

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK INCEPTIONV3 UNTUK ANALISIS KUALITAS TIDUR BERBASIS CITRA WAJAH

M. Alwi Sihab^{1*}, Asep Budiman Kusdinar², Agung Pambudi³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Sukabumi; Jl. R. Syamsudin, S.H. No. 50, Sukabumi; Telp/Fax (0266) 218342

Keywords:

Convolutional Neural Network;
InceptionV3;
Kualitas Tidur;
Citra Wajah;
Deep Learning.

Correspondent Email:

malwisihab@ummi.ac.id

Abstrak. Kualitas tidur berperan penting dalam menjaga kesehatan fisik dan mental, namun penilaian kesehatan tidur saat ini masih bersifat subjektif atau memerlukan perangkat medis yang kurang praktis. Penelitian ini bertujuan menganalisis tingkat kesehatan tidur seseorang melalui citra wajah, dengan fokus utama pada area mata, menggunakan metode *Convolutional Neural Network* (CNN) arsitektur *InceptionV3* melalui pendekatan *transfer learning*. Metodologi penelitian mengikuti kerangka kerja CRISP-DM yang meliputi *business understanding*, *data understanding*, *data preparation*, *modeling*, dan *evaluation*. Dataset yang digunakan berjumlah 9.752 citra wajah subjek berusia 19–25 tahun yang bersumber dari data primer, dataset publik, dan hasil *web scraping*, dibagi menjadi 80% data latih, 10% data validasi, dan 10% data uji dengan skema *subject-based split*. Model dilatih untuk mengklasifikasikan kualitas tidur ke dalam empat kategori, yaitu Tidur Baik, Tidur Cukup, Tidur Kurang, dan Tidur Buruk, serta dievaluasi menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan model mencapai akurasi 99,39% dengan *F1-score* rata-rata 0,9939 pada 976 data uji. Model kemudian diimplementasikan ke dalam aplikasi *web SleepyFace* berbasis *Flask*. Hasil ini menunjukkan bahwa pendekatan CNN berbasis area mata dapat digunakan secara efektif dan objektif untuk memantau kesehatan tidur secara mandiri.



Copyright © 2026 The Author(s), Published by Jurnal Informatika dan Teknik Elektro Terapan. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

Abstract. Sleep quality plays an important role in maintaining physical and mental health; however, current sleep-quality assessments are generally subjective or require specialized devices. This study analyzes indications of an individual's sleep quality based on facial images, focusing primarily on the eye region, by applying a Convolutional Neural Network (CNN) with the InceptionV3 architecture through transfer learning. The research follows the CRISP-DM framework, covering business understanding, data understanding, data preparation, modeling, and evaluation. The dataset consists of 9,752 facial images of subjects aged 19-25 years, obtained from primary data, public datasets, and web scraping, split into 80% training, 10% validation, and 10% testing data using a subject-based split. The model classifies sleep quality into four categories: Good Sleep, Adequate Sleep, Insufficient Sleep, and Poor Sleep, evaluated using accuracy, precision, recall, and F1-score. The model achieved a test accuracy of 99.39% and a weighted average F1-score of 0.9939 on 976 test images, and was deployed as a Flask-based web application named SleepyFace. These results indicate that an eye-region-focused CNN approach can objectively and effectively support independent sleep-health monitoring.

1. PENDAHULUAN

Kualitas tidur merupakan salah satu indikator utama dalam menentukan tingkat kesehatan tidur seseorang, yang ditentukan [1]kontinuitas dan kemampuan tubuh untuk memperbaiki diri setelah bangun[2]. Gangguan kesehatan tidur menjadi permasalahan global yang serius, dengan sekitar 10% populasi Indonesia dilaporkan mengalami masalah tidur [3]. Kualitas tidur yang buruk berdampak pada peningkatan risiko penyakit kardiovaskular, diabetes, serta penurunan fungsi kognitif dan produktivitas, khususnya pada kelompok mahasiswa [2], [3].

