

ANALISIS PERBANDINGAN ALGORITMA LOCAL BINARY PATTERNS HISTOGRAM (LBPH) DAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) PADA SISTEM PENGENALAN WAJAH

Galang Pratama Sukma Putra¹, Erfanti Fatkhiyah², Renna Yanwastika Ariyana³

²Program Studi Informatika, Universitas AKPRIND Indonesia

Jl Kalisahak No. 28 Komplek Balapan Tromol Pos 45, Yogyakarta 55222

Email: galang4pro@gmail.com¹, erfanti@akprind.ac.id², renna@akprind.ac.id³

ABSTRACT

In digital security and verification systems, passwords are commonly used but have vulnerabilities to manipulation and theft. To address these issues, alternative methods such as facial recognition are increasingly being used because facial features are difficult to forge, remain stable throughout a person's life, and are unique to each individual. Facial recognition can be implemented using various methods, including the Local Binary Patterns Histogram (LBPH) algorithm and Convolutional Neural Network (CNN). LBPH is a traditional algorithm based on facial features that excels in its lightweight computational resource usage but is less effective in poor lighting conditions and has longer processing times. On the other hand, CNN is a modern method based on deep learning that offers higher accuracy and faster processing speeds but requires more computational resources. This research compares the performance of both algorithms in terms of accuracy and speed. The results show that each algorithm has its advantages and limitations. The CNN algorithm demonstrates superior performance compared to LBPH in terms of accuracy and computational efficiency for facial recognition. From the tests, it is observed that CNN has a slight lower facial recognition accuracy rate of 98.6607% compared to LBPH's 99.1071% with 0.4464% difference. Additionally, the computation time for the CNN algorithm is faster, at 0.0030 seconds per image, compared to LBPH's 0.0238 seconds per image. This indicates CNN's superiority in capturing complex features of facial images and efficiency in data processing. However, it should be noted that the CNN algorithm requires more significant computational resources than the LBPH algorithm. Therefore, selecting the appropriate algorithm must be tailored to the specific needs of the application to be implemented. Given that both methods have their advantages and limitations, the final decision in choosing the algorithm should consider factors such as the availability of computational resources, lighting conditions, and the specific requirements of the facial recognition application. Hence, this research provides practical guidance for developers and users in selecting and implementing the facial recognition algorithm that best fits their needs and available resources.

Keywords: Face Recognition, Local Binary Patterns Histogram, Convolutional Neural Network, Accuracy, Speed.

INTISARI

Dalam sistem pengamanan dan verifikasi digital, kata sandi sering digunakan tetapi memiliki kerentanan terhadap manipulasi dan pencurian. Untuk mengatasi masalah ini, metode alternatif seperti pengenalan wajah mulai banyak digunakan karena fitur wajah sulit dipalsukan, stabil sepanjang hidup, dan unik bagi setiap individu. Pengenalan wajah dapat dilakukan dengan berbagai metode, termasuk algoritma Local Binary Patterns Histogram (LBPH) dan Convolutional Neural Network (CNN). LBPH adalah algoritma tradisional yang berbasis pada fitur wajah dengan keunggulan dalam penggunaan sumber daya komputasi yang ringan. Namun, algoritma ini kurang efektif dalam kondisi pencahayaan yang buruk dan memiliki waktu pemrosesan yang lebih lama. Sebaliknya, CNN adalah metode modern berbasis deep learning yang menawarkan akurasi dan kecepatan pemrosesan yang lebih tinggi, tetapi membutuhkan sumber daya komputasi yang lebih besar. Penelitian ini membandingkan performa kedua algoritma dalam hal akurasi dan kecepatan. Hasil penelitian menunjukkan bahwa masing-masing algoritma memiliki kelebihan dan keterbatasan.

