

DETEKSI KELELAHAN PENGEMUDI BERDASARKAN EKSPRESI WAJAH EAR DAN MAR MENGGUNAKAN 1DCNN-LSTM PADA DATASET NITYMED

Eneng Nuraeni, Sunardi, Abdul Fadlil

Magister Teknik Elektro, Universitas Ahmad Dahlan

Ringroad Selatan, Tamanan, Banguntapan, Bantul, Daerah Istimewa Yogyakarta, 55166

2307057004@webmail.uad.ac.id

ABSTRAK

Kecelakaan lalu lintas akibat kelelahan pengemudi masih menjadi masalah serius di berbagai negara, termasuk Indonesia. Deteksi dini kelelahan penting untuk mencegah terjadinya kecelakaan fatal. Penelitian ini mengembangkan sistem deteksi kelelahan pengemudi berbasis citra wajah dengan memanfaatkan dua parameter utama, yaitu *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR). Model yang digunakan adalah arsitektur hibrid *1-Dimensional Convolutional Neural Network* (1DCNN) dan *Long Short-Term Memory* (LSTM). Dataset yang digunakan adalah NITYMED, yang terdiri dari 126 video pengemudi dengan total 63.748 citra. Proses penelitian meliputi pra-pemrosesan, ekstraksi fitur, pelabelan, pelatihan, dan pengujian model. Hasil menunjukkan bahwa kombinasi fitur EAR dan MAR menghasilkan akurasi tertinggi sebesar 96,8%, dengan presisi 97,1%, *recall* 96,5%, dan *F1-score* 96,8%. Temuan ini menunjukkan bahwa penggunaan gabungan fitur mata dan mulut mampu meningkatkan akurasi deteksi kelelahan dibandingkan penggunaan satu fitur saja. Hasil ini berpotensi diimplementasikan dalam sistem peringatan dini kendaraan untuk meningkatkan keselamatan berkendara.

Kata kunci : kelelahan pengemudi, EAR, MAR, 1DCNN, LSTM

1. PENDAHULUAN

Kecelakaan lalu lintas merupakan salah satu penyebab utama kematian di dunia dan menjadi masalah global yang memerlukan perhatian serius dari berbagai pihak. Organisasi Kesehatan Dunia atau *World Health Organization* (WHO) melaporkan bahwa setiap tahun sekitar 1,35 juta orang meninggal akibat kecelakaan lalu lintas, sementara puluhan juta lainnya mengalami luka-luka yang dapat menyebabkan kecacatan jangka panjang [1]. Selain faktor teknis seperti kondisi kendaraan dan infrastruktur jalan, faktor manusia merupakan penyebab dominan dari terjadinya kecelakaan. Salah satu faktor manusia yang memiliki kontribusi besar adalah kelelahan pengemudi atau *driver fatigue* [2]. Kelelahan ini tidak hanya mengurangi kewaspadaan pengemudi, tetapi juga memperlambat waktu reaksi, mengganggu koordinasi, dan menurunkan kemampuan pengambilan keputusan yang tepat. Kondisi tersebut sangat berbahaya karena dapat terjadi secara tiba-tiba, terutama pada perjalanan jarak jauh atau ketika ritme sirkadian tubuh berada pada fase kantuk, seperti pada malam hari atau dini hari [3].

Di Indonesia, masalah kelelahan pengemudi juga menjadi perhatian serius. Berdasarkan data Badan Pusat Statistik (BPS) dalam Statistik Transportasi Darat 2023, selama periode 2019–2021 tercatat sebanyak 320.084 kasus kecelakaan lalu lintas dengan 74.466 korban meninggal dunia [4]. Angka tersebut mengindikasikan bahwa rata-rata setiap tahun terdapat lebih dari 24 ribu korban meninggal akibat kecelakaan lalu lintas. Faktor kelelahan pengemudi, khususnya pada sektor transportasi umum, logistik, dan perjalanan jarak jauh, berkontribusi signifikan terhadap angka ini. Kondisi ini menunjukkan bahwa deteksi dini kelelahan pengemudi merupakan langkah

penting yang tidak dapat diabaikan dalam upaya pencegahan kecelakaan lalu lintas yang fatal [5].