Secara fisiologis, penurunan kualitas tidur berdampak pada wajah manusia. Area mata (mata merah, kantung mata, penyempitan kelopak mata), kondisi bibir, tekstur kulit, dan ekspresi mikro seperti menguap merupakan indikator visual utama dari kelelahan dan gangguan tidur[4]. Penilaian manual terhadap tanda-tanda tersebut umumnya bersifat subjektif dan tidak konsisten, sehingga diperlukan pendekatan otomatis berbasis kecerdasan buatan[5],[6]. *Convolutional Neural Network* (CNN) terbukti efektif digunakan sebagai sistem deteksi kelelahan otomatis karena mampu mempelajari fitur visual secara hierarkis tanpa memerlukan ekstraksi fitur manual [4].

Sebagian besar penelitian terdahulu masih menggunakan pendekatan yang parsial: penelitian kesehatan tidur umumnya menggunakan survei atau pengukuran fisiologis non-visual, sedangkan penelitian analisis wajah lebih berfokus pada identifikasi biometrik atau deteksi kelelahan ringan seperti kedipan mata. Belum banyak penelitian yang menerapkan CNN untuk analisis wajah secara menyeluruh yang mencakup kondisi mata, kulit, dan bibir sekaligus, serta yang mempertimbangkan variasi bentuk mata pada populasi Asia (termasuk mata sipit/monolid)[7]. yang kurang terwakili pada dataset yang telah ada. Kesenjangan inilah yang mendasari penelitian ini[7][5], [8], [9].

Berdasarkan uraian tersebut, penelitian ini bertujuan

(1) mengidentifikasi dan menganalisis area mata, warna kulit, dan kondisi bibir sebagai indikator visual dalam menentukan tingkat kesehatan tidur seseorang, dan

(2) mengembangkan, menerapkan, serta menguji sistem klasifikasi berbasis CNN dengan arsitektur *InceptionV3* melalui pendekatan *transfer learning* yang dapat mengukur kesehatan tidur secara otomatis dan objektif berdasarkan citra wajah, kemudian mengimplementasikannya ke dalam aplikasi *web*.

2. TINJAUAN PUSTAKA

Penelitian mengenai pola tidur dan dampaknya terhadap kesehatan tubuh menunjukkan bahwa kurang tidur berkaitan dengan variabilitas tekanan darah dan peningkatan risiko penyakit jangka panjang pada kelompok usia produktif [2]. Di sisi lain, penelitian di bidang pengolahan citra wajah menunjukkan bahwa deteksi wajah berbasis *Haar Cascade* maupun pendekatan berbasis pembelajaran mendalam mampu memberikan objektivitas yang lebih tinggi dibandingkan penilaian manual, meskipun deteksi berbasis fitur *Haar* tetap sensitif terhadap variasi pencahayaan dan sudut wajah [10][11] .

Pada ranah klasifikasi citra, penelitian menunjukkan bahwa algoritma *deep learning* seperti CNN mampu mengenali pola visual kompleks tanpa ekstraksi fitur manual, dengan performa yang sangat dipengaruhi oleh strategi pelatihan, regularisasi, augmentasi data, dan penggunaan model prelatih[12]. Studi lain menerapkan CNN untuk deteksi kelelahan pengemudi (*drowsiness*) berbasis citra wajah dan menunjukkan bahwa arsitektur CNN *robust* terhadap variasi ekspresi dan pencahayaan[5]. Penelitian klasifikasi gender berbasis citra wajah dengan pendekatan *clustering* dan *deep learning* turut menegaskan bahwa arsitektur *InceptionV3* mampu menghasilkan representasi

fitur yang akurat pada data wajah yang bersumber dari media tidak terstruktur [13].

Metodologi CRISP-DM telah banyak digunakan pada penelitian berbasis citra wajah dan pembelajaran mendalam, seperti pada penelitian deteksi emosi wajah, karena mampu mengakomodasi tahapan teknis mulai dari preprocessing citra, pelatihan model, hingga evaluasi performa klasifikasi secara sistematis [13]. Berdasarkan tinjauan tersebut, penelitian ini memposisikan diri sebagai pengembangan dari penelitian-penelitian terdahulu dengan menggabungkan analisis multi-indikator wajah (mata, kulit, dan bibir), penambahan variasi data bentuk mata Asia melalui *web scraping*, serta penerapan skema *subject-based split* untuk mencegah kebocoran data pada proses evaluasi model [1], [14].