Algoritma CNN menunjukkan performa yang lebih unggul dibandingkan LBPH dalam efisiensi waktu komputasi untuk pengenalan wajah. Dari hasil pengujian, terlihat bahwa CNN memiliki tingkat akurasi pengenalan wajah yang mirip dengan LBPH, yaitu 98.6607%, dibandingkan dengan LBPH yang memiliki selisih 0.4464% lebih tinggi, yaitu mencapai 99.1071%. Selain itu, waktu komputasi untuk algoritma CNN lebih cepat, yaitu 0,0030 detik per citra, dibandingkan dengan LBPH yang memerlukan waktu 0,0227 detik per citra. Hal ini menunjukkan keunggulan CNN dalam menangkap fitur-fitur kompleks dari citra wajah dan efisiensi dalam pemrosesan data. Namun, perlu diperhatikan bahwa algoritma CNN membutuhkan sumber daya komputasi yang lebih besar jika dibandingkan dengan algoritma LBPH. Sehingga, pemilihan algoritma yang sesuai harus disesuaikan dengan kebutuhan spesifik dari aplikasi yang akan diterapkan. Mengingat kedua metode memiliki kelebihan dan keterbatasan masing-masing, keputusan akhir dalam pemilihan algoritma harus mempertimbangkan faktor-faktor seperti ketersediaan sumber daya komputasi, kondisi pencahayaan, dan kebutuhan spesifik dari aplikasi pengenalan wajah tersebut. Dengan demikian, penelitian ini memberikan panduan praktis bagi pengembang dan pengguna dalam memilih dan mengimplementasikan algoritma pengenalan wajah yang sesuai dengan kebutuhan dan sumber daya yang dimiliki.

Kata kunci: *Pengenalan Wajah, Local Binary Patterns Histogram, Convolutional Neural Network, Akurasi, Kecepatan.*

PENDAHULUAN

Teknologi biometri telah mengalami perkembangan signifikan dalam beberapa tahun terakhir, terutama dalam pengenalan wajah, yang kini menjadi salah satu metode paling banyak digunakan untuk identifikasi dan verifikasi identitas. Menurut Adjabi dkk., penggunaan teknologi ini tidak hanya terbatas pada keamanan siber tetapi juga meluas ke berbagai bidang seperti perbankan, kesehatan, dan layanan publik. Dalam sektor keamanan, pengenalan wajah digunakan untuk autentikasi akses dan pengawasan. Di bidang perbankan, teknologi ini membantu dalam autentikasi transaksi dan pencegahan penipuan. Dalam sektor kesehatan, pengenalan wajah digunakan untuk mengelola rekam medis dan mengidentifikasi pasien secara cepat. Teknologi biometri, termasuk pengenalan wajah, terus berkembang dengan integrasi algoritma canggih dan sistem *deep learning* yang meningkatkan akurasi dan efisiensi. Menurut penelitian terbaru, teknologi ini menghadapi tantangan seperti privasi dan etika, tetapi juga menawarkan potensi besar untuk inovasi di masa depan [1].

Dalam sistem pengamanan dan verifikasi digital, penggunaan kata sandi sering menjadi metode utama untuk memastikan identitas pengguna. Namun, kata sandi memiliki kelemahan yang signifikan, yaitu kerentanannya terhadap manipulasi dan pencurian oleh pihak-pihak yang tidak berwenang. Untuk mengatasi kelemahan ini, teknologi pengenalan wajah telah dikembangkan sebagai alternatif yang lebih aman dan efektif. Pengenalan wajah menawarkan berbagai keunggulan, antara lain karena fitur wajah setiap individu sulit untuk dipalsukan, tetap stabil sepanjang hidup, dan memiliki keunikan yang membedakan satu individu dari individu lainnya. Suryansah dkk. menjelaskan bahwa teknologi pengenalan wajah merupakan suatu sistem yang canggih dan kompleks. Sistem ini mampu mengenali serta menganalisis komponen wajah, seperti alis, mata, hidung, dan mulut, dengan cara mengukur jarak serta rasio antara komponen-komponen tersebut untuk menentukan 'tanda tangan' unik dari setiap wajah. Dalam praktiknya, sistem pengenalan wajah bekerja dengan menganalisis citra wajah yang diperoleh, menghitung parameter-parameter yang menentukan keunikan wajah tersebut, dan kemudian membandingkan citra wajah yang baru diambil dengan data yang telah disimpan sebelumnya. Dengan membandingkan parameter-parameter ini, sistem dapat menilai tingkat kesamaan antara wajah yang dianalisis dengan wajah-wajah yang sudah ada dalam basis data, sehingga proses identifikasi atau verifikasi dapat dilakukan dengan akurat dan efisien [2].

