



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 4 (2026) pp: 15319-15326

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Perbandingan Efektivitas Arsitektur CNN Pada Sistem Klasifikasi Kelelahan Pada Wajah Pengemudi

Adinda Sofia Iriyanti¹, Muhammad Ali Nur Hidayat², Jamaludin Hakim³, Stefanus Ndala⁴, Damar Surya Sasono⁵

¹Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Yapis Papua

^{2,3,4,5}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Yapis Papua

[1dndsofiaaaa@gmail.com](mailto:dndsofiaaaa@gmail.com), [2aalnur9@gmail.com](mailto:aalnur9@gmail.com), [3j2hakim@gmail.com](mailto:j2hakim@gmail.com), [4ndalstefanus@gmail.com](mailto:ndalstefanus@gmail.com), [5dsurvosas@gmail.com](mailto:dsurvosas@gmail.com)

Abstrak

Kondisi kelelahan pada pengemudi berperan signifikan dalam meningkatkan risiko kecelakaan lalu lintas karena berdampak langsung pada penurunan tingkat konsentrasi serta keterlambatan respons terhadap situasi di jalan. Dengan demikian, pengembangan sistem klasifikasi kelelahan berbasis citra wajah yang mampu melakukan deteksi secara otomatis dan memiliki tingkat keandalan tinggi menjadi kebutuhan yang penting. Penelitian ini bertujuan membandingkan kinerja empat arsitektur Convolutional Neural Network (CNN), yaitu VGG16, ResNet50, MobileNetV2, dan InceptionV3, dalam mengklasifikasikan kelelahan wajah pengemudi. Dataset penelitian ini mencakup sebanyak 2.000 citra wajah yang bersumber dari platform Kaggle, yang selanjutnya melalui tahap praproses meliputi penyesuaian ukuran citra, normalisasi nilai piksel, serta penerapan teknik augmentasi data. Seluruh model dilatih selama 35 epoch dengan memanfaatkan bobot awal pretrained ImageNet. Evaluasi performa dilakukan menggunakan metrik training accuracy, training loss, validation accuracy, dan validation loss. Hasil pengujian menunjukkan bahwa ResNet50 dan MobileNetV2 mencapai performa terbaik dengan training dan validation accuracy sebesar 100% serta validation loss yang rendah, masing-masing 0,0301 dan 0,0309. Sementara itu, VGG16 memperoleh training accuracy 95,82% dan validation accuracy 93,03% dengan validation loss 0,1511, sedangkan InceptionV3 mencapai training accuracy 98,57% dan validation accuracy 95,73% dengan validation loss yang relatif lebih tinggi. Hasil ini menunjukkan bahwa meskipun arsitektur CNN yang kompleks mampu menghasilkan akurasi tinggi, model ringan seperti MobileNetV2 lebih optimal untuk implementasi sistem deteksi kelelahan pengemudi berbasis real-time karena efisiensi komputasinya.

Kata kunci: Kelelahan Pengemudi, CNN, Klasifikasi Wajah, Deep Learning

1. Latar Belakang

Kecelakaan lalu lintas terus menjadi masalah besar yang membahayakan kehidupan manusia dan harta benda. (Hatta Fudholi et al., 2021) Sangat penting untuk membangun sistem pemantauan pengemudi yang dapat secara otomatis mengidentifikasi kondisi kelelahan pengemudi karena kelelahan adalah penyebab utama kecelakaan dan dapat mengurangi tingkat konsentrasi, memperlambat waktu reaksi, dan meningkatkan risiko kesalahan saat berkendara. (Ritonga & Muhandhis, 2024)

Pengolahan citra dan visi komputer telah sangat dipengaruhi oleh kemajuan teknologi kecerdasan buatan, khususnya deep learning. (Alfinor Diana et al., 2025) Karena kemampuan untuk mengekstraksi informasi visual secara otomatis dan hierarkis, Convolutional Neural Network (CNN) adalah teknik pengenalan wajah yang populer. (Mbaba et al., 2022) Dengan berbagai tingkat efisiensi dan kompleksitas, berbagai arsitektur CNN telah dikembangkan. (Indra et al., n.d.)