3. METODE PENELITIAN

Penelitian ini menggunakan metode CRISP-DM (*Cross Industry Standard Process for Data Mining*) yang terdiri atas enam tahapan: *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment* [15], [16].

3.1 Business Understanding

Tahap ini merumuskan kebutuhan sistem yang mampu mendeteksi indikasi kualitas tidur secara objektif melalui citra wajah, tanpa memerlukan perangkat medis khusus, dengan target keluaran berupa empat kategori kualitas tidur: Tidur Baik, Tidur Cukup, Tidur Kurang, dan Tidur Buruk [1][7].

3.2 Data Understanding dan Data Preparation

Dataset penelitian berjumlah 9.752 citra wajah yang bersumber dari data primer (pemeriksaan langsung disertai formulir riwayat tidur), data sekunder (dataset publik *Drowsiness Dataset* dari *Kaggle*), dan data tambahan hasil *web scraping* untuk memperkaya variasi bentuk mata pada populasi Asia. Label kelas pada data primer ditentukan berdasarkan kombinasi *self-report* durasi tidur dan observasi visual, dengan estimasi

kekurangan jam tidur terhadap kebutuhan normal 7-9 jam sebagai acuan kategori. Tahap persiapan data meliputi deteksi wajah menggunakan *Haar Cascade*, *cropping area* 0-60% bagian atas wajah (fokus pada area mata), *resizing* ke 299×299 piksel sesuai kebutuhan input *InceptionV3*, normalisasi piksel ke rentang 0-1, serta augmentasi (rotasi 15°, pergeseran lebar/tinggi 10%, horizontal flip, dan *zoom* 10%) yang hanya diterapkan pada data latih. Dataset dibagi menggunakan skema *subject-based split* dengan rasio 80% latih (7.808 citra), 10% validasi (973 citra), dan 10% uji (978 citra) untuk mencegah kebocoran data antar subset.

3.3 Modeling

Model dibangun di atas arsitektur *InceptionV3* sebagai base model dengan bobot pra-latih *ImageNet* (*include_top=False*), ditambah lapisan *Global Average Pooling*, *Dense* 256 unit dengan aktivasi ReLU, *Dropout* 0,5, dan lapisan *output Dense* 4 unit dengan aktivasi *Softmax*. Pelatihan dilakukan dalam dua fase: (1) *feature extraction*, dengan base model dibekukan (*trainable=False*), *learning rate* 0,001, *optimizer* Adam, selama 15 *epoch*; dan (2) *fine tuning*, dengan 50 lapisan terakhir base model diaktifkan kembali, *learning rate* diturunkan menjadi 0,0001, dilatih hingga 30 *epoch*. Fungsi *loss* yang digunakan adalah *categorical crossentropy* dengan *batch size* 64 dan *mixed precision* (*mixed_float16*). *Callback EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint* digunakan untuk menjaga stabilitas pelatihan dan menyimpan bobot terbaik berdasarkan *validation accuracy*.

3.4 Evaluation

Evaluasi model dilakukan menggunakan *Confusion Matrix* serta metrik *Accuracy*, *Precision*, *Recall*, dan *F1-score* sebagaimana Persamaan (1)-(4):

$$Accuracy = (TP+TN) / (TP+TN+FP+FN) \quad (1)$$

$$Precision = TP / (TP+FP) \quad (2)$$

$$Recall = TP / (TP + FN) \quad (3)$$

$$F1-Score = 2 \times (Precision \times Recall) / (Precision + Recall) \quad (4)$$


3.5 Deployment

Model terbaik diintegrasikan ke dalam aplikasi web bernama *SleepyFace* berbasis framework *Flask* (Python). Sistem menerima citra wajah melalui unggahan berkas atau kamera perangkat secara real-time, melakukan pra-pemrosesan menggunakan *OpenCV* (deteksi wajah, *cropping*, *resize*, normalisasi), kemudian meneruskan hasilnya ke model *InceptionV3* untuk inferensi. Hasil klasifikasi beserta *confidence score* ditampilkan kepada pengguna dan disimpan pada basis data riwayat analisis.

