

KLASIFIKASI GENDER BERDASARKAN CITRA MATA MANUSIA MENGGUNAKAN ALGORITMA CONVOLUTION NEURAL NETWORK

Rizky Dwi Wicaksono^{1*}, Fandy Indra Pratama², dan Avira Budianita³

¹ Magister Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro
Jl. Imam Bonjol No.207, Pendrikan Kidul, Kec. Semarang Tengah, Kota Semarang, 50131.

² Teknik Informatika, Fakultas Teknik, Universitas Wahid Hasyim
Jl. Raya Gunungpati No.KM.15, Nongkosawit, Gunungpati, Semarang 50224.

³ Sistem Informasi, Fakultas Sains dan Teknologi,
Universitas Muhammadiyah Kudus
Jl. Ganesha Raya No.I, Purwosari, Kec. Kota Kudus, Kabupaten Kudus, Jawa Tengah 59316.
*Email: rizkydwiwicaksono3@gmail.com

Abstrak

Teknologi otentikasi biometrik yang memanfaatkan karakteristik manusia seperti wajah, sidik jari, suara, dan iris mata semakin banyak digunakan untuk seperti wajah, sidik jari, suara, dan iris mata semakin banyak digunakan untuk identifikasi individu. Meskipun efektif dalam memastikan keaslian, sistem-sistem ini umumnya tidak memberikan informasi tambahan seperti jenis kelamin atau etnis dari individu yang diverifikasi. Penelitian sebelumnya telah meneliti klasifikasi jenis kelamin berdasarkan citra wajah, sedangkan penggunaan citra iris mata masih terbatas. Penelitian ini bertujuan untuk mengklasifikasikan jenis kelamin manusia berdasarkan citra iris mata dengan menerapkan pendekatan deep learning, khususnya menggunakan algoritma Convolutional Neural Network (CNN). Pengujian dilakukan pada sejumlah besar data untuk mengukur kinerja. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi hingga 92% dalam mengklasifikasikan jenis kelamin berdasarkan citra iris mata. Penelitian ini membuka peluang baru untuk pengembangan lebih lanjut dalam biometrik berbasis iris mata.

Kata kunci: Convolutional Neural Networks, Citra mata, Gender, Klasifikasi.

1. PENDAHULUAN

Menurut (Tapia and Aravena, 2017) Dalam beberapa waktu terakhir, teknologi autentikasi biometrik yang memanfaatkan ciri-ciri manusia seperti wajah, sidik jari, suara, dan iris mata menjadi semakin diminati di kalangan peneliti. Meskipun efektif dalam mengidentifikasi individu dan mengungkap penipuan, sistem-sistem ini cenderung kurang memberikan informasi tambahan seperti jenis kelamin atau etnis. Beberapa penelitian telah difokuskan pada penggunaan gambar wajah untuk mengklasifikasikan jenis kelamin, sementara identifikasi atribut manusia melalui citra iris mata masih memiliki referensi yang terbatas. (Venkateswarlu *et al.*, 2023) pentingnya klasifikasi jenis kelamin melalui gambar wajah telah meningkat secara signifikan dalam waktu belakangan ini. Dalam konteks pengenalan individu melalui pemrosesan gambar, fitur biometrik seperti struktur wajah, iris mata, suara, dan karakteristik fisik lainnya digunakan untuk menetapkan identifikasi unik pada setiap individu. Sejalan dengan peningkatan jumlah dataset gambar yang tersedia di internet, kebutuhan akan algoritma *Artificial Intelligence* (AI) yang mampu menangani tugas-tugas pengklasifikasian, seperti pengenalan wajah dan jenis kelamin, juga mengalami pertumbuhan yang signifikan.

