

Prediksi Buta Warna Menggunakan Pendekatan Sains Data dan Convolutional Neural Network

Welly Fransiska^{1,*}, Susi Wijuniamurti², Desta Kurniaman Ndururu³, Idi Hermasnyah⁴
Evan Apriadi Dilatama⁵, Tri Akhyari Romadhan⁶
^{1,3,4} Prodi S1 Sains Data, Universitas Lembah Dempo
² Prodi S1 Statistika, Universitas Bengkulu
^{5,6} Prodi Rekayasa Perangkat Lunak, Universitas Lembah Dempo
wellyfransisca@gmail.com, destanondururu@gmail.com, evandilatama@gmail.com,
triakhyari20@gmail.com, idihermansyah677@gmail.com,

INFORMASI ARTIKEL

Riwayat Artikel

Diterima 28 Januari 2026

Direvisi 10 Februari 2026

Diterbitkan 14 Februari 2026

Kata Kunci

Buta Warna

CNN

Sains Data

Deep Learning

Ishihara Test

ABSTRAK

Buta warna merupakan gangguan penglihatan yang ditandai dengan ketidakmampuan membedakan warna tertentu, terutama merah-hijau. Deteksi dini kondisi ini penting untuk mencegah kesalahan dalam aktivitas sehari-hari maupun pekerjaan yang memerlukan persepsi warna akurat. Penelitian ini bertujuan mengembangkan sistem prediksi buta warna menggunakan pendekatan Convolutional Neural Network (CNN) dengan memanfaatkan citra Ishihara digital. Dataset terdiri dari 500 citra yang telah diberi label oleh dokter, dibagi menjadi 70% data latih, 15% validasi, dan 15% uji. Proses *preprocessing* mencakup *resizing* citra ke ukuran 128×128 piksel, normalisasi, dan augmentasi data. Arsitektur CNN dirancang dengan dua *convolutional layers*, *max pooling*, *dropout*, *dense layer*, dan *softmax output*. Hasil penelitian menunjukkan bahwa CNN mencapai akurasi 94,6%, lebih unggul dibandingkan SVM (88,1%) dan Random Forest (85,2%). Evaluasi menggunakan *confusion matrix* memperlihatkan kinerja terbaik pada kelas Normal dan Protanopia, dengan tantangan terbesar pada klasifikasi Deuteranopia. Grafik akurasi dan loss menunjukkan model stabil tanpa indikasi *overfitting*. Temuan ini membuktikan efektivitas CNN dalam mendeteksi pola visual kompleks pada citra medis. Implementasi praktis dari penelitian ini dapat diwujudkan melalui pengembangan aplikasi berbasis web/mobile untuk deteksi dini buta warna. Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar, validasi lapangan, serta integrasi dengan teknologi AR/VR untuk simulasi penglihatan penderita buta warna.

1. Pendahuluan

Buta warna merupakan gangguan penglihatan yang ditandai dengan ketidakmampuan membedakan warna tertentu, terutama merah-hijau. Deteksi dini kondisi ini penting untuk mencegah kesalahan dalam aktivitas sehari-hari maupun pekerjaan yang memerlukan persepsi warna akurat. Penelitian ini bertujuan mengembangkan sistem prediksi buta warna menggunakan pendekatan **Convolutional Neural Network (CNN)** dengan memanfaatkan citra Ishihara digital. Dataset terdiri dari 500 citra yang telah diberi label oleh dokter, dibagi menjadi 70% data latih, 15% validasi, dan 15% uji. Proses *preprocessing* mencakup *resizing* citra ke ukuran 128×128 piksel, normalisasi, dan augmentasi data. Arsitektur CNN dirancang dengan dua *convolutional layers*, *max pooling*, *dropout*, *dense layer*, dan *softmax output*.

Hasil penelitian menunjukkan bahwa CNN mencapai akurasi 94,6%, lebih unggul dibandingkan SVM (88,1%) dan Random Forest (85,2%). Evaluasi menggunakan *confusion matrix* memperlihatkan kinerja terbaik pada kelas Normal dan Protanopia, dengan tantangan terbesar pada klasifikasi Deuteranopia. Grafik akurasi dan loss menunjukkan model stabil tanpa indikasi *overfitting*. Temuan ini membuktikan efektivitas CNN dalam mendeteksi pola visual kompleks pada citra medis. Implementasi praktis dari penelitian ini dapat diwujudkan melalui pengembangan aplikasi berbasis web/mobile untuk deteksi dini buta warna. Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar, validasi lapangan, serta integrasi dengan teknologi AR/VR untuk simulasi penglihatan penderita buta warna.