Terdapat berbagai algoritma pengenalan wajah yang telah dikembangkan oleh para peneliti, masing-masing menawarkan pendekatan berbeda untuk mencapai akurasi dan kecepatan yang optimal dalam proses identifikasi. Dalam penelitian ini, pemilihan algoritma *Local Binary Patterns Histogram* (LBPH) dan *Convolutional Neural Network* (CNN) untuk perbandingan didasarkan pada perbedaan signifikan dalam cara kerja dan kebutuhan sumber daya antara keduanya. LBPH adalah algoritma tradisional yang dikenal karena keefisienannya dalam penggunaan sumber daya komputasi. Sebaliknya, CNN merupakan algoritma modern yang berbasis *deep learning*, menawarkan akurasi tinggi dan fleksibilitas dalam menghadapi variasi gambar, namun memerlukan

sumber daya komputasi yang lebih besar. Perbandingan kedua algoritma ini penting untuk menentukan keunggulan relatif masing-masing dalam konteks aplikasi pengenalan wajah yang berbeda.

Perbandingan antara algoritma LBPH dan CNN bertujuan untuk mengevaluasi dan menganalisis perbedaan performa keduanya dalam hal akurasi dan kecepatan pengenalan wajah. Dengan banyaknya algoritma yang tersedia, para pengembang sistem perlu memahami kekuatan dan keterbatasan masing-masing algoritma untuk memilih yang paling sesuai dengan kebutuhan spesifik mereka. Penelitian ini bertujuan untuk memberikan panduan praktis bagi pengembang dengan membandingkan bagaimana LBPH dan CNN berfungsi dalam berbagai kondisi, sehingga hasil analisis dapat membantu dalam menentukan algoritma mana yang paling efisien dan efektif untuk diterapkan dalam sistem pengenalan wajah tertentu.

LBPH memiliki keunggulan utama dalam hal penggunaan sumber daya komputasi yang relatif ringan, membuatnya cocok untuk aplikasi dengan perangkat keras terbatas. Selain itu, LBPH cukup efisien dalam kondisi pencahayaan yang bervariasi dan tidak memerlukan pelatihan yang intensif. Di sisi lain, CNN menawarkan akurasi yang lebih tinggi berkat kemampuannya dalam memproses dan menganalisis fitur wajah dengan pendekatan *deep learning*. CNN juga menunjukkan keunggulan dalam kecepatan pemrosesan yang lebih baik ketika berhadapan dengan *dataset* yang besar dan kompleks, namun memerlukan sumber daya komputasi yang lebih besar. Dengan demikian, kedua algoritma ini memiliki keunggulan yang spesifik dan dapat dipilih sesuai dengan kebutuhan aplikasi dan kapasitas perangkat yang tersedia.

METODE PENELITIAN

Penelitian ini terdiri dari beberapa tahapan yang dapat diuraikan sebagai berikut:

1. Pengumpulan data, tahap ini meliputi pengumpulan data yang akan digunakan sebagai sampel untuk mendapatkan data untuk dilakukan analisis komparatif. Data dari berbagai sumber yang dapat diambil dan digunakan secara bebas dikumpulkan untuk selanjutnya digunakan dalam perancangan sistem uji.
2. Pengujian, pada tahap ini data yang telah dikumpulkan diaplikasikan pada kode pemrograman menggunakan Jupyter Lab untuk dilakukan uji pengenalan wajah menggunakan metode LBPH dan CNN. Tahap pengujian menghasilkan data berupa catatan waktu dan besaran akurasi masing-masing algoritma.
3. Analisis, merupakan tahapan pengolahan catatan waktu dan besaran akurasi dari tahapan sebelumnya agar didapatkan nilai komparasi yang ditampilkan dalam grafik perbandingan.
4. Pengambilan Kesimpulan, adalah tahapan penentuan kesimpulan berdasarkan hasil analisis agar didapatkan informasi yang dapat dimanfaatkan kembali.

HASIL DAN PEMBAHASAN


Dalam penelitian ini menggunakan *dataset* yang berasal dari *Yale Face Database* yang terdiri dari 560 citra wajah dari 28 individu yang berbeda. Setiap citra telah dilakukan *preprocessing* secara manual untuk menghilangkan latar belakang citra. Setiap citra wajah menggunakan posisi pencahayaan yang berbeda. Jenis pencahayaan dan jumlah citra dapat dilihat pada Tabel 1.