Menurut (Şafak and Barişçi, 2018) tantangan utama dalam mengestimasi usia dan jenis kelamin adalah ekstraksi fitur yang efektif dari gambar wajah. Saat ini, kemajuan metode *Convolutional Neural Network* (CNN) telah menjadi sorotan keberhasilan dalam hal ini. Pada pengenalan wajah, klasifikasi gambar, dan identifikasi objek, telah terlihat kemajuan yang signifikan. Oleh karena itu, dalam penelitian ini, disarankan untuk menggunakan *Convolutional Neural Network* (CNN) guna melakukan prediksi otomatis terkait usia dan jenis kelamin berdasarkan gambar wajah. *Convolutional Neural Network* terdiri dari beragam lapisan konvolusi, di mana setiap lapisan menghasilkan output dari lapisan sebelumnya, menciptakan output yang kuat dan padat. Dalam penelitian ini, *Convolutional Neural Network* yang telah mengalami pelatihan sebelumnya dimanfaatkan untuk memproyeksikan estimasi usia dan jenis kelamin dari gambar wajah.

Menurut (Tan and Le, 2019) Metode *Machine Learning* umumnya melibatkan langkah penentuan fitur secara manual, yang tidak selalu merepresentasikan secara akurat masalah yang dihadapi. Sebaliknya, seperti *Convolutional Neural Network* (CNN), mampu melakukan pemrosesan *input* secara optimal dan menemukan konfigurasi jaringan yang terbaik melalui proses pelatihan. *Convolutional Neural Networks* (CNN atau *ConvNets*) merupakan jenis khusus dari jaringan *feed-forward* yang banyak diterapkan untuk menganalisis gambar visual. *Convolutional Neural Networks* (CNNs) memiliki kemiripan dengan jaringan saraf konvensional, namun terdiri dari *neuron* yang memiliki bobot dan *bias* yang dapat diadaptasi melalui pembelajaran. Keunggulan kinerja *ConvNets* dibandingkan dengan arsitektur *Convolutional Neural Network* lainnya terletak pada proses unik yang diterapkan. Berbeda dengan pendekatan melihat gambar satu per satu, *ConvNets* melakukan pengelompokan piksel secara simultan, memungkinkannya untuk memahami pola temporal dengan lebih efisien.

Pada peneliti-peneliti sebelumnya telah fokus pada klasifikasi *gender* menggunakan citra wajah secara umum (Singh *et al.*, 2024), namun hanya sedikit penelitian yang secara khusus meneliti klasifikasi *gender* berdasarkan citra mata. Faktanya, *iris* mata merupakan salah satu biometrik yang unik dan berpotensi lebih akurat dalam tugas mencari pembeda setiap objek. Oleh karena itu, penelitian ini bertujuan untuk mengetahui akurasi pada penerapan metode *Convolutional Neural Network* (CNN) dalam klasifikasi *gender* berdasarkan citra mata manusia.

2. METODOLOGI

Metodologi pada penelitian ini dengan mengumpulkan 1. Dataset; 2. Pra pemrosesan; 3. Ekstraksi Fitur; serta 4. Evaluasi keakuratan. Detail dari bagian tersebut ada pada penjelasan sebagai berikut:

2.1. Dataset

Dataset yang digunakan dalam penelitian ini berasal dari *Kaggle* dan dapat diunduh dari (pavel biza, 2021). Terdapat total 11.525 gambar citra mata, dengan 9.220 gambar digunakan sebagai data pelatihan dan 2.305 gambar sebagai data uji. Gambar tersebut digunakan untuk pengujian yang dikelompokkan menjadi dua kelas yaitu *female* dan *male*. Berikut adalah pembagian dua kelas sample pada gambar dibawah ini :



Gambar 1 Dataset

2.2. Pra pemrosesan

Pra pemrosesan membantu meningkatkan penanganan gambar dengan menyelaraskannya pada ukuran dan format yang seragam. *Interpolasi bilinear* digunakan untuk menjaga rasio aspek gambar tanpa mengubahnya. Agar menghindari potensi meledaknya *gradien* dan mempercepat konvergensi, gambar di *rescale* dengan faktor 1/255. **Error! Reference source not found.** menampilkan struktur arsitektur *Convolutional Neural Network*.