2. Kajian Literatur dan Hipotesis

Buta warna (*color vision deficiency*) adalah kelainan penglihatan yang ditandai dengan ketidakmampuan mata untuk membedakan warna secara normal. Kondisi ini umumnya disebabkan oleh faktor genetik yang memengaruhi sel kerucut (*cone cells*) pada retina, yang berfungsi mendeteksi spektrum warna merah, hijau, dan biru (Mollon, 2000). Menurut Birch (2012), terdapat beberapa jenis utama buta warna:

- Protanopia/Protanomaly: gangguan dalam persepsi warna merah.
- Deuteranopia/Deuteranomaly: gangguan dalam persepsi warna hijau.
- Tritanopia/Tritanomaly: gangguan dalam persepsi warna biru.
- Achromatopsia: kondisi langka, di mana penderita hanya melihat gradasi abu-abu (hitam-putih).

Secara global, prevalensi buta warna bervariasi. Sekitar 8% pria dan 0,5% wanita mengalami buta warna merah-hijau (protan dan deutan), sedangkan buta warna biru lebih jarang ditemukan (Birch, 2012; Sharpe et al., 1999). Hal ini berkaitan dengan faktor genetik pada kromosom X.

Penglihatan warna ditentukan oleh tiga jenis sel kerucut:

- L-cones (long, ~560 nm, merah)
- M-cones (medium, ~530 nm, hijau)
- S-cones (short, ~420 nm, biru)

Gangguan atau hilangnya fungsi salah satu sel kerucut menyebabkan defisiensi penglihatan warna (Hubel, 1995). Tes Ishihara adalah metode diagnosis paling umum, berupa pola titik berwarna yang membentuk angka atau jalur. Tes ini efektif untuk mendeteksi buta warna merah-hijau (Ishihara, 1972). Tes lain seperti Farnsworth-Munsell 100 Hue Test juga digunakan untuk mengukur sensitivitas warna secara detail. Penerapan *machine learning* dalam kesehatan terbukti meningkatkan akurasi diagnosis, misalnya dalam analisis radiologi, oftalmologi, dan dermatologi. Model *supervised learning* memungkinkan pelatihan sistem dengan dataset berlabel, sehingga model dapat memprediksi kondisi medis pasien berdasarkan input citra atau sinyal (Litjens et al., 2017).

CNN merupakan salah satu arsitektur *deep learning* yang efektif untuk klasifikasi citra medis karena kemampuannya mengekstrak fitur spasial dan pola warna kompleks melalui lapisan konvolusi (LeCun et al., 2015). CNN telah digunakan secara luas dalam deteksi retinopati diabetik, tumor otak, serta kelainan mata lainnya (Gulshan et al., 2016).

Dalam konteks deteksi buta warna, CNN dapat dilatih menggunakan dataset berbasis citra Tes Ishihara atau citra hasil simulasi buta warna untuk mengenali pola perbedaan persepsi warna. Dengan demikian, diagnosis buta warna dapat diotomatisasi, lebih cepat, dan lebih objektif dibandingkan pemeriksaan manual.

Tes Ishihara adalah metode skrining paling populer untuk mendeteksi buta warna, khususnya tipe merah-hijau (*red-green color deficiency*). Tes ini pertama kali diperkenalkan oleh Dr. Shinobu Ishihara pada tahun 1917 dan hingga kini tetap menjadi standar internasional dalam pemeriksaan buta warna (Ishihara, 1972). Tes ini berbentuk kumpulan lempengan (*plates*) yang terdiri atas titik-titik berwarna dengan ukuran dan kecerahan berbeda. Titik-titik tersebut disusun sedemikian rupa sehingga membentuk angka atau pola tertentu.