Namun, penelitian komparatif yang mengevaluasi berbagai arsitektur CNN dalam klasifikasi kelelahan wajah pengemudi harus dilakukan. Penelitian seperti itu harus menggunakan pendekatan evaluasi yang berfokus pada perilaku pembelajaran dan generalisasi model. Tujuan penelitian ini adalah untuk membandingkan berbagai arsitektur CNN berdasarkan metrik pelatihan dan validasi untuk menentukan model CNN terbaik.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimental dengan melakukan komparasi performansi empat arsitektur CNN populer, yaitu VGG16, ResNet50, MobileNetV2, dan InceptionV3. Proses penelitian dilakukan melalui

beberapa tahapan utama yaitu alur penelitian, persiapan dataset, perancangan model, proses pelatihan, serta evaluasi performansi.

2.1. Alur Penelitian



Gambar 1. Alur Penelitian

Tahap awal penelitian dilakukan dengan mengumpulkan data citra wajah pengemudi dari repositori daring Kaggle. Penggunaan dataset publik telah banyak diterapkan dalam penelitian deteksi kelelahan untuk memastikan replikasi dan validitas penelitian (Oktaviani, 2024).

Dataset kemudian melalui tahap praproses berupa resizing, normalisasi piksel, serta augmentasi data guna meningkatkan keberagaman sampel dan meminimalkan risiko overfitting. Penerapan data augmentation terbukti mampu meningkatkan kemampuan generalisasi model CNN dalam berbagai studi klasifikasi citra (ANHAR & PUTRA, 2023).

Selanjutnya, model CNN dipersiapkan dengan memanfaatkan bobot pretrained ImageNet sebagai transfer learning, pendekatan yang umum digunakan untuk mempercepat konvergensi dan meningkatkan performa pada dataset terbatas (Iswahyudi et al., n.d.). Tahap akhir penelitian berupa evaluasi performa model berdasarkan training accuracy, training loss, validation accuracy, dan validation loss untuk menganalisis perilaku pembelajaran dan generalisasi model. (SISTEM+DETEKSI+KANTUK+REAL-TIME+BERBASIS+CNN+DAN+LANDMARK+WAJAH, n.d.).

2.2. Dataset

Dataset yang digunakan adalah *Driver Drowsiness Detection Dataset* dari Kaggle, terdiri dari ribuan citra wajah pengemudi dalam kondisi lelah dan tidak lelah. Citra memiliki variasi pose, ekspresi wajah, dan kondisi pencahayaan yang berbeda sehingga cocok untuk meningkatkan generalisasi model. Seluruh citra diubah ukurannya menjadi 224×224 piksel serta dinormalisasi menggunakan skala 0–1. Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20.

2.3. Pre-Processing

Tahap praproses bertujuan untuk meningkatkan kualitas citra masukan serta memastikan kesesuaian dengan kebutuhan arsitektur CNN. Teknik augmentasi seperti rotasi acak, horizontal flipping, penyesuaian kecerahan, dan zooming ringan diterapkan untuk mensimulasikan kondisi nyata seperti variasi sudut kamera dan pencahayaan (Hariesugama et al., n.d.). Pendekatan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa augmentasi data efektif dalam meningkatkan robustnes model terhadap variasi lingkungan (Rendra Fajaresta et al., n.d.).

2.4. Arsitektur Model

Model CNN yang diuji meliputi VGG16, ResNet50, MobileNetV2, dan InceptionV3. VGG16 dipilih karena kedalamannya yang terstruktur dan terbukti stabil. ResNet50 digunakan karena memanfaatkan residual connection yang dapat mengurangi masalah vanishing gradient. MobileNetV2 dipilih karena sifatnya yang ringan dengan parameter lebih sedikit sehingga cocok untuk aplikasi real-time. InceptionV3 digunakan karena kemampuannya menangkap fitur multi-skala. Semua model menggunakan pretrained ImageNet sebagai bobot awal dan lapisan akhir dimodifikasi untuk klasifikasi dua kelas.

2.5. Optimizer

Optimizer yang digunakan adalah Adam dengan *learning rate* 0.0001. Adam dipilih karena mampu memberikan konvergensi yang cepat dan stabil. *Batch size* yang digunakan adalah 10 dan *training* dilakukan selama 35 *epoch*. *Early stopping* diterapkan untuk mencegah *overfitting*.

2.6. Evaluasi

Evaluasi performa model dilakukan dengan memantau nilai *training accuracy* dan *training loss* selama proses pelatihan, serta *validation accuracy* dan *validation loss* pada data validasi. Parameter ini digunakan untuk menilai kemampuan model dalam mempelajari data latih serta kemampuan generalisasi terhadap data yang belum pernah dilihat sebelumnya. (Suyuti, n.d.).