2.3. Ekstraksi Fitur

Berdasarkan citra yang telah dinormalisasi berfungsi sebagai *input* untuk modul ekstraksi fitur dalam arsitektur *Convolutional Neural Network*. Model *Convolutional Neural Network* ini

dibangun dari awal, dan dataset pelatihan dibagi menjadi *batch* dengan ukuran 32. Ukuran *batch* mengacu pada jumlah data yang diambil pada satu waktu untuk melatih model, dan ukuran *batch* yang lebih kecil dapat mempercepat dan membuat proses pembelajaran lebih efisien. Jumlah *epoch*, yaitu seberapa sering seluruh dataset melewati jaringan, menggunakan *epoch* sebanyak 10 kali untuk model ini.

Dalam konteks *convolution*, filter melewati gambar secara vertikal, menciptakan dimensi baru untuk gambar yang sama. Proses ini dikenal sebagai *convolution*, dan *convolution layer* dalam *convolutional neural network* untuk mengekstrak atribut dari gambar citra mata, yang membuatnya menjadi komponen penting dalam arsitektur ini. *Kernel* dihasilkan melalui operator konvolusi untuk membuat peta fitur. *Convolution layer* berikutnya akan mengekstrak fitur tingkat lebih tinggi, sementara *convolution layer* awal mengekstrak fitur. Setelah *convolution layer*, *pooling layer* mengurangi dimensi fitur yang telah diperoleh. Model ini menggunakan *max-pooling*, di mana operasi penyatuan menghasilkan nilai maksimum dari *patch-patch* dalam fitur. *Output* dari *pooling convolution layer* kemudian dijadikan *input* untuk lapisan perataan, di mana *array 2-D* dari lapisan penyatuan diubah menjadi satu *vektor linier kontinu* yang panjang. Kombinasi antara hasil *convolution* dan *input* lainnya disajikan sebagai *output*.

$$x_j^L = f \left(\sum_{i \in M^j} (x_i^{(L-1)} k_{ij}^L + b_j^L) \right) \quad (1)$$

Dimana:


x_j^L - j^{th} keluaran dari L^{th} lapisan.

b_j^L - bias aditif untuk L^{th} lapisan

k_j^L - *kernel* untuk L^{th} lapisan

M^j - kumpulan gambar masukan

Output dari lapisan perataan dimasukkan ke dalam *dense layer* atau *fully connected*. Pada *dense layer*, setiap *neuron* menerima *input* dari semua *neuron* pada *layer* sebelumnya. Untuk mencegah *overfitting* data, lapisan *dropout* dengan tingkat *dropout* sebesar 0,2 ditambahkan di antara *dense layer*. Proses klasifikasi gambar dilakukan berdasarkan *fully connected*, menggunakan *output* dari *layer* sebelumnya. *ReLU* digunakan sebagai fungsi aktivasi untuk dua *layer* pertama, sementara *sigmoid* digunakan untuk *layer* terakhir.



Gambar 2 Convolutional Neural Network

Dapat meringkas model ini secara sederhana:

1. *Input Layer*: Merupakan *layer* pertama dalam jaringan, menerima data masukan, dengan dimensi sebesar 75×75 .
2. *Convolution Layer*: Metode yang diusulkan menerapkan *convolutional neural network* dengan beberapa *convolution layer*, karena *convolutional neural network* dapat menggambarkan fitur-fitur kompleks dan tingkat tinggi dari data masukan, termasuk bentuk dan pola, serta fitur tingkat rendah seperti tepi dan tekstur. Terdapat dua *convolutional layer*, dan setiap setnya menggunakan *kernel* untuk mengekstraksi fitur melalui operasi *convolution*. Rincian terkait *convolution layer* pertama dan kedua disajikan di bawah ini.
Convolution Layer Pertama: $75 \times 75 \times 3$.
Convolution Layer Kedua: $36 \times 36 \times 32$.
Ukuran *Kernel*: 3×3 .