4. HASIL DAN PEMBAHASAN

4.1 Distribusi Dataset

Dataset akhir berjumlah 9.752 citra yang terbagi ke dalam empat kelas dengan komposisi relatif seimbang (selisih $\pm 7\%$ antar kelas), sehingga meminimalkan risiko bias model terhadap kelas tertentu. Tabel 1 menyajikan distribusi dataset per kelas dan subset.



Gambar 1. Distribusi Dataset Per kelas

Kelas	Train (80%)	Validasi (10%)	Test (10%)	Total
Tidur Baik	2.005	250	251	2.506
Tidur Buruk	1.863	232	234	2.466
Tidur Cukup	1.972	246	248	2.466
Tidur Kurang	1.968	245	245	2.458

Kelas	Train (80%)	Validasi (10%)	Test (10%)	Total
Tidur Baik	1.863	232	234	2.329
Tidur Buruk				
Total	7.808	973	978	9.752

Tabel 1. Distribusi Dataset per Kelas dan Subset

4.2 Hasil Pelatihan Model

Pada *Fase 1 (feature extraction)*, *validation accuracy* meningkat konsisten dari 91,18% pada *epoch* pertama hingga mencapai 96,21% dengan *validation loss* 0,1358 pada *epoch* terakhir. Pada *Fase 2 (fine tuning)*, pelatihan berhenti otomatis pada *epoch* ke-10 dari 15 *epoch* yang direncanakan karena *EarlyStopping*, dengan *validation accuracy* terbaik 99,38%. Kurva *training* dan *validation accuracy* meningkat konsisten sementara *loss* menurun pada kedua subset, tanpa indikasi *overfitting* yang signifikan, yang mengonfirmasi efektivitas strategi *transfer learning* dua fase.


4.3 Evaluasi Model pada Data Uji

Model dievaluasi pada 976 citra data uji yang belum pernah dilihat selama pelatihan, menghasilkan *Test Accuracy* sebesar 99,39% dan *Test Loss* sebesar 0,0187. Tabel 2 menyajikan *classification report* yang menunjukkan *precision*, *recall*, dan *F1-score* untuk setiap kelas.

Kelas	Precision	Recall	F1-Score	Support
Tidur Baik	1,0000	1,0000	1,0000	251
Tidur Buruk	0,9957	1,0000	0,9979	233
Tidur Cukup	0,9839	0,9919	0,9879	247
Tidur Kurang	0,9959	0,9837	0,9897	245
Weighted Avg	0,9939	0,9939	0,9939	976

Tabel 2. Classification Report Model InceptionV3

Tabel 3 menyajikan *confusion matrix* hasil pengujian model, yang menunjukkan distribusi prediksi terhadap label aktual pada setiap kelas.



Gambar 2. Confusion Matrix Model InceptionV3 pada Data Uji

Aktual \ Prediksi	Tidur Baik	Tidur Buruk	Tidur Cukup	Tidur Kurang
Tidur Baik	251	0	0	0
Tidur Buruk	0	233	0	0
Tidur Cukup	0	1	245	1
Tidur Kurang	0	0	4	241

Tabel 3. Confusion Matrix Model InceptionV3 pada Data Uji

Berdasarkan Tabel 2, kelas Tidur Baik dan Tidur Buruk memperoleh akurasi klasifikasi sempurna (100%), sementara kelas Tidur Cukup memperoleh F1- score terendah (0,9879). Analisis *confusion matrix* menunjukkan bahwa dari total 976 sampel uji, hanya 6 sampel yang mengalami misklasifikasi, dengan kesalahan terbanyak terjadi antara kelas Tidur Cukup dan Tidur Kurang. Hal ini dapat dijelaskan oleh kemiripan fitur visual pada area mata di antara kedua kondisi tersebut, seperti derajat bukaan kelopak mata yang relatif berdekatan dan bergantung pada variasi individu. Secara keseluruhan, hasil ini menunjukkan bahwa model *InceptionV3* berhasil membangun batas keputusan yang sangat efektif dalam membedakan keempat kategori kualitas tidur, khususnya setelah dilatih menggunakan skema *subject-based split* yang bebas dari data *leakage*.