Tabel 1. Jenis pencahayaan dan jumlah citra

Jenis Pencahayaan	Jumlah
Baik	252
Sedang	140
Kurang	168
Total	560


PENERAPAN ALGORITMA LBPH

Pada proses pengenalan wajah menggunakan algoritma LBPH terdapat beberapa tahapan yaitu ekstraksi piksel ke bentuk matriks 3x3 yang dilakukan secara urut berdasarkan piksel tengah, kemudian dilakukan proses *thresholding* untuk mendapatkan nilai biner untuk kemudian diubah menjadi nilai tengah. Proses tersebut dikenal dengan nama *Local Binary Patterns* (LBP) yang kemudian dibentuk menjadi histogram per region untuk membentuk histogram gabungan yang akan digunakan untuk pengenalan wajah. Proses LBPH dapat digambarkan seperti pada Gambar 1.




Gambar 1. Proses LBPH

Pada proses ekstraksi piksel dilakukan dengan mengambil blok kecil berukuran 3x3 piksel untuk kemudian dilakukan proses perhitungan pola biner. Proses ekstraksi dapat digambarkan seperti pada Gambar 2.



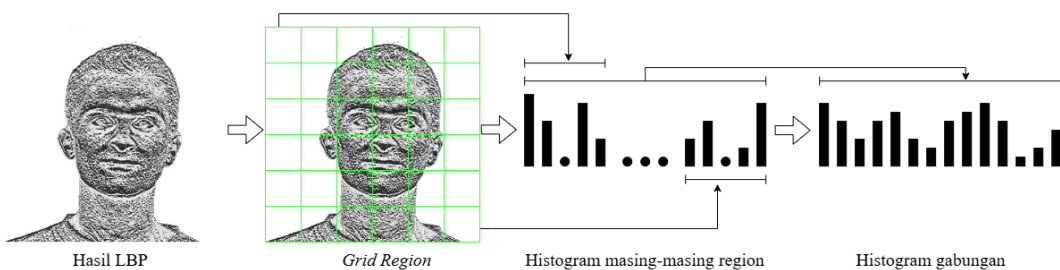
Gambar 2. Proses ekstraksi piksel dari citra wajah

Berdasarkan nilai tengah pada matriks 3x3 kemudian dilakukan *thresholding* untuk mendapatkan nilai biner dari blok tersebut. Pada Gambar 3, nilai tengah dari blok tersebut adalah 27, nilai ini kemudian digunakan untuk *thresholding* sehingga didapatkan nilai biner untuk kemudian diubah ke bentuk desimal untuk dijadikan nilai tengah yang baru.



Gambar 31. Proses LBP

Dari hasil proses LBP sebelumnya kemudian dibagi menjadi beberapa region, masing-masing region lalu dibuat menjadi histogram terpisah. Pada proses LBPH, histogram pada setiap region kemudian digabung menjadi histogram gabungan. Histogram gabungan inilah yang akan digunakan sebagai dasar pengukuran pada pengenalan wajah menggunakan algoritma LBPH. Proses LBPH dapat dilihat pada Gambar 4.



Gambar 4. Proses LBPH

HASIL PENGENALAN WAJAH MENGGUNAKAN METODE LBPH

Dataset yang digunakan dalam penelitian ini terdiri dari 560 citra wajah dari 28 individu berbeda. Citra-citra tersebut mencakup variasi ekspresi wajah dan kondisi pencahayaan yang berbeda. Data dibagi menjadi 80% citra (448 citra) untuk pelatihan dan 20% citra (112 citra) untuk pengujian. Pengujian dilakukan sebanyak 10 kali dengan konfigurasi yang sama.