3. Hasil dan Diskusi

Hasil evaluasi performa masing-masing arsitektur CNN diperoleh dari proses pelatihan dan validasi model menggunakan dataset citra wajah pengemudi. Evaluasi difokuskan pada nilai *training accuracy*, *training loss*, *validation accuracy*, dan *validation loss* untuk menilai kemampuan pembelajaran model serta tingkat generalisasi terhadap data yang belum pernah dilihat sebelumnya.

Model	Training Accuracy	Training Loss	Validation Accuracy	Validation Loss
VGG16	0.9582	0.1267	0.9303	0.1511
ResNet50	1.0000	0.0359	1.0000	0.0301
MobileNetV2	1.0000	0.0389	1.0000	0.0309
InceptionV3	0.9857	0.0308	0.9573	0.1600

Tabel 1. Hasil Evaluasi Training dan Validation Model CNN

Berdasarkan hasil evaluasi training dan validation, MobileNetV2 dan ResNet50 menunjukkan performa tertinggi dengan nilai akurasi sempurna dan loss yang sangat rendah. Namun, MobileNetV2 dinilai lebih optimal karena mampu mencapai performa tersebut dengan arsitektur yang lebih ringan dan efisien, sehingga lebih sesuai untuk implementasi sistem klasifikasi kelelahan pengemudi secara real-time. Hasil penelitian ini sejalan dengan temuan dari studi literatur yang menunjukkan bahwa model yang lebih dalam dan kompleks cenderung memberikan akurasi lebih tinggi. Namun, model ringan seperti MobileNet lebih cocok untuk perangkat IoT dan aplikasi real-time (Ahmad Fauzan et al., n.d.). Oleh karena itu, pemilihan model harus disesuaikan dengan kebutuhan sistem monitoring pengemudi yang akan dibuat.

3.1. VGG16




Gambar 2. Training & Validation Accuracy

Berdasarkan grafik kinerja yang dihasilkan, model VGG16 menunjukkan peningkatan nilai ketepatan pelatihan yang konsisten sepanjang proses pelatihan; nilai ketepatan validasi kemudian meningkat, dan pada fase akhir, kondisi stabil mencapai nilai antara 93 dan 95 persen. Pola ini menunjukkan kemampuan model untuk mempelajari pola data dengan baik dan memiliki kemampuan generalisasi yang baik tanpa menunjukkan indikasi overfitting yang signifikan.



Gambar 3. Training & Validation Loss

Meskipun kehilangan validasi sedikit berubah pada awal pelatihan, nilai umumnya menunjukkan tren penurunan dan tetap pada nilai rendah sejak pertengahan pelatihan. Ini menunjukkan bahwa model lebih baik dalam mengurangi kesalahan prediksi terhadap data validasi. Mekanisme penundaan dini menghentikan proses pelatihan secara otomatis pada epoch ke-34, sehingga risiko *overfitting* diminimalkan dan efisiensi pelatihan ditingkatkan.



Gambar 4. Hasil Evaluasi Sistem Klasifikasi

Sehubungan dengan pola fitur visual yang diekstraksi, gambar yang dianalisis dikategorikan oleh model sebagai representasi dari kondisi individu yang mengalami rasa kantuk (*drowsy*) berdasarkan hasil evaluasi sistem klasifikasi.

3.2. ResNet50



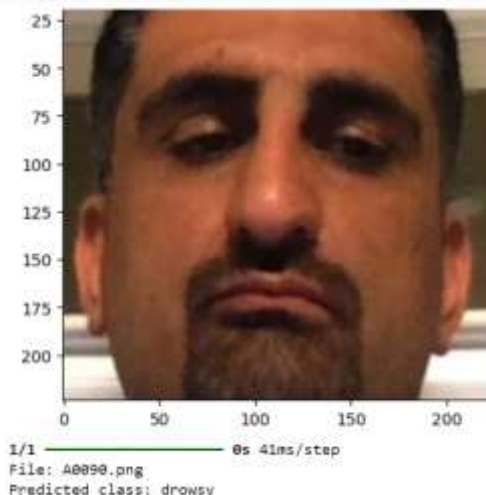
Gambar 5. Training & Validation Accuracy

Model Resnet50 menunjukkan tren peningkatan akurasi pelatihan yang stabil selama proses pembelajaran, seperti yang ditunjukkan oleh visualisasi grafik performa pelatihan. Akurat validasi meningkat secara bertahap sejalan dengan akurasi pelatihan dan cenderung berada pada kondisi stabil pada fase akhir pelatihan. Ini meningkat dari kisaran awal sekitar 45–50% hingga mencapai nilai tinggi pada rentang 93–95% selama lebih dari dua puluh *epoch*. Koneksi kedua metrik menunjukkan bahwa model dapat mempelajari representasi fitur dengan baik dan memiliki kemampuan generalisasi yang baik tanpa menunjukkan gejala *overfitting* yang signifikan.



