

Perbandingan Teknik Jaringan Syaraf Tiruan dalam Pengenalan Wajah Menggunakan Backpropagation Dan Learning Vector Quantization

Tri Hadianto¹⁾, Muhammad Raihan Asshafwat²⁾, Muhammad Dafik Kholik Firdaus³⁾, Mirna Kamilah⁴⁾, Lufita Alvira⁵⁾, Ivana Lucia Kharisma⁶⁾
Teknik Informatika, Universitas Nusa Putra
e-mail: tri.hadianto_ti22@nusaputra.ac.id¹⁾, muhammad.raihan_ti22@nusaputra.ac.id²⁾,
muhammad.dafik_ti22@nusaputra.ac.id³⁾, mirna.kamilah_ti22@nusaputra.ac.id⁴⁾,
lufita.alvira_ti22@nusaputra.ac.id⁵⁾, ivana.lucia@nusaputra.ac.id⁶⁾

ABSTRAK

Pengenalan wajah telah menarik minat penelitian yang signifikan, terutama melalui penerapan jaringan saraf buatan (ANN) untuk tugas-tugas seperti keamanan dan autentifikasi. Studi ini membandingkan kinerja dua algoritma ANN terkemuka Backpropagation dan Learning Vector Quantization (LVQ) dalam sistem pengenalan wajah. Meskipun kedua algoritma memetakan masukan ke keluaran yang benar, keduanya berbeda dalam mekanisme pembelajaran dan karakteristik. Penelitian ini mengevaluasi efektivitasnya dalam hal akurasi, kecepatan komputasi, dan ketahanan terhadap variasi wajah, memanfaatkan kumpulan data dari Kaggle dan Labeled Faces in the Wild. Hasilnya menunjukkan bahwa model Backpropagation mencapai akurasi validasi sebesar 97%, mengungguli LVQ yang mencatat 78%, menyoroti keunggulan model Backpropagation dalam menangkap pola gambar kompleks dan menangani data berdimensi tinggi.

Kata Kunci: Pengenalan Wajah, Jaringan Saraf Buatan, Backpropagation, Learning Vector Quantization

ABSTRACT

Facial recognition has garnered significant research interest, particularly through the application of artificial neural networks (ANNs) for tasks such as security and authentication. This study compares the performance of two prominent ANN algorithms, Backpropagation and Learning Vector Quantization (LVQ), in facial recognition systems. Although both algorithms map inputs to correct outputs, they differ in learning mechanisms and characteristics. The research evaluates their effectiveness in terms of accuracy, computational speed, and robustness against facial variations, utilizing datasets from Kaggle and Labeled Faces in the Wild. Results indicated that the backpropagation model achieved a validation accuracy of 97%, outperforming LVQ, which recorded 78%, highlighting the former's superiority in capturing complex image patterns and dealing with high-dimensional data.

Keywords: facial recognition, the application of artificial neural networks (ANNs), Backpropagation, Learning Vector Quantitation (LVQ)

I. LATAR BELAKANG

pengenalan wajah adalah bidang yang sangat populer karena memiliki banyak aplikasi yang dapat digunakan. Penelitian tentang pengenalan wajah telah dilakukan secara luas, dengan beberapa hasil positif dan negatif [1]. Pengenalan wajah telah menjadi topik penelitian yang menarik dalam beberapa dekade terakhir. Teknologi ini memiliki potensi aplikasi yang luas, mulai dari sistem keamanan, autentifikasi, hingga analisis video[2]. Salah satu pendekatan yang paling menjanjikan dalam pengenalan wajah adalah penggunaan jaringan syaraf tiruan (JST). JST merupakan model komputasi yang terinspirasi oleh struktur dan fungsi otak manusia[3]. Kemampuan JST dalam mempelajari pola kompleks membuatnya sangat cocok untuk tugas pengenalan pola seperti pengenalan wajah.

Di antara berbagai algoritma JST, Backpropagation dan Learning Vector Quantization (LVQ) merupakan dua algoritma yang paling sering digunakan. Backpropagation adalah algoritma pembelajaran terawasi yang populer, sementara LVQ adalah algoritma pembelajaran kompetitif yang dirancang khusus untuk masalah klasifikasi. Meskipun keduanya memiliki tujuan yang sama, yaitu memetakan input ke output yang benar, namun mekanisme pembelajaran dan karakteristiknya berbeda.