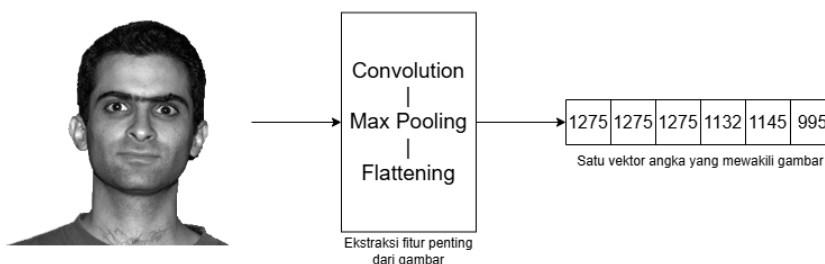
Berdasarkan Tabel 2. hasil pengujian menunjukkan nilai akurasi rata-rata 99.1071% dan waktu komputasi rata-rata 0,0227 detik per citra. Hal ini menunjukkan LBPH memiliki akurasi yang tinggi dan waktu pemrosesan yang cukup singkat.

Tabel 2. Hasil pengujian algoritma LBPH

Pengujian	Akurasi (%)	Waktu Komputasi (detik)
1	99.1071	2.6461
2	99.1071	2.6428
3	99.1071	2.6338
4	99.1071	2.6280
5	99.1071	2.6263
6	99.1071	2.6249
7	99.1071	2.6093
8	99.1071	2.6536
9	99.1071	2.6332
10	99.1071	2.6200
Rata-rata	99.1071	2.6318


PROSES PENGENALAN WAJAH MENGGUNAKAN METODE CNN

Proses pengenalan wajah menggunakan metode CNN terdiri dari beberapa tahapan, yaitu proses konvolusi, *pooling*, dan *flattening* yang dapat digambarkan seperti pada Gambar 5.




Gambar 5. Proses CNN

Proses konvolusi merupakan tahap awal dalam jaringan CNN yang berfungsi untuk mengekstraksi fitur-fitur lokal dari citra *input*. Sebagai contoh pada Gambar 6, pada bagian (A) diubah ke dalam bentuk matriks *grayscale* yang dapat direpresentasikan pada matriks (B).




Gambar 6. Tampilan matriks *grayscale*

Pada matriks *grayscale* kemudian terapkan filter matriks 3x3 untuk mendeteksi fitur spesifik, misalnya pada contoh pada Gambar 7 diterapkan filter 3x3 untuk mendeteksi sudut pada citra *input*. Matrix (A) merupakan matriks dari bagian kecil gambar selumnya, matriks (B) merupakan filter, dan matriks (C) merupakan hasil konvolusi. Pada bagian matriks (C) berwarna hijau merupakan hasil perhitungan dari bagian matriks (A) berwarna hijau dengan filter matriks (B).




Gambar 7. Matriks hasil konvolusi

Pooling merupakan tahap yang bertujuan untuk mengurangi dimensi pada vektor hasil konvolusi sekaligus mempertahankan informasi penting. *Pooling* juga membantu membuat model lebih tahan terhadap pergeseran dan perubahan kecil dalam citra *input*. Contoh perhitungan *pooling* menggunakan filter 2x1 dapat dilihat pada Gambar 8. Pada matriks (A) dilakukan filter *max pooling* menggunakan filter 2x1 yang ditandai dengan warna hijau, kemudian ditentukan nilai maksimal untuk kemudian disimpan pada matriks (B).



Gambar 8. Proses *Max Pooling*

Flattening merupakan tahap yang mengubah peta fitur dua dimensi yang telah di-*pooling* menjadi matriks satu dimensi yang akan digunakan untuk lapisan pengenalan wajah. Proses *Flattening* dapat digambarkan seperti pada Gambar 9.



Gambar 9. Proses *Flattening*

HASIL PENGENALAN WAJAH MENGGUNAKAN METODE CNN

Dataset yang sama digunakan untuk pengujian CNN, dengan 80% citra (448 citra) untuk pelatihan dan 20% citra (112 citra) untuk pengujian. Berdasarkan Tabel 3, hasil pengujian menunjukkan akurasi pengenalan wajah dengan nilai rata-rata sebesar 98.6607% dengan waktu komputasi rata-rata 0.0030 detik per citra. Dengan perbedaan kurang dari 0.5% dari LBPH, menunjukkan bahwa CNN juga memiliki tingkat akurasi yang tinggi serta waktu komputasi yang cepat.