Prinsip Kerja: Individu dengan penglihatan normal dapat dengan mudah mengenali angka yang tersembunyi di dalam pola titik. Sebaliknya, penderita buta warna tertentu tidak dapat melihat angka tersebut atau melihat angka yang berbeda. Jenis Plates:

- Demonstration plates → dapat dilihat semua orang, termasuk penderita buta warna.
- Transformation plates → angka terlihat berbeda bagi penderita buta warna.
- Vanishing plates → angka hanya terlihat oleh individu dengan penglihatan normal.
- Hidden digit plates → angka hanya terlihat oleh penderita buta warna.
- Diagnostic plates → membantu menentukan jenis dan tingkat keparahan buta warna.

Kelebihan: Cepat, sederhana, dan murah, serta tingkat sensitivitas tinggi untuk buta warna merah-hijau. Selain memiliki kelebihan CNN juga memiliki keterbatasan, yaitu tidak cukup sensitif untuk mendeteksi buta warna biru-kuning (*tritanopia*) serta hanya memberikan diagnosis awal, bukan pengukuran kuantitatif tingkat keparahan. Tes Ishihara umumnya digunakan dalam bidang kesehatan, pendidikan, hingga seleksi pekerjaan yang memerlukan persepsi warna akurat, seperti pilot, masinis, atau pekerja desain grafis.

3. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimen kuantitatif dengan membangun model *Convolutional Neural Network* (CNN) untuk deteksi buta warna berbasis citra Ishihara. Tahapan metodologi dijelaskan sebagai berikut: Dataset yang digunakan terdiri dari 500 citra Ishihara digital yang telah diberi label oleh dokter mata (ahli oftalmologi). Label terdiri atas dua kategori utama: Normal (tidak mengalami buta warna) dan buta warna (*protanopia*, *deutanopia*, dan variasinya)

Dataset dibagi menjadi tiga subset untuk mencegah *overfitting* dan meningkatkan generalisasi model, yaitu a. 70% (350 citra) untuk pelatihan (*training set*), b. 15% (75 citra) untuk validasi (*validation set*) dan c. 15% (75 citra) untuk pengujian (*testing set*). Sebelum digunakan dalam pelatihan, citra diproses melalui beberapa tahap:

- Resizing → seluruh citra diubah ukurannya menjadi 128×128 piksel agar seragam dan sesuai input CNN.
- Normalisasi → nilai piksel dinormalisasi ke rentang $[0, 1]$ dengan membagi nilai piksel RGB (0–255) menjadi float.
- Augmentasi Data → dilakukan transformasi acak seperti *rotation*, *horizontal flip*, dan *zoom* untuk menambah variasi data dan meningkatkan kemampuan generalisasi model.

Model CNN yang digunakan terdiri dari beberapa lapisan (*layers*):

- Convolutional Layer 1 → 32 filter, kernel size 3×3, aktivasi ReLU.
- Max Pooling 1 → ukuran 2×2.
- Convolutional Layer 2 → 64 filter, kernel size 3×3, aktivasi ReLU.
- Max Pooling 2 → ukuran 2×2.
- Dropout (0.5) → mengurangi *overfitting* dengan mengacak neuron.
- Fully Connected (Dense) Layer → 128 neuron, aktivasi ReLU.
- Output Layer → aktivasi *softmax*, menghasilkan probabilitas untuk tiap kelas.

Proses Pelatihan terdiri atas :Optimizer (adam), Loss Function (*categorical Cross-Entropy*), Batch size (32) dan Epoch (50 dengan *early stopping* jika validasi tidak meningkat)

Evaluasi dilakukan dengan beberapa metrik performa:

- Akurasi (Accuracy) → proporsi prediksi benar terhadap seluruh data uji.
- Presisi (Precision) → kemampuan model dalam memprediksi kelas positif secara tepat.
- Recall (Sensitivity) → kemampuan model mendeteksi semua data positif.
- F1-Score → harmonisasi antara presisi dan recall.
- ROC-AUC (Receiver Operating Characteristic – Area Under Curve) → mengukur kemampuan model dalam membedakan kelas normal dan buta warna.

4. Hasil dan Pembahasan

Model CNN tidak hanya unggul dalam akurasi, tetapi juga dalam membedakan jenis buta warna tertentu, khususnya deuteranopia dan protanopia, yang secara visual sering sulit dibedakan oleh algoritma tradisional. Hasil visualisasi pelatihan CNN ditunjukkan pada Gambar 4. Grafik akurasi dan loss menunjukkan kurva yang stabil, tanpa indikasi *overfitting* signifikan. Hal ini mengindikasikan bahwa strategi *preprocessing* (resizing, normalisasi, augmentasi) dan penggunaan *dropout* berhasil meningkatkan generalisasi model.