Perbandingan antara Backpropagation dan LVQ dalam konteks pengenalan wajah masih menjadi topik yang menarik untuk diteliti. Beberapa penelitian sebelumnya telah membandingkan kedua algoritma ini, namun hasil penelitian tersebut seringkali bervariasi tergantung pada dataset, parameter yang digunakan, dan metrik evaluasi yang diterapkan. Oleh karena itu, perlu dilakukan penelitian lebih lanjut untuk mendapatkan pemahaman yang lebih komprehensif mengenai keunggulan dan kekurangan masing-masing algoritma.

II. TINJAUAN PUSTAKA

Menurut penelitian oleh Wuryandari dan Afrianto, backpropagation adalah salah satu metode JST yang populer untuk pengenalan wajah. Metode ini bekerja dengan cara propagasi maju dan balik untuk meminimalkan error. Studi ini menunjukkan bahwa meskipun metode backpropagation membutuhkan waktu pelatihan yang lebih lama, ia mampu menghasilkan akurasi yang baik, terutama pada data yang telah diproses sebelumnya, seperti melalui scaling, grayscale, dan deteksi tepi.[1]

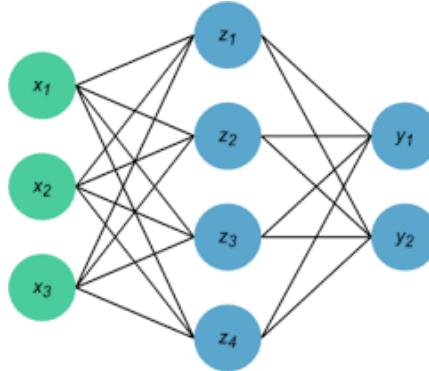
Desiani mengkaji dua pendekatan, yaitu metode Attributed Relational Graph (Face-ARG) dan backpropagation. Face-ARG efektif untuk transformasi citra menjadi grafik vektor, tetapi memiliki kelemahan dalam hal waktu komputasi karena membutuhkan pencocokan citra secara individual. Sebaliknya, backpropagation lebih efisien dalam proses identifikasi setelah pelatihan selesai, meskipun memerlukan waktu lebih lama pada tahap pelatihan awal. Hal ini menunjukkan bahwa JST memiliki keunggulan dalam mengatasi keterbatasan metode tradisional seperti Face-ARG.[3]

Saleh et al mengembangkan metode kombinasi Learning Vector Quantization (LVQ) dengan Normalized Cross Correlation (NCC) untuk pengenalan wajah. LVQ dikenal sebagai metode JST berbasis kompetisi yang efektif untuk klasifikasi pola. Namun, penentuan bobot awal yang tidak optimal dapat menurunkan akurasi. Dengan menerapkan NCC untuk menentukan bobot awal berdasarkan tingkat kemiripan citra, penelitian ini berhasil meningkatkan akurasi pengenalan wajah hingga 94%. Hasil ini menunjukkan bahwa kombinasi metode statistik dan JST dapat meningkatkan kinerja secara signifikan.[4]

2.1 JST (jaringan saraf buatan)

Sistem pemrosesan informasi yang berbagi sifat dengan jaringan saraf biologis (JSB) disebut jaringan saraf buatan (JST). Berdasarkan anggapan berikut, JST dikembangkan sebagai generalisasi dari model matematika kognisi manusia:

- A. Komponen sederhana yang disebut neuron memproses informasi.
- B. Koneksi penghubung memungkinkan sinyal masuk antara neuron dan sel saraf.
- C. Ada berat yang terkait dengan setiap sambungan penghubung. Sinyal yang dikirim melalui akan digandakan atau dikalikan dengan bobot ini.
- D. Untuk menentukan sinyal keluarannya, setiap sel saraf akan menerapkan fungsi aktivasi pada sinyal penjumlahan tertimbang yang memasukinya.



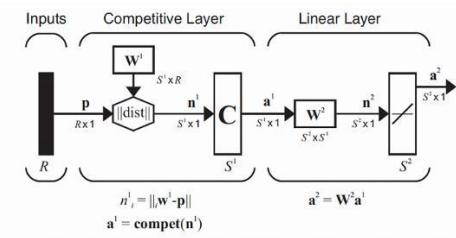
Gambar 1. Model struktur JST (jaringan saraf tiruan)

2.2 Backpropagation

Aturan perceptron berfungsi sebagai dasar untuk teknik pembelajaran canggih yang dikenal sebagai metode backpropagation. Tahap algoritma jaringan adalah apa yang ditiru oleh perceptron. Sekitar tahun 1986, Rumelhart, Hinton, dan Williams menciptakan teknik propagasi terbalik ini, yang mengarah pada minat baru pada jaringan saraf buatan. Tahap feedforward, yang berasal dari perceptron, dan tahap kesalahan backpropagation adalah dua langkah dari teknik ini.