Tabel 3. Hasil pengujian algoritma CNN

Pengujian	Akurasi %	Waktu Komputasi (detik)
1	98.2143	0.3379
2	100.0000	0.3404
3	98.2143	0.3428
4	95.5357	0.3399
5	100.0000	0.3402
6	97.3214	0.3494
7	100.0000	0.3381
8	99.1071	0.3405
9	99.1071	0.3350
10	99.1071	0.3399
Rata-rata	98.6607	0.3404

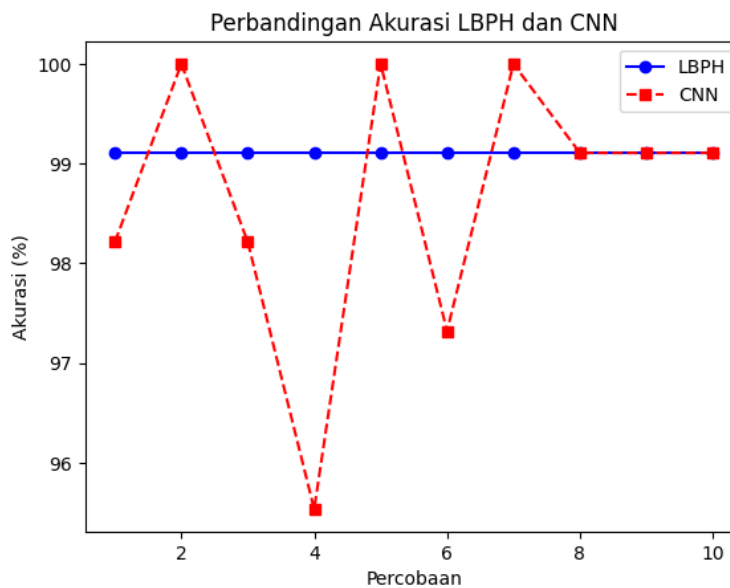
PERBANDINGAN AKURASI

Tabel 4 menunjukkan hasil akurasi dari dua algoritma pengenalan wajah, yaitu LBPH dan CNN, yang diuji pada sepuluh kondisi berbeda. Algoritma LBPH menunjukkan akurasi yang sangat konsisten, dengan nilai mencapai 99,1071% di semua pengujian. Hal ini menunjukkan bahwa LBPH memiliki performa yang stabil dan dapat diandalkan dalam berbagai situasi. Sebaliknya, akurasi CNN bervariasi lebih besar, dengan nilai tertinggi mencapai 100% pada beberapa pengujian dan nilai terendah sebesar 95,5357%. Rata-rata akurasi CNN adalah 98,6607%, yang sedikit lebih rendah dibandingkan dengan LBPH, tetapi masih menunjukkan kinerja yang sangat baik secara keseluruhan. Perbandingan ini menunjukkan bahwa LBPH menawarkan stabilitas akurasi yang lebih baik, sementara CNN memiliki potensi untuk mencapai akurasi yang sangat tinggi dalam kondisi tertentu, meskipun dengan variasi yang lebih besar. Dengan demikian, meskipun kedua algoritma menunjukkan hasil yang baik dalam pengenalan wajah, LBPH cenderung lebih stabil, sedangkan CNN dapat memberikan performa waktu komputasi yang lebih baik. Perbedaan akurasi dapat dilihat pada Gambar 10.

Tabel 4. Perbandingan akurasi LBPH dan CNN

Pengujian	Akurasi LBPH (%)	Akurasi CNN (%)
1	99.1071	98.2143
2	99.1071	100.0000
3	99.1071	98.2143

4	99.1071	95.5357
5	99.1071	100.0000
6	99.1071	97.3214
7	99.1071	100.0000
8	99.1071	99.1071
9	99.1071	99.1071
10	99.1071	99.1071
Rata-rata	99.1071	98.6607