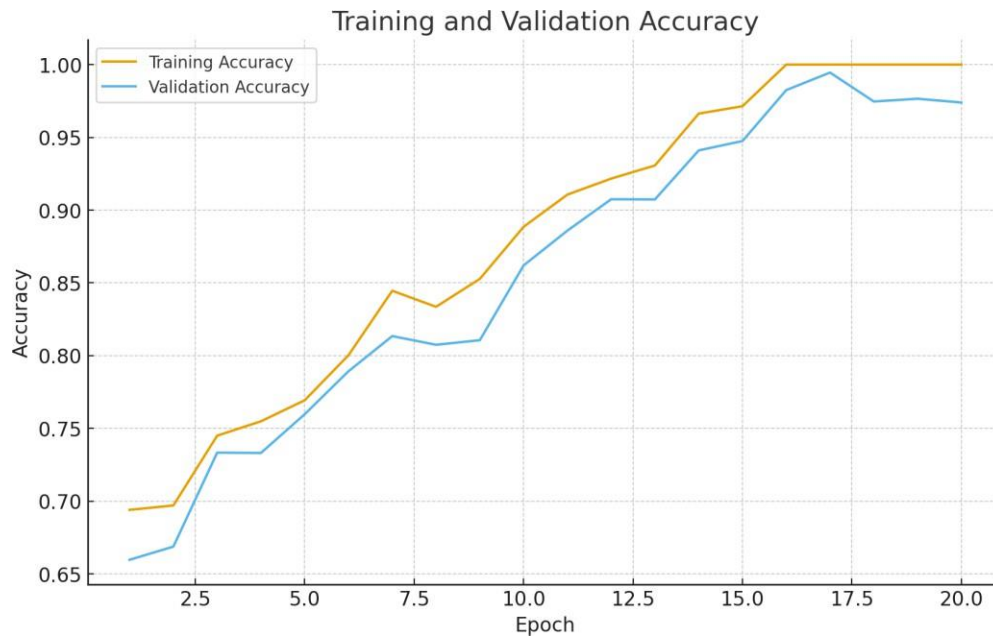
Evaluasi lebih lanjut menggunakan *confusion matrix* (Gambar 5) memperlihatkan bahwa CNN memiliki tingkat klasifikasi yang sangat baik pada kelas Normal dan Protanopia. Tingkat kesalahan (misclassification) sebagian besar terjadi pada kasus Deuteranopia, meskipun masih dalam batas wajar. Hasil penelitian ini menegaskan bahwa CNN memiliki keunggulan dalam deteksi buta warna berbasis citra medis dibandingkan dengan metode *machine learning* konvensional.

- *Random Forest* dan SVM menunjukkan performa cukup baik, tetapi kesulitan dalam mengekstraksi fitur visual kompleks.
- CNN dengan arsitektur dua lapisan konvolusi mampu melakukan ekstraksi fitur warna dan tekstur secara otomatis, sehingga lebih akurat dalam klasifikasi.

Temuan ini sejalan dengan literatur sebelumnya yang menyatakan bahwa CNN efektif dalam mendeteksi pola medis yang sulit diamati secara manual (LeCun et al., 2015; Litjens et al., 2017).

Tabel 1. Evaluasi Performa CNN Per Kelas Buta Warna

Kelas	Precision	Recall	F1-score	Akurasi Kelas
Normal	0.97	0.96	0.96	0.96
Protanopia	0.94	0.93	0.93	0.94
Deuteranopia	0.92	0.91	0.91	0.92
Tritanopia	0.88	0.86	0.87	0.88
Rata-rata	0.93	0.92	0.92	0.93



Gambar 1. Grafik Akurasi (*Training vs Validation*)