Gambar 6. Training & Validation Loss

Nilai kehilangan validasi, di sisi lain, sempat berubah sedikit pada awal kursus, tetapi secara keseluruhan menunjukkan kecenderungan menurun dan stabil pada nilai yang relatif rendah sejak pertengahan periode. Tren ini menunjukkan kemampuan model yang lebih baik dalam mengurangi kesalahan prediksi terhadap data validasi seiring bertambahnya iterasi pelatihan. Selain itu, penurunan terus menerus dari nilai awal yang tinggi menuju nilai yang lebih kecil menunjukkan bahwa proses optimisasi berjalan dengan baik dan bahwa model menyesuaikan bobot jaringan dengan benar.



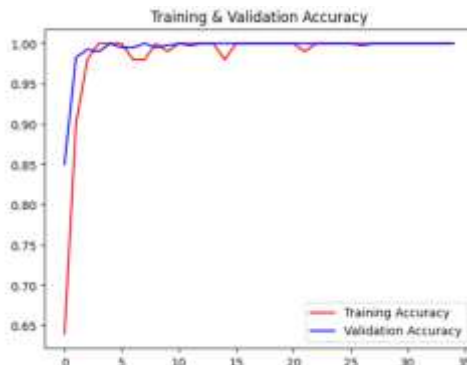
Gambar 7. Hasil Evaluasi Sistem Klasifikasi

DOI: <https://doi.org/10.31004/riggs.v4i4.6937>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Berdasarkan hasil evaluasi sistem klasifikasi, citra yang dianalisis dikategorikan oleh model sebagai representasi dari kondisi individu yang mengalami rasa kantuk (*drowsy*), sesuai dengan pola fitur visual yang diekstraksi.

3.3. MobileNetV2



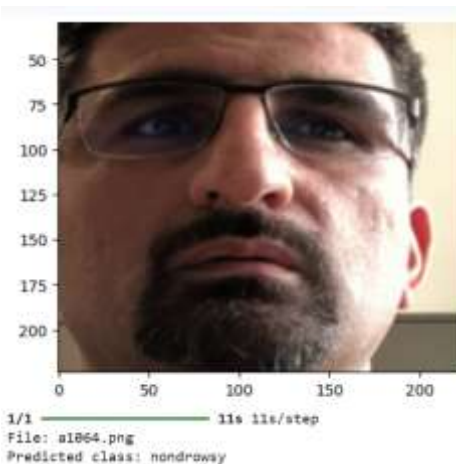
Gambar 8. Training & Validation Accuracy

Pada grafik yang ditampilkan, kinerja model terbaik ditemukan melalui analisis metrik akurasi dan kehilangan nilai selama proses pembelajaran. Akurasi pelatihan meningkat secara bertahap pada setiap *epoch*, menunjukkan kemampuan model untuk menyesuaikan bobot terhadap data pelatihan. Sementara itu, akurasi validasi menunjukkan stabilitas yang tinggi, berada di kisaran yang hampir maksimal dari epoch tengah hingga akhir pelatihan, menunjukkan bahwa model mampu melakukan generalisasi tanpa kecenderungan untuk *overfitting*.



Gambar 9. Training & Validation Loss

Nilai *loss* pada data validasi sempat mengalami fluktuasi ringan pada awal pelatihan, namun selanjutnya menunjukkan tren penurunan yang konsisten dan tetap rendah sejak pertengahan periode pelatihan. Kondisi ini menunjukkan bahwa meskipun terdapat variabilitas awal, model secara bertahap mampu meminimalkan kesalahan prediksi secara efektif pada data yang tidak termasuk dalam pelatihan.



Gambar 10. Hasil Evaluasi Sistem Klasifikasi


Berdasarkan hasil evaluasi sistem klasifikasi, gambar yang dianalisis dikategorikan oleh model sebagai representasi dari kondisi individu yang tidak kantuk (*non drowsy*), sesuai dengan pola fitur visual yang diekstraksi.