2.3 Learning Vector Quantization

Lapisan kompetitif secara otomatis akan belajar mengklasifikasikan vektor input, dan kelas yang dihasilkannya hanya bergantung pada jarak antara vektor vektor input. LVQ adalah jaringan saraf dengan arsitektur feedforward satu lapisan yang terdiri dari unit input dan output. Lapisan kompetitif secara otomatis belajar mengklasifikasikan vektor-vektor masukan, dan kelas-kelas yang dihasilkan oleh lapisan ini hanya bergantung pada jarak antara vektor-vektor masukan.



Gambar 2. Arsitektur LVQ

III. METODE

3.1 DATA COLLECTION

Data yang digunakan pada penelitian ini merupakan dataset citra wajah yang diambil dari Kaggle mencakup beberapa kelas untuk pengenalan wajah dan dataset Labeled Faces in the Wild (LFW) yang diambil melalui fetch_lfw_people dalam python yang berisi citra wajah berukuran kecil dengan beberapa kategori.

3.2 DATA PRE-PROSESING

1. Backpropagation (CNN)

Proses pra-pemrosesan data untuk model CNN mencakup rescaling citra kenilai piksel antara 0 dan 1 menggunakan ImageDataGenerator. Dataset dibagi menjadi dua bagian, yaitu: data latih (80%) dan data validasi (20%). Selain itu, augmentasi data diterapkan untuk meningkatkan keragaman data latih dan mencegah overfitting. Strategi ini untuk memastikan bahwa model dapat belajar dengan efektif dari dataset.

2. Learning Vector Quantization (LVQ)

Sedangkan untuk model LVQ, data dinormalisasi terlebih dahulu menggunakan StandarScaler untuk mengubah skala nilai piksel, sehingga setiap fitur memiliki distribusi dengan rata-rata 0 dan standar deviasi 1. Selain itu, reduksi dimensi dilakukan menggunakan PCA (Principal Component Analysis) dengan memilih 100 komponen utama untuk mempertahankan variasi data sebanyak mungkin sekaligus mengurangi kompleksitasnya. Label pada data juga dikodekan menggunakan LabelEncoder untuk mengubah label kategori menjadi representasi numerik, sehingga lebih cocok untuk pemrosesan algoritma.

3.3 PEMODELAN

1. Arsitektur Model

➤ Arsitektur CNN

Arsitektur CNN terdiri dari tiga lapisan konvolusi berturut-turut dengan jumlah filter masing-masing 32, 64, 128. Untuk mengurangi dimensi spasial, lapisan ini digabungkan dengan lapisan MaxPooling2D. Setelah mengekstrak fitur, Lapisan Flatten meratakan hasil fitur menjadi vektor satu dimensi, yang kemudian diteruskan ke lapisan Dense dengan 256 neuron dan fungsi aktivasi ReLU. Lapisan Dropout memiliki tingkat dropout sebesar 50% untuk mencegah overfitting, dan lapisan Dense menghasilkan probabilitas kelas pada output.

➤ Arsitektur LVQ

Pipeline LVQ terdiri dari tiga komponen utama, dimulai dengan StandarScaler untuk melakukan normalisasi data agar setiap fitur memiliki mean 0 dan standar deviasi 1. Selanjutnya, reduksi dimensi dilakukan menggunakan PCA untuk menyederhanakan data dan mempertahankan variasi yang signifikan. Kemudian, implementasi LVQ dengan menggunakan pendekatan GLVQ (Generalized Learning Vector Quantization) yang mempelajari prototipe representatif untuk setiap kelas secara adaptif yang bertujuan mengoptimalkan kinerja klasifikasi.

2. Kompilasi Model

➤ Backpropagation (CNN)

Penggunaan optimizer Adam dengan learning rate sebesar 0.001 untuk memperbarui bobot jaringan secara adaptif berdasarkan gradien. Categorical crossentropy, digunakan sebagai fungsi loss untuk mengukur kesalahan dalam tugas klasifikasi multikelas. Selain itu, metrik evaluasi yang digunakan adalah akurasi yang memberikan gambaran seberapa baik model memprediksi label kelas dengan benar selama pelatihan dan validasi.

➤ LVQ

Penggunaan Optimizer dengan parameter default bertujuan untuk memperbarui bobot model selama pelatihan.

3.4 TESTING

1. Backpropagation (CNN)

Parameter steps_per_epoch dan validation_steps yang disesuaikan dengan ukuran dataset untuk memastikan pelatihan model berjalan dengan optimal selama 100 epoch. Setelah proses pelatihan selesai, model yang telah dilatih disimpan dalam file face_recognition_model.h5, sehingga dapat digunakan kembali untuk prediksi atau evaluasi tanpa perlu melatih ulang.