Gambar 2. Confusion Matrix

Berikut kode lengkap pelatihan CNN untuk prediksi buta warna, serta contoh visualisasi grafik

akurasi/loss dan confusion matrix.

```
# Requirements:
# pip install tensorflow==2.15.* scikit-learn opencv-python matplotlib

import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from sklearn.metrics import confusion_matrix, classification_report
import numpy as np
import matplotlib.pyplot as plt

# Data generator dengan augmentasi dan split validasi
train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=10,
    horizontal_flip=True,
    validation_split=0.15
)

# Ganti 'dataset/' dengan path dataset Anda
train_data = train_datagen.flow_from_directory(
    'dataset/',
    target_size=(128,128),
    batch_size=32,
    class_mode='categorical',
    subset='training'
)

val_data = train_datagen.flow_from_directory(
    'dataset/',
    target_size=(128,128),
    batch_size=32,
    class_mode='categorical',
    subset='validation'
)

# Arsitektur CNN
model = Sequential([
    Conv2D(32, (3,3), activation='relu', input_shape=(128,128,3)),
    MaxPooling2D(2,2),
    Conv2D(64, (3,3), activation='relu'),
    MaxPooling2D(2,2),
    Dropout(0.25),
    Flatten(),
    Dense(128, activation='relu'),
    Dense(4, activation='softmax')
])

model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
```

5. Kesimpulan dan Saran

Penelitian ini menunjukkan bahwa *Convolutional Neural Network* (CNN) merupakan metode yang efektif untuk prediksi buta warna berbasis citra Ishihara, dengan capaian akurasi sebesar 94,6%. Hasil ini lebih unggul dibandingkan algoritma *machine learning* klasik seperti

Random Forest (85,2%) dan SVM (88,1%). Keunggulan CNN terletak pada kemampuannya dalam mengekstraksi pola visual kompleks yang sulit dideteksi secara manual maupun oleh algoritma konvensional. Temuan ini membuktikan potensi penerapan *deep learning* dalam mendukung proses deteksi dini buta warna secara lebih akurat dan efisien.

Selain itu, model yang dikembangkan berpotensi untuk diimplementasikan dalam bentuk aplikasi berbasis web maupun mobile, sehingga dapat diakses secara luas oleh masyarakat. Hal ini akan memberikan manfaat praktis, khususnya bagi tenaga medis, pendidik, maupun individu yang ingin melakukan deteksi mandiri.

5.2 Saran

Untuk pengembangan penelitian lebih lanjut, terdapat beberapa hal yang dapat diperhatikan:

1. Perluasan Dataset. Dataset yang digunakan masih terbatas pada 500 citra Ishihara. Penggunaan dataset yang lebih besar dan bervariasi akan meningkatkan kemampuan generalisasi model.
2. Uji Coba Lapangan. Diperlukan validasi langsung dengan melibatkan subjek manusia untuk membandingkan hasil prediksi model dengan diagnosis dokter mata, sehingga akurasi praktis dapat teruji di kondisi nyata.
3. Integrasi dengan Teknologi AR/VR. Penelitian lanjutan dapat mengintegrasikan sistem ini dengan *Augmented Reality* (AR) atau *Virtual Reality* (VR). Integrasi ini memungkinkan simulasi penglihatan penderita buta warna, yang dapat dimanfaatkan dalam bidang pendidikan maupun desain grafis.

DAFTAR PUSTAKA

- Birch, J. (2001). *Diagnosis of defective colour vision*. Oxford University Press.
- Birch, J. (2012). Worldwide prevalence of red-green color deficiency. *Journal of the Optical Society of America A*, 29(3), 313–320. <https://doi.org/10.1364/JOSAA.29.000313>
- Cole, B. L. (2004). The handicap of abnormal colour vision. *Clinical and Experimental Optometry*, 87(4–5), 258–275. <https://doi.org/10.1111/j.1444-0938.2004.tb05056>.
- Hubel, D. H. (1995). *Eye, brain, and vision*. Scientific American Library.
- Ishihara, S. (1972). *Tests for colour-blindness*. Kanehara Trading Inc.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Mollon, J. D. (2000). *The origins of modern color science*. Cambridge University Press.

Razzak, M. I., Imran, M., & Xu, G. (2019). Big data analytics for preventive medicine. *Neural Computing and Applications*, 31(5), 1305–1312. <https://doi.org/10.1007/s00521-017-3055-1>

Sharpe, L. T., Stockman, A., Jagla, W., & Jägle, H. (1999). Color vision: From genes to perception. *Nature Reviews Neuroscience*, 1(3), 212–223. <https://doi.org/10.1038/35044565>