Gambar 10. Grafik perbandingan akurasi LBPH dan CNN

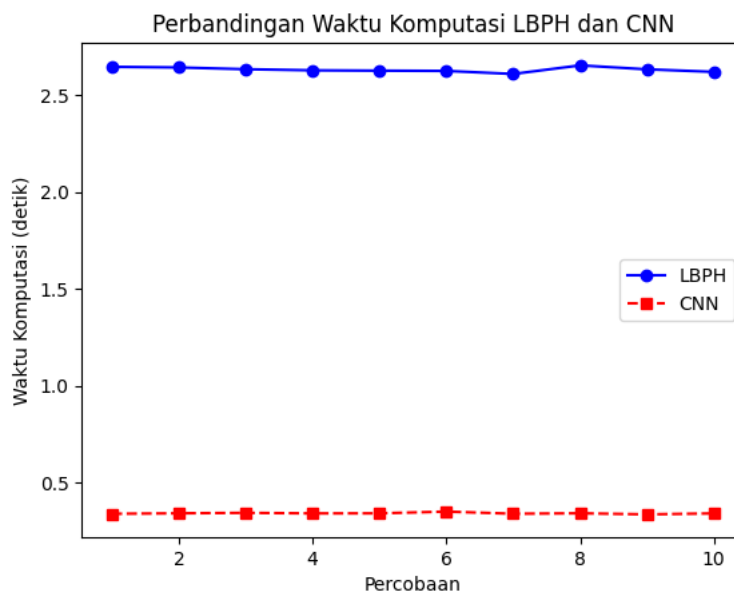
PERBANDINGAN WAKTU KOMPUTASI

Tabel 5 menunjukkan waktu komputasi dari dua algoritma pengenalan wajah, yaitu LBPH dan CNN, yang diuji pada sepuluh kondisi berbeda. Algoritma LBPH memerlukan waktu komputasi yang relatif lama, dengan nilai rata-rata mencapai 2,6318 detik. Waktu komputasi LBPH bervariasi antara 2,6093 detik hingga 2,6536 detik di setiap pengujian, menunjukkan bahwa proses komputasi untuk LBPH cukup intensif dan memerlukan waktu yang lebih lama. Sebaliknya, algoritma CNN menunjukkan waktu komputasi yang jauh lebih singkat, dengan rata-rata mencapai 0,3404 detik. Waktu komputasi CNN bervariasi antara 0,3350 detik hingga 0,3494 detik di setiap pengujian, menunjukkan bahwa CNN mampu memproses data dengan lebih cepat dibandingkan LBPH. Perbandingan ini menunjukkan bahwa meskipun LBPH menawarkan akurasi yang sangat tinggi dan stabil, algoritma CNN memiliki keunggulan dalam hal efisiensi waktu komputasi, membuatnya lebih sesuai untuk aplikasi yang memerlukan pengolahan data dalam waktu singkat. Perbedaan waktu komputasi dapat dilihat pada Gambar 11.

Tabel 5. Perbandingan waktu komputasi LBPH dan CNN

Pengujian	Waktu Komputasi LBPH (detik)	Waktu Komputasi CNN (detik)
1	2.6461	0.3379
2	2.6428	0.3404
3	2.6338	0.3428
4	2.6280	0.3399

5	2.6263	0.3402
6	2.6249	0.3494
7	2.6093	0.3381
8	2.6536	0.3405
9	2.6332	0.3350
10	2.6200	0.3399
Rata-rata	2.6318	0.3404



Gambar 11. Grafik perbandingan waktu komputasi LBPH dan CNN

KESIMPULAN

Dalam penelitian ini, algoritma CNN menunjukkan performa yang lebih unggul dalam hal kecepatan waktu komputasi pengenalan wajah dibandingkan dengan LBPH. Dari hasil pengujian, terlihat bahwa CNN memiliki waktu komputasi yang jauh lebih rendah, yaitu 0.0030 detik per citra, dibandingkan dengan LBPH yang mencapai 0.0227 detik per citra. Hal ini menunjukkan keunggulan CNN dalam pemrosesan. Sama halnya dari sisi akurasi, keduanya memiliki tingkat akurasi yang mirip, yaitu 99.1071% untuk LBPH dan 98.6607% untuk CNN. Dengan demikian, LBPH memiliki akurasi yang lebih unggul 0.4464% dibandingkan dengan CNN. Meskipun kedua metode memiliki kelebihan dan keterbatasan masing-masing, pemilihan algoritma yang sesuai harus disesuaikan dengan kebutuhan spesifik dari aplikasi yang akan diterapkan.

DAFTAR PUSTAKA

[1] I. Adjabi, A. Ouahabi, A. Benzaoui, and A. Taleb-Ahmed, "Past, present, and future of face recognition," Aug. 01, 2020, MDPI AG. doi: 10.3390/electronics9081188.