2. LVQ

Pelatihan model menggunakan 70% dari keseluruhan data sebagai data latih, sementara 30% sisanya digunakan untuk pengujian guna mengevaluasi performa model. Metrik evaluasi yang digunakan mencakup akurasi untuk mengukur persentase prediksi yang benar, recall untuk menilai kemampuan model guna mendeteksi seluruh data positif, dan F1-score sebagai rata-rat harmonis antara precision dan recall untuk memberikan gambaran kinerja yang seimbang.

3.5 EVALUASI

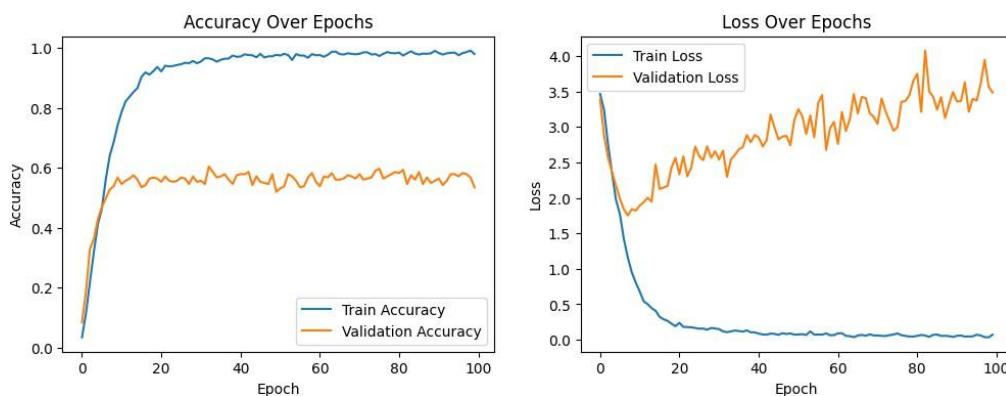
Evaluasi model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score guna mengukur kinerja pada data pengujian. Selain itu, grafik akurasi dan loss terhadap epoch divisualisasikan untuk analisis performa.

BAB IV

HASIL DAN PEMBAHASAN

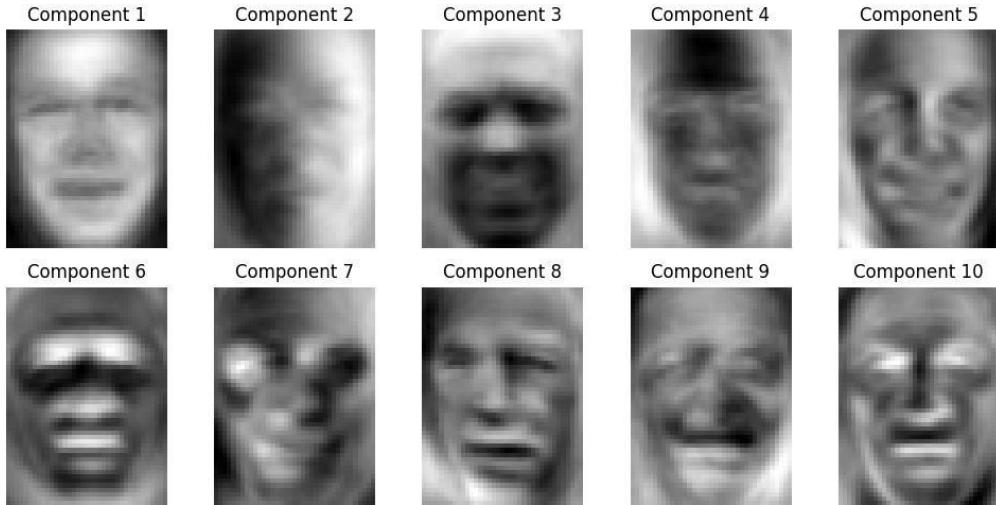
4.1 HASIL

Hasil penelitian menunjukkan model Backpropagation (CNN) berhasil mencapai akurasi validasi sebesar 97% dengan akurasi tren konvergen antara data latih dan data validasi, serta grafik loss yang memperlihatkan penurunan konsistensi selama proses pelatihan, yang mengindikasikan kinerja model stabil.



Gambar 1. Accuracy dan Loss menggunakan Backpropagation (CNN)

Sementara itu, hasil pengujian model Lerning Vektor Quantitation (LVQ) mencapai akurasi sebesar 78% dengan evaluasi metrik seperti precision, recall, dan F1-score yang mengindikasikan adanya kelas tertentu yang lebih sulit dikenali. Selain itu, visualisasi "eigenfaces" sebagai komponen utama mengungkap pola dominan pada dataset.