4.4 Implementasi Sistem (Deployment)

Model yang telah dilatih diimplementasikan ke dalam aplikasi *web SleepyFace* yang terdiri dari tiga lapisan: frontend (HTML5, CSS3, JavaScript) untuk antarmuka unggah/pengambilan citra wajah, backend (Flask) untuk pra-pemrosesan citra menggunakan *OpenCV* serta orkestrasi inferensi, dan lapisan model *InceptionV3* yang dimuat sekali pada saat server dijalankan agar proses inferensi lebih efisien. Sistem menampilkan hasil klasifikasi berupa kategori kualitas tidur beserta *confidence score*, estimasi jam kekurangan tidur, dampak kesehatan, dan rekomendasi, yang dapat diunduh dalam bentuk laporan PDF maupun dibagikan melalui *WhatsApp*. Fitur riwayat analisis dan *dashboard* admin turut disediakan untuk memantau data hasil analisis pengguna dari waktu ke waktu.

Implementasi ini membuktikan bahwa sistem klasifikasi kualitas tidur berbasis citra wajah dapat digunakan secara praktis tanpa memerlukan perangkat medis khusus seperti *polysomnography*. Meskipun demikian, kinerja sistem tetap dipengaruhi oleh kualitas citra input (pencahayaannya, sudut pengambilan, resolusi), keterbatasan variasi demografis pada dataset pelatihan, serta proses inferensi yang saat ini masih dilakukan secara sinkron per citra dan belum mendukung analisis *real-time* melalui video *streaming* secara berkelanjutan.

5. KESIMPULAN

Model klasifikasi kualitas tidur berbasis CNN dengan arsitektur *InceptionV3* dan pendekatan *transfer learning* dua fase berhasil mencapai akurasi pengujian sebesar 99,39% dengan F1-score rata-rata 0,9939 pada 976 citra uji, menggunakan skema *subject-based split* yang bebas dari kebocoran data.

Fokus ekstraksi fitur pada area mata (0-60% bagian atas wajah) beserta penambahan variasi bentuk mata Asia melalui *web scraping*

terbukti meningkatkan kemampuan generalisasi model terhadap keberagaman fisik wajah pengguna.

Model yang telah dilatih dan dievaluasi berhasil diimplementasikan ke dalam aplikasi *web SleepyFace* berbasis *Flask*, sehingga pengguna dapat melakukan analisis kualitas tidur secara mandiri, objektif, dan tanpa memerlukan perangkat medis khusus.

Penelitian selanjutnya disarankan memperluas variasi demografis dataset, mengeksplorasi arsitektur CNN yang lebih ringan untuk implementasi pada perangkat *mobile*, mendukung analisis *real-time* melalui video *streaming*, serta memperhatikan aspek keamanan dan privasi data biometrik pengguna.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Sukabumi, serta seluruh pihak yang telah memberikan dukungan, bimbingan, dan fasilitas selama penelitian ini berlangsung.