[2] A. Suryansah, R. Habibi, and R. M. Awangga, *Penggunaan Face Recognition Untuk Akses Ruangannya*, Cetakan Pertama. Bandung: Kreatif Industri Nusantara, 2020.

[3] I. Muslihah and H. Imaduddin, "Perbandingan Algoritma Eigenface Dengan Local Binary Pattern (LBP) Pada Pengenalan Wajah," *Proceeding Seminar Nasional & Call For Papers*, pp. 108–115, Nov. 2020.

[4] N. Amalia, "Perbandingan Algoritma Fisherface dan Algoritma Local Binary Pattern Untuk Pengenalan Wajah," *TIN: Terapan Informatika Nusantara*, vol. 2, no. 12, pp. 690–704, May 2022, doi: 10.47065/tin.v2i12.1568.

[5] A. Azis, D. P. Pamungkas, and A. B. Setiawan, "Analisa Perbandingan Algoritma Euclidean Dan Manhattan Distance," *Seminar Nasional Inovasi Teknologi*, Jul. 2021.

- [6] N. Dewi and F. Ismawan, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CNN UNTUK SISTEM PENGENALAN WAJAH," *Faktor Exacta*, vol. 14, no. 1, p. 34, Mar. 2021, doi: 10.30998/faktorexacta.v14i1.8989.
- [7] I. N. T. A. Putra and K. S. Kartini, "Perbandingan Metode Pengenalan Wajah Melalui Penerapan Pada Sistem Surveillance," *SINTECH JOURNAL*, vol. 4, no. 1, pp. 88–98, 2021, [Online]. Available: <https://doi.org/10.31598>
- [8] B. Nugroho, "The Face Recognition Performance in Every Lighting Condition of Testing Data," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Jul. 2020. doi: 10.1088/1742-6596/1569/2/022052.
- [9] S. A. Sahy, "Descriptor feature based on local binary pattern for face classification," *Original Research*, vol. 10, no. 2, pp. 500–511, 2022.
- [10] A. Raj, REAL TIME MULTIPLE FACE RECOGNITION SECURITY SYSTEM (RTM-FS). 2014. [Online]. Available: <https://www.researchgate.net/publication/261703721>
- [11] R. Anantharam, "Local Binary Patterns." Accessed: May 22, 2024. [Online]. Available: <https://medium.com/@rajatanantharam/local-binary-patterns-8807ecf7f87c>
- [12] G. Carstens-Peters, "Unsplash." Accessed: Jan. 10, 2024. [Online]. Available: <https://unsplash.com/@glennancarstenspeters>
- [13] A. S. Georghiades, P. N. Belhumeur, and D. J. Kriegman, "Extended Yale B." Accessed: Jan. 15, 2024. [Online]. Available: <http://vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html>
- [14] T. Lusni Pratama, M. Ayu Dusea Widya Dara, and J. Sahertian, "Perbandingan Pengenalan Wajah Dengan Metode Local Binary Pattern Histogram Dan Eigenface Untuk Presensi," *Seminar Nasional Inovasi Teknologi*, pp. 255–260, 2021.
- [15] C. C. Aggarwal, *Neural Networks and Deep Learning: A Textbook*. Springer, 2018.
- [16] J. Project, "JupyterLab Documentation." Accessed: May 22, 2024. [Online]. Available: <https://jupyterlab.readthedocs.io/en/stable/index.html>
- [17] Y. Sari, *Logika Algoritma, Pseudocode, Flowchart, dan C++*, 1st ed. Perahu Litera, 2017.
- [18] R. M. Bolle, J. H. Connell, S. Pankanti, N. K. Ratha, and A. W. Senior, *Guide to Biometrics*. Springer New York, 2013.
- [19] J. Brownlee, *Machine Learning Algorithms From Scratch with Python. Machine Learning Mastery*, 2016.
- [20] D. Rahman Sya'bani, A. Hamzah, and E. Susanti, "KLASIFIKASI BUAH SEGAR DAN BUSUK MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK DENGAN TFLITE SEBAGAI MEDIA PENERAPAN MODEL MACHINE LEARNING," 2022.
- [21] J. Bielecki and M. Śmiałek, "Estimation of execution time for computing tasks," *Cluster Comput*, vol. 26, no. 6, pp. 3943–3956, Dec. 2023, doi: 10.1007/s10586-022-03774-1.