. Rabago, and J. M. Cabardo, “Digital conversion model for hand-filled forms using optical character recognition (OCR),” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 482, p. 012049, Mar. 2019, doi: 10.1088/1757-899X/482/1/012049.
- [10] J. Wu, “Research on the Application of Artificial Intelligence in Design Courses,” *Highlights Sci. Eng. Technol.*, vol. 122, pp. 123–135, Dec. 2024, doi: 10.54097/xm3gdb81.
- [11] K.-L. Du and M. N. S. Swamy, “Support Vector Machines,” in *Neural Networks and Statistical Learning*, London: Springer London, 2014, pp. 469–524. doi: 10.1007/978-1-4471-5571-3_16.
- [12] Y. Hasija and R. Chakraborty, “Support Vector Machines,” in *Hands-On Data Science for Biologists Using Python*, First edition. | Boca Raton : CRC Press, 2021.: CRC Press, 2021, pp. 219–225. doi: 10.1201/9781003090113-12-12.
- [13] P. Xanthopoulos, P. M. Pardalos, and T. B. Trafalis, “Support Vector Machines,” 2013, pp. 35–48. doi: 10.1007/978-1-4419-9878-1_5.
- [14] D. K. Khanduja and S. Kaur, “The Categorization of Documents Using Support Vector Machines,” *Int. J. Sci. Res. Comput. Sci. Eng.*, vol. 11, no. 6, pp. 1–12, Dec. 2023, doi: 10.26438/ijsrcse/v11i6.112.
- [15] Z. A. A. Alhuseen, F. A. Joda, and M. A. Naser, “Abnormal Behavior Detection in Gait Analysis Using Convolutional Neural Networks,” *Ingénierie des systèmes d’Inf.*, vol. 28, no. 5, pp. 1151–1159, Oct. 2023, doi: 10.18280/isi.280504.
- [16] A. Abayomi, O. O. Olugbara, and D. Heukelman, “Recognition of Human Emotion using Radial Basis Function Neural Networks with Inverse Fisher Transformed Physiological Signals,” *Int. J. Integr. Eng.*, vol. 13, no. 6, Aug. 2021, doi: 10.30880/ijie.2021.13.06.001.
- [17] H. A. Khan, “MCS HOG Features and SVM Based Handwritten Digit Recognition System,” *J. Intell. Learn. Syst. Appl.*, vol. 09, no. 02, pp. 21–33, 2017, doi: 10.4236/jilsa.2017.92003.
- [18] A. Tatke, M. Patil, A. Khot, P. Jadhav, and D. V. Karad, “HYBRID APPROACH OF GARBAGE CLASSIFICATION USING COMPUTER VISION AND DEEP LEARNING,” *Int. J. Eng. Appl. Sci. Technol.*, vol. 5, no. 10, Feb. 2021, doi: 10.33564/IJEAST.2021.v05i10.032.
- [19] Z. Sedaghatjoo, H. Hosseinzadeh, and B. S. Bigham, “Local Binary Pattern(LBP) Optimization for Feature Extraction,” Jul. 2024, [Online]. Available: <http://arxiv.org/abs/2407.18665>
- [20] A. Abaei Kashan, A. Maghsoudi, N. Shoeibi, M. Heidarzadeh, and K. Mirnia, “An Automatic Optic Disk Segmentation Approach from Retina of Neonates via Attention Based Deep Network,” *Int. J. Eng.*, vol. 35, no. 04, pp. 715–724, 2022, doi: 10.5829/IJE.2022.35.04A.11.
- [21] H. Maher, “Texture Analysis and Classification using Local Binary Patterns and Statistical Features,”

- Wasit J. Comput. Math. Sci.*, vol. 3, no. 3, pp. 79–88, Sep. 2024, doi: 10.31185/wjcms.279.
- [22] M. Hazgui, H. Ghazouani, and W. Barhoumi, “Genetic programming-based fusion of HOG and LBP features for fully automated texture classification,” *Vis. Comput.*, vol. 38, no. 2, pp. 457–476, Feb. 2022, doi: 10.1007/s00371-020-02028-8.
- [23] A. A. A. A. Habeb, M. M. Taresh, J. Li, Z. Gao, and N. Zhu, “Enhancing Medical Image Classification with an Advanced Feature Selection Algorithm: A Novel Approach to Improving the Cuckoo Search Algorithm by Incorporating Caputo Fractional Order,” *Diagnostics*, vol. 14, no. 11, p. 1191, Jun. 2024, doi: 10.3390/diagnostics14111191.
- [24] T. J. Alhindi, S. Kalra, K. H. Ng, A. Afrin, and H. R. Tizhoosh, “Comparing LBP, HOG and Deep Features for Classification of Histopathology Images,” in *2018 International Joint Conference on Neural Networks (IJCNN)*, IEEE, Jul. 2018, pp. 1–7. doi: 10.1109/IJCNN.2018.8489329.
- [25] N. Dalal and B. Triggs, “Histograms of Oriented Gradients for Human Detection,” in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, IEEE, pp. 886–893. doi: 10.1109/CVPR.2005.177.
- [26] S. M. Darwish and K. O. Elzoghaly, “An Enhanced Offline Printed Arabic OCR Model Based on Bio-Inspired Fuzzy Classifier,” *IEEE Access*, vol. 8, pp. 117770–117781, 2020, doi: 10.1109/ACCESS.2020.3004286.
- [27] S. Anthwal and D. Ganotra, “Dynamic Features Based on Flow-Correlation and HOG for Recognition of Discrete Facial Expressions,” *Rev. d’Intelligence Artif.*, vol. 34, no. 5, pp. 585–594, Nov. 2020, doi: 10.18280/ria.340508.
- [28] N. Alpaslan and K. Hanbay, “Multi-Resolution Intrinsic Texture Geometry-Based Local Binary Pattern for Texture Classification,” *IEEE Access*, vol. 8, pp. 54415–54430, 2020, doi: 10.1109/ACCESS.2020.2981720.
- [29] T. Alghamdi, S. Snoussi, and L. Hsairi, “Arabic Document Classification by Deep Learning,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 10, 2021, doi: 10.14569/IJACSA.2021.0121034.
- [30] A. H. Mohammad, T. Alwada‘n, and O. Al-Momani, “Arabic Text Categorization Using Support vector machine, Naïve Bayes and Neural Network,” *GSTF J. Comput.*, vol. 5, no. 1, p. 16, Sep. 2016, doi: 10.7603/s40601-016-0016-9.