DAFTAR PUSTAKA

- [1] N. Lebkiri *et al.*, "Using Machine Learning for Prediction Students Failure in Morocco: an Application of the CRISP-DM Methodology," *Int. J. Educ. Inf. Technol.*, vol. 15, pp. 344–352, Oct. 2021, doi: 10.46300/9109.2021.15.36.
- [2] F. Kamila and N. C. Dainy, "Faktor-faktor yang Berhubungan dengan Kualitas Tidur Mahasiswa Kedokteran dan Kesehatan UMJ," *J. Ilmu Gizi dan Diet.*, vol. 2, no. 3, pp. 168–174, Oct. 2023, doi: 10.25182/jigd.2023.2.3.168-174.
- [3] A. Van Fadhila *et al.*, "Implementasi Metode Machine Learning Untuk Mendeteksi Tingkat Stres Manusia Berdasarkan Kualitas Tidur," 2023.
- [4] H. Arifa Rahmayanti *et al.*, "Dampak Pola Tidur terhadap Variabilitas Tekanan Darah pada Mahasiswi dengan Pola Hidup Tidak Teratur," 2025. [Online]. Available: <http://jurnalilmiah.org/journal/index.php/Anal> is
- [5] R. M. Salman, M. Rashid, R. Roy, M. M. Ahsan, and Z. Siddique, "Driver Drowsiness Detection Using Ensemble Convolutional Neural Networks on YawDD," Dec. 2021, [Online]. Available: <http://arxiv.org/abs/2112.10298>
- [6] E. Setia Budi, A. Nofriyaldi Chan, P. Priscillia Alda, and M. Arif Fauzi Idris, "RESOLUSI : Rekayasa Teknik Informatika dan Informasi Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network," *Media Online*, vol. 4, no. 5, p. 509, 2024, [Online]. Available: <https://djournals.com/resolusi>
- [7] C. Szegedy, V. Vanhoucke, S. Ioffe, and J. Shlens, "Rethinking the Inception Architecture for Computer Vision," 2022.
- [8] Harizahayu, "Facial emotion recognition base artificial neural network backpropagation with principal component analysis method," *Barekeng*, vol. 15, no. 1, pp. 037–046, Mar. 2021, doi: 10.30598/barekengvol15iss1pp037-046.
- [9] K. D. Shearer and K. D. Shearer, "Experimental design, statistical analysis and modelling of dietary nutrient requirement studies for @sh: a critical review," 2020.
- [10] J. Vokasi Teknik *et al.*, "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN OPTIMIZER ADAM DALAM DETEKSI EMOSIONALPADA WAJAH MANUSIA INFORMASI ARTIKEL A B S T R A K," 2021, doi: 10.12345/xxxxx.
- [11] M. H. Hasbi, "Face Recognition (Pengenalan Wajah) Untuk Sistem Presensi Berbasis Website Pada Laboratorium Software Universitas Andi Djemma," *J. Inform. dan Tek. Elektro Terap.*, vol. 14, no. 2, pp. 982–994, 2026, doi: 10.23960/jitet.v14i2.9078.
- [12] P. Mbaba, K. Anwar, S. Rahayu, A. Eka Kartawati, P. Studi Informatika, and F. Matematika dan Ilmu Pengetahuan Alam Universitas Udayana Bali, "PENERAPAN METODE CONVOLUTION NEURAL NETWORKS UNTUK MENGIDENTIFIKASI WAJAH KELELAHAN," 2022. [Online]. Available: <https://www.kaggle.com/datasets/davidvazquezic/yawn-dataset>
- [13] Okky Prasetya, Syaeful Machfud, P. Rosyani, and Bobi Agustian, "Klasifikasi Gender Berbasis Citra Wajah Menggunakan Clustering Dan Deep Learning," *Bull. Comput. Sci. Res.*, vol. 5, no. 4, pp. 770–777, Jun. 2025, doi: 10.47065/bulletincsr.v5i4.581.
- [14] A. Y. Setyawan, J. Jumadi, and E. Nurlatifah, "Deteksi Emosi Pada Citra Wajah Dengan Deep Learning Sebagai Alat Pendukung Terapi Bagi Pengidap Alexithymia," *SMATIKA J.*, vol. 14, no. 02, pp. 353–362, Dec. 2024, doi: 10.32664/smatika.v14i02.1368.
- [15] P. Viola and M. Jones, "Rapid Object Detection using a Boosted Cascade of Simple Features," 2021.

- [16] S. Siddique and J. C. L. Chow, "Machine Learning in Healthcare Communication," *Encyclopedia*, vol. 1, no. 1, pp. 220–239, Mar. 2021, doi: 10.3390/encyclopedia1010021.