3.4. InceptionV3



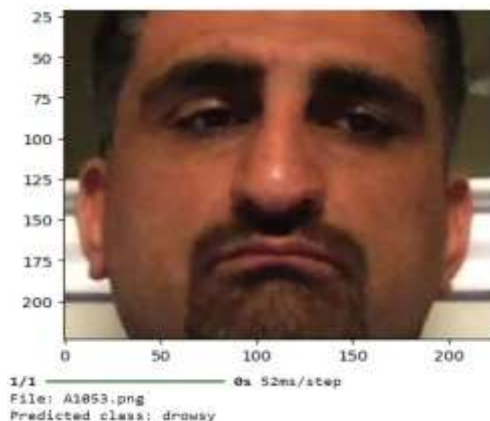
Gambar 11. Training & Validation Accuracy

Untuk menilai kinerja model terbaik pada percobaan ke-7, metrik akurasi dan nilai kehilangan yang dibuat selama proses pelatihan digunakan. Terlihat bahwa akurasi data pelatihan meningkat secara bertahap dan konsisten pada setiap epoch, menunjukkan bahwa model semakin mampu mengenali pola data. Sementara itu, akurasi validasi juga sangat stabil, dengan nilai sekitar 0,95 setelah epoch ke-20, menunjukkan kemampuan model untuk menggeneralisasi tanpa menunjukkan tanda-tanda overfitting yang signifikan.



Gambar 12. Training & Validation Loss

Nilai kehilangan data validasi kadang-kadang berubah-ubah di awal pelatihan, tetapi nilainya cenderung stabil dari pertengahan hingga akhir pelatihan. Kondisi ini menunjukkan bahwa model tidak hanya meningkatkan akurasi tetapi juga berhasil mengurangi kesalahan prediksi pada data yang tidak dimasukkan dalam proses pembelajaran langsung. Mekanisme Early Stopping secara otomatis menghentikan pelatihan pada epoch ke-34, dan epoch ke-24 adalah epoch terbaik. Dengan menggunakan teknik penghentian dini ini, overfitting dicegah dan efisiensi komputasi ditingkatkan tanpa mengorbankan kualitas model.



Gambar 13. Hasil Evaluasi Sistem Klasifikasi

Berdasarkan hasil evaluasi sistem klasifikasi, gambar yang dianalisis dikategorikan oleh model sebagai representasi dari kondisi individu yang tidak kantuk (*non drowsy*), sesuai dengan pola fitur visual yang diekstraksi.

4. Kesimpulan

Penelitian ini menyajikan analisis komparatif kinerja empat arsitektur Convolutional Neural Network (CNN), yaitu VGG16, ResNet50, MobileNetV2, dan InceptionV3, dalam sistem klasifikasi kelelahan wajah pengemudi menggunakan dataset berjumlah 2.000 citra wajah yang dilatih selama 35 epoch. Berdasarkan hasil evaluasi, VGG16 memperoleh training accuracy sebesar 95,82% dengan training loss 0,1267, serta validation accuracy 93,03% dan validation loss 0,1511, yang menunjukkan kemampuan pembelajaran dan generalisasi yang cukup baik pada jumlah epoch yang ditetapkan. InceptionV3 mencapai training accuracy 98,57% dan validation accuracy 95,73%, namun disertai validation loss yang relatif lebih tinggi, yaitu sekitar 0,16, mengindikasikan stabilitas generalisasi yang lebih rendah meskipun dilatih hingga akhir epoch. Performa terbaik ditunjukkan oleh ResNet50 dan MobileNetV2, dengan akurasi pelatihan dan validasi masing-masing mencapai 100%, dan nilai kehilangan pelatihan dan validasi yang sangat rendah, masing-masing 0,0359 dan 0,0301 untuk ResNet50 dan 0,0389 dan 0,0309 untuk MobileNetV2. Hasil menunjukkan bahwa kedua arsitektur dapat memanfaatkan data dengan baik dalam batas 35 epoch tanpa overfitting. Meskipun keduanya memiliki akurasi yang sama, MobileNetV2 sebenarnya lebih baik karena mampu mencapai kinerja yang sebanding dengan kompleksitas arsitektur yang lebih rendah dan efisiensi komputasi yang lebih baik. Oleh karena itu, MobileNetV2 lebih cocok untuk penggunaan sistem deteksi kelelahan pengemudi berbasis real-time, terutama pada perangkat yang memiliki sumber daya terbatas. Hasil menunjukkan bahwa arsitektur CNN harus dipertimbangkan selain tingkat akurasi, efisiensi pelatihan, dan kebutuhan implementasi sistem.