Metode deteksi kelelahan secara umum terbagi menjadi dua pendekatan, yaitu subjektif dan objektif [6]. Pendekatan subjektif mengandalkan pelaporan diri pengemudi mengenai tingkat kelelahan yang dirasakan, misalnya melalui pengisian kuesioner atau penggunaan *self-report scale* seperti *Karolinska Sleepiness Scale* (KSS) atau *Stanford Sleepiness Scale* (SSS). Walaupun relatif mudah diterapkan, pendekatan ini memiliki kelemahan mendasar karena sangat bergantung pada kesadaran dan kejujuran pengemudi serta tidak praktis digunakan dalam situasi berkendara [7]. Sebaliknya, pendekatan objektif memanfaatkan data yang dapat diukur secara langsung, sehingga lebih dapat diandalkan. Pendekatan objektif ini dapat dibagi menjadi tiga kategori, yaitu berbasis fisiologis, berbasis kendaraan, dan berbasis perilaku [8].

Pendekatan berbasis fisiologis biasanya menggunakan sinyal biologis seperti *elektroensefalogram* (EEG), *elektrookulogram* (EOG), atau detak jantung untuk mendeteksi tanda-tanda kelelahan [9]. Metode ini memiliki tingkat akurasi tinggi, namun bersifat invasif dan memerlukan perangkat khusus yang tidak nyaman digunakan dalam jangka waktu lama. Pendekatan berbasis kendaraan memantau perilaku kendaraan seperti pergerakan setir, kecepatan, atau posisi kendaraan di jalur [10]. Meskipun non-invasif, metode ini rentan terhadap kesalahan deteksi karena perilaku kendaraan juga dapat dipengaruhi oleh faktor lain seperti kondisi jalan atau cuaca. Sementara itu, pendekatan berbasis perilaku memanfaatkan pengamatan terhadap perubahan perilaku pengemudi, khususnya melalui analisis citra wajah atau gerakan tubuh, dan menjadi

semakin populer karena non-invasif, relatif murah, dan dapat berjalan secara *real-time* [11].

Pendekatan perilaku berbasis citra wajah memiliki potensi besar dalam deteksi kelelahan karena dapat mengamati tanda-tanda visual yang jelas, seperti mata yang tertutup lebih lama dari biasanya atau mulut yang terbuka lebar saat menguap [12]. Dua parameter yang banyak digunakan dalam metode ini adalah *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR). EAR digunakan untuk mengukur rasio pembukaan mata dengan memanfaatkan koordinat titik fitur mata yang diperoleh melalui *facial landmark detection*. Penurunan nilai EAR secara konsisten menunjukkan indikasi mata tertutup atau terjadinya *microsleep* [13]. Sementara itu, MAR digunakan untuk mengukur rasio pembukaan mulut, yang dapat mengindikasikan aktivitas menguap sebagai tanda awal mengantuk [14]. Penggunaan EAR dan MAR secara bersamaan dapat meningkatkan akurasi deteksi karena kedua indikator ini saling melengkapi; EAR mendeteksi gejala mengantuk yang berhubungan dengan mata, sedangkan MAR mendeteksi tanda menguap yang berhubungan dengan mulut [15].

Kemajuan teknologi *deep learning* dalam beberapa tahun terakhir telah memberikan peningkatan signifikan terhadap akurasi sistem deteksi kelelahan berbasis citra wajah. Model *Convolutional Neural Network* (CNN) dikenal efektif dalam mengekstraksi fitur spasial dari citra, sedangkan *Long Short-Term Memory* (LSTM) unggul dalam menangkap pola temporal dari urutan frame video [16]. Kombinasi CNN dan LSTM memungkinkan sistem memahami tidak hanya bentuk fitur wajah pada satu *frame*, tetapi juga perubahan pola tersebut dari waktu ke waktu. Hal ini relevan untuk mendeteksi kelelahan karena perubahan seperti penurunan EAR atau peningkatan MAR cenderung terjadi secara bertahap [17].