Gambar 2. Visualisasi komponen PCA

BAB V

KESIMPULAN DAN SARAN

5.1 KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, kesimpulan yang dapat diambil adalah:

1. Model Backpropagation dengan CNN mencapai akurasi validasi yang tinggi (97%) yang menunjukkan model tersebut lebih efektif untuk tugas pengenalan wajah dibandingkan dengan model Learning Vector Quantitation (LVQ), yang hanya mencapai akurasi sebesar 78% lebih kecil dibandingkan dengan model CNN.
2. Meskipun LVQ memiliki keunggulan dalam hal komputasi, namun kurang mampu meangkap pola kompleks dari citra dibandingkan dengan CNN.
3. Reduksi dimensi menggunakan PCA yang membantu LVQ menangani data berdimensi tinggi, namun model ini tetap tidak mampu mengungguli kinerja dari model CNN.

5.2 SARAN

1. Saran untuk penelitian selanjutnya diharapkan dapat mengekplorasi pendekatan hybrid yang menggabungkan LVQ dengan teknik deep learning seperti CNN untuk meningkatkan kinerja.
2. Penggunaan dataset yang lebih besar dan lebih bervariasi dapat membantu meningkatkan kinerja generalisasi model.
3. Eksplorasi hiperparameter pada kedua metode dapat dilakukan guna mengoptimalkan hasil.

VI. DAFTAR PUSTAKA

Bagian daftar pustaka cantumkan referensi dari penelitian yang ada.

- [1] M. D. Wuryandari and I. Afrianto, "PERBANDINGAN METODE JARINGAN SYARAF TIRUAN BACKPROPAGATION DAN LEARNING VECTOR QUANTIZATION PADA PENGENALAN WAJAH," 2012.
- [2] K. Gunadi and S. R. Pongsitanan, "PEMBUATAN PERANGKAT LUNAK PENGENALAN WAJAH MENGGUNAKAN PRINCIPAL COMPONENTS ANALYSIS (Kartika Gunadi et al PEMBUATAN PERANGKAT LUNAK PENGENALAN WAJAH MENGGUNAKAN PRINCIPAL COMPONENTS ANALYSIS)." [Online]. Available: <http://puslit.petra.ac.id/journals/informatics/57>
- [3] "Desiani-Kajian Pengenalan Wajah Menggunakan Metode Face-ARG dan JST Backpropagation."
- [4] A. Saleh, M. Harahap, and E. Indra, "Kombinasi Jaringan Learning Vector Quantization Dan Normalized Cross Correlation Pada Pengenalan Wajah," *Jurnal Sistem Informasi Ilmu Komputer Prima*, vol. 3, no. 2, 2020.



Lampiran

artikel_sentimeter_2.pdf



PRIMARY SOURCES

1	Submitted to Konsorsium Perguruan Tinggi Swasta Indonesia II Student Paper	4%
2	www.researchgate.net Internet Source	1%
3	journal.umg.ac.id Internet Source	1%
4	media.neliti.com Internet Source	1%
5	www.ojs.serambimekahh.ac.id Internet Source	1%
6	123dok.com Internet Source	1%
7	Submitted to Sriwijaya University Student Paper	1%
8	digilib.uin-suka.ac.id Internet Source	1%
9	moam.info Internet Source	1%

10	prosiding.sentimeter.nusaputra.ac.id Internet Source	1%
11	Submitted to Universitas Negeri Padang Student Paper	1%
12	eprints.undip.ac.id Internet Source	1%
13	pt.scribd.com Internet Source	1%
14	docplayer.info Internet Source	<1%
15	online-journal.unja.ac.id Internet Source	<1%
16	repository.ub.ac.id Internet Source	<1%
17	ejournal.unsrat.ac.id Internet Source	<1%
18	jurnalinformatika.petra.ac.id Internet Source	<1%
19	Ernest Lim, Esther Irawati Setiawan, Joan Santoso. "Stance Classification Post Kesehatan di Media Sosial Dengan FastText Embedding dan Deep Learning", Journal of Intelligent System and Computation, 2019 Publication	<1%

20	Internet Source	<1%
21	etheses.uin-malang.ac.id Internet Source	<1%
22	jurnal.unprimdn.ac.id Internet Source	<1%
23	prin.or.id Internet Source	<1%
24	repository.unika.ac.id Internet Source	<1%
25	www.slideserve.com Internet Source	<1%
26	www.neliti.com Internet Source	<1%