Referensi

1. Ahmad Fauzan, H., Kurniawan, A., Informatika, M., Vokasi, F., Negeri Surabaya Jl Lidah Wetan, U., Wetan, L., Lakarsantri, K., & Timur, J. (n.d.). *Aplikasi Warning Alert Pendeteksi Kelelahan Ekspresi Wajah Pada Pengemudi Secara Real-Time Menggunakan Metode You Only Look Once Berbasis Website*.
2. Alfinor Diana, D., Martyan Anggadimas, N., & Ahkam Sani, D. (2025). PENERAPAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI EMOSI WAJAH PEKERJA. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 9, Number 5). https://universe.roboflow.com/chocking/choking_face
3. ANHAR, A., & PUTRA, R. A. (2023). Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(2), 466. <https://doi.org/10.26760/elkomika.v11i2.466>
4. Hariesugama, F., Bimantoro, F., & Satya Nugraha, G. (n.d.). *Pengenalan Wajah dan Deteksi Kantuk Menggunakan Metode Haar Cascade dan Convolutional Neural Network Method*.
5. Hatta Fudholi, D., Abida Nayoan, R. N., Suyuti, M., & Rahmadi, R. (2021). Deteksi Indikasi Kelelahan Menggunakan Deep Learning. In *Jurnal Sains Komputer & Informatika (J-SAKTI)* (Vol. 5, Number 1).
6. Indra, G., Hamida Saputri, H., & Aulia Aziza, N. (n.d.). Penerapan MobileNet untuk Klasifikasi Kondisi Wajah Mengantuk pada Citra Wajah. *JUNI 2025 Journal of Informatics and Communications Technology*, 7(1), 189–197. <https://doi.org/10.52661>
7. Iswahyudi, R., Fauzi Ikhsan, A., Muhamad, I., & Matin, M. (n.d.). *Fuse-teknik Elektro DETEKSI KANTUK MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) BERDASARKAN KEDIPAN MATA*.
8. Mbaba, P., Anwar, K., Rahayu, S., Eka Kartawati, A., Studi Informatika, P., & Matematika dan Ilmu Pengetahuan Alam Universitas Udayana Bali, F. (2022). PENERAPAN METODE CONVOLUTIONAL NEURAL NETWORKS UNTUK MENGIDENTIFIKASI WAJAH KELELAHAN. In *JNATIA* (Vol. 1, Number 1). <https://www.kaggle.com/datasets/davidvazquezcic/yawn-dataset>
9. Oktaviani, F. (2024). PERANCANGAN GUIDEBOOK PEMILIHAN WARNA PAKAIAN BERDASARKAN SKIN TONE MENGGUNAKAN SEASONAL COLOR THEORY. In *Jurnal Barik* (Vol. 5, Number 2). <https://ejournal.unesa.ac.id/index.php/JDKV/>
10. Rendra Fajaresta, A., Dijaya, R., Findawati, Y., & Intan Mauliana, M. (n.d.). *Detection of Facial Fatigue in High-Risk Workers Using YOLOV4 [Deteksi Kelelahan Wajah Pada Pekerja Beresiko Tinggi Menggunakan YOLOV4]*.
11. Ritonga, A. S., & Muhandhis, I. (2024). Analisis dan Implementasi Metode Viola-Jones dan CNN pada Sistem Deteksi Kantuk Real-Time. *Jurnal Ilmiah IT CIDA : Diseminasi Teknologi Informasi*, 10(2).
12. Suyuti, M. (n.d.). *Lembar Pengesahan Pembimbing Pengembangan Model Klasifikasi Mata Tertutup dan Terbuka Dalam Identifikasi Kelelahan Menggunakan Arsitektur Mobile CNN*.
13. Wu, Z., Shen, C., & Hengel, A. (2016). *Wider or Deeper: Revisiting the ResNet Model for Visual Recognition*. *Pattern Recognition*, 90. <https://doi.org/10.1016/j.patcog.2019.01.006>
14. M. A. N. Hidayat, "Convolutional Neural Network Pada Identifikasi Varian Tanaman Anggur Menggunakan Resnet-50," vol. 10, no. 3, 2023.
15. T. Berliani, E. Rahardja, dan L. Septiana, "Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16," *J. Med. Health*, vol. 5, no. 2, hlm. 123–135, Agu 2023, doi: 10.28932/jmh.v5i2.6116.