3. *Activation Layer*: *Activation layer* memasukkan unsur *nonlinier* untuk memungkinkan jaringan belajar pola yang kompleks dan nuansa dalam data. Dalam pendekatan yang diajukan, *activation layer ReLU*, yang cukup populer, digunakan. Dimensi keluaran dari *activation layer*, yang terletak setelah kedua *activation layer*, sejajar dengan dimensi keluaran dari masing-masing *activation layer*, dan tidak mengandung parameter yang dapat diatur dalam *training*.
4. *Pooling Layer*: Proses *pooling* diterapkan setelah setiap *convolutional activation layer*. *Pooling* menggunakan metode *max pooling*. Dimensi keluaran dari dua lapisan *max pooling* adalah sebagai berikut:
Pooling Layer Pertama: $34 \times 34 \times 32$
Pooling Layer Kedua: $15 \times 15 \times 64$
Pooling yang digunakan adalah 2×2 .
5. *Fully-Connected Layer*: Peta fitur yang diekstraksi kemudian diubah menjadi bentuk vektor dan disalurkan ke dalam *full connected layer*. Peta fitur yang dihasilkan dari *layer* penggabungan kedua memiliki dimensi $23 \times 23 \times 64$. Pendekatan yang diajukan mengaplikasikan *layer* dengan 128 *neuron*.
6. *Output Layer*: *Output* dari *fully connected layer* diteruskan ke lapisan *output convolutional neural network*, yang memiliki jumlah *neuron* yang setara dengan jumlah kelas pada target.
7. Selanjutnya, CNN akan mengikuti pengoptimalisasi Sigmoid dengan proses pembelajaran.

Rincian desain *convolutional neural network* termasuk dimensi lapisan dan total parameter.

Tabel 1 parameter

Layer (Type)	Output Size	Param
Conv2d (Conv2d)	(None, 73, 73, 32)	896
batch_normalization (Batch Normalization)	(None, 73, 73, 32)	128
max_pooling2d (MaxPooling2D)	(None, 36, 36, 32)	0
conv2d_1 (Conv2D)	(None, 34, 34, 32)	9248
max_pooling2d_1 (MaxPooling2D)	(None, 17, 17, 32)	0
conv2d_2 (Conv2D)	(None, 15, 15, 64)	18496
spatial_dropout2d (Spatial Dropout2D)	(None, 15, 15, 64)	0
max_pooling2d_2 (MaxPoolin g2D)	(None, 7, 7, 64)	0
flatten (Flatten)	(None, 3136)	0
dense (Dense)	(None, 128)	401536
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 1)	129

Tabel 1 merupakan struktur *Convolutional Neural Network* yang diaplikasikan dalam teknik yang diusulkan. Rincian mengenai lapisan, dimensi *output*, dan jumlah parameter pada *Convolutional Neural Network* yang diimplementasikan untuk kelas target dirangkum dan dipresentasikan dalam Tabel 1.

3. HASIL DAN PEMBAHASAN

Pada hasil dan pembahasan menjelaskan hasil kinerja dan melihat performa dari penerapan algoritma CNN pada iris mata manusia.

3.1. Metrik Kinerja

Hasil tugas dianalisis dengan menggunakan ukuran akurasi klasifikasi. Ukuran akurasi klasifikasi digunakan sebagai indikator seberapa baik model berkinerja.

$$\text{Accuracy} = \frac{TP+FN}{TP+TN+FP+FN} \quad (2)$$

Dimana:

FN – *False Negative*

FP – *False Positive*

TN – *False Negative*

TP – *True Positive*

Beberapa parameter evaluasi lain yang diterapkan meliputi *precision*, *recall*, dan *F1- Score*.

$$\text{Accuracy} = \frac{TP+FN}{TP+TN+FP+FN} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

3.2. Performa


Performa model mengalami variasi pada setiap *epoch*, meningkat seiring berjalannya *epoch*, dan mencapai puncaknya sebelum akhirnya mencapai tingkat stabilisasi. Akurasi model yang dihasilkan dengan membangun model *Convolutional Neural Network* dari awal dapat dilihat pada Tabel 2.

Tabel 2 Performa model

	Precision	Recall	F1-score
0	0.94	0.88	0.91
1	0.91	0.96	0.93
accuracy			0.92
Macro avg	0.93	0.92	0.92
weighted	0.92	0.92	0.92
avg			

Model *accuracy* yang dihasilkan membangun dengan model *Convolutional Neural Network* dari awal dapat dilihat pada

Gambar 3.



Gambar 3 Model accuracy

Gambar 3 menunjukkan peningkatan akurasi *training* dan *validation* dari model selama 10 *epoch*. Akurasi *validation* lebih tinggi dari *training* setelah beberapa *epoch*, namun mulai berfluktuasi setelah *epoch* ke-6, yang mungkin mengindikasikan *overfitting*. Pada akhir *training*, keduanya mendapatkan akurasi 92%, menunjukkan model bekerja dengan baik. Loss model yang dihasilkan membangun dengan model *Convolutional Neural Network* dari awal dapat dilihat pada Gambar 4.



Gambar 4 Model loss

Gambar 4 menunjukkan penurunan *training* dan *validation loss* selama 10 *epoch*. Loss menurun, namun *validation loss* menunjukkan fluktuasi, terutama pada epoch ke-7, yang bisa menandakan *overfitting*. Di akhir pelatihan, baik *training* maupun *validation loss* mendekati 0.32, menunjukkan model memiliki performa yang cukup baik namun perlu memperhatikan stabilitas generalisasi.

4. PENUTUP

Penelitian ini membuktikan hasil bahwa *Convolutional Neural Network* (CNN) untuk klasifikasi jenis kelamin berdasarkan citra mata mencapai akurasi 92% dan menunjukkan kinerja yang tinggi dalam hal *presicion*, *recall*, dan *F1-score*, temuan ini mendukung hipotesis bahwa *Convolutional Neural Networks* lebih unggul dalam menangani klasifikasi citra biometrik yang kompleks. Penelitian di masa depan harus memperluas dataset dengan berbagai kondisi gambar dan mengeksplorasi arsitektur *Convolutional Neural Networks* lainnya atau teknik deep learning yang baru.

DAFTAR PUSTAKA

- pavel Biza (2021) 'Female and male eyes', *Kaggle* [Preprint]. Available at: <https://doi.org/10.34740/KAGGLE/DS/1438879>.
- Şafak, E. and Barışçi, N. (2018) 'Age and Gender Prediction Using Convolutional Neural Networks', in *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, pp. 1–7. Available at: <https://doi.org/10.1109/ISMSIT.2018.8567066>.
- Singh, J. et al. (2024) 'Real-Time Convolutional Neural Networks for Emotion and Gender Classification', *Procedia Computer Science*, 235, pp. 1429–1435. Available at: <https://doi.org/https://doi.org/10.1016/j.procs.2024.04.134>.
- Tan, M. and Le, Q. (2019) 'Efficientnet: Rethinking model scaling for convolutional neural networks', in *International conference on machine learning*. PMLR, pp. 6105–6114.
- Tapia, J. and Aravena, C. (2017) 'Gender classification from NIR iris images using deep learning', *Deep learning for biometrics*, pp. 219–239.
- Venkateswarlu, B. et al. (2023) 'AI-based Gender Identification using Facial Features', in *2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, pp. 1692–1697. Available at: <https://doi.org/10.1109/ICAAIC56838.2023.10140602>.