Penelitian ini menggunakan arsitektur *1-Dimensional Convolutional Neural Network* (1DCNN) yang dipadukan dengan LSTM. Pemilihan 1DCNN didasarkan pada kemampuannya memproses data deret waktu yang dihasilkan dari pengukuran EAR dan MAR secara efisien, sementara LSTM digunakan untuk mempelajari hubungan temporal antar *frame* sehingga pola kelelahan dapat dikenali dengan lebih baik [18]. *Dataset* yang digunakan adalah NITYMED, sebuah *dataset* yang secara khusus dirancang untuk mendukung penelitian deteksi kelelahan pengemudi. *Dataset* ini terdiri dari rekaman video pengemudi dalam berbagai kondisi pencahayaan dan aktivitas, lengkap dengan anotasi untuk pelabelan kondisi “lelah” atau “normal” [19]. NITYMED dipilih karena memiliki variasi yang luas dalam representasi ekspresi wajah, durasi menguap, dan pola berkedip, sehingga ideal untuk melatih model berbasis kombinasi fitur EAR dan MAR.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi kelelahan berbasis fitur EAR dan MAR menggunakan

model 1DCNN-LSTM, mengevaluasi performa sistem pada dataset NITYMED, serta menganalisis kontribusi masing-masing fitur terhadap akurasi sistem. Kontribusi penelitian ini meliputi pengembangan model deteksi kelelahan yang memanfaatkan kombinasi dua fitur wajah utama dengan pendekatan *deep learning* berbasis pemrosesan spasial dan temporal, memberikan analisis komparatif antara penggunaan fitur tunggal dan gabungan, serta menawarkan potensi implementasi sistem ini dalam fitur keselamatan kendaraan modern untuk mengurangi risiko kecelakaan akibat kelelahan pengemudi. Dengan pendekatan ini, penelitian diharapkan dapat menghasilkan solusi deteksi kelelahan yang efektif, efisien, dan praktis, serta dapat diimplementasikan secara *real-time* untuk meningkatkan keselamatan berkendara di Indonesia maupun di tingkat global.

2. TINJAUAN PUSTAKA

2.1. Kelelahan Pengemudi dan Dampaknya terhadap Keselamatan

Kelelahan pengemudi (*driver fatigue*) merupakan kondisi fisiologis dan mental yang ditandai oleh penurunan kewaspadaan, berkurangnya respons terhadap rangsangan, dan menurunnya koordinasi motorik [1]. Kondisi ini sering disebabkan oleh kurang tidur, perjalanan jarak jauh, pekerjaan bergilir, atau monotonnya aktivitas berkendara. Efek kelelahan terhadap pengemudi sangat mirip dengan efek konsumsi alkohol dalam jumlah berlebih, yang ditandai dengan menurunnya waktu reaksi, terganggunya konsentrasi, dan menurunnya kualitas pengambilan keputusan [2].

Menurut WHO, sekitar 20–30% kecelakaan lalu lintas di dunia dikaitkan langsung dengan kelelahan pengemudi [20]. Di Indonesia, faktor ini menjadi penyebab penting kecelakaan pada kendaraan angkutan barang dan penumpang, terutama di jalur antar provinsi [4]. Oleh karena itu, deteksi dini kelelahan pengemudi menjadi fokus utama dalam peningkatan keselamatan lalu lintas.

2.2. Metode Deteksi Kelelahan

Deteksi kelelahan dapat dikategorikan menjadi dua pendekatan utama, yaitu subjektif dan objektif [5]. Pendekatan subjektif mengandalkan pelaporan diri (*self-report*) menggunakan instrumen seperti *Karolinska Sleepiness Scale* (KSS) atau *Stanford Sleepiness Scale* (SSS) [6]. Pendekatan ini mudah diterapkan namun tidak praktis dalam kondisi berkendara dan rawan bias pelaporan.

Pendekatan objektif memanfaatkan data yang dapat diukur secara langsung, terbagi menjadi tiga subkategori:

- a. Berbasis fisiologis, yaitu menggunakan sinyal seperti EEG, EOG, atau detak jantung [7]. Akurat, tetapi invasif dan tidak nyaman digunakan lama.

- b. Berbasis kendaraan, yaitu memantau perilaku kendaraan seperti pergerakan setir, kecepatan, dan posisi jalur [8]. Non-invasif, tetapi sensitif terhadap faktor eksternal.
- c. Berbasis perilaku, yaitu memantau citra wajah atau gerakan tubuh pengemudi [11]. Non-invasif, murah, dan dapat bekerja secara *real-time*.

2.3. Parameter Visual dalam Deteksi Kelelahan

Deteksi kelelahan secara visual mengandalkan analisis perubahan fisiologis wajah dan kepala subjek. Dua parameter visual yang paling umum dan sering digunakan adalah *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR). Penggunaan kedua parameter ini bertujuan untuk secara efektif memantau indikasi kantuk dan kelelahan secara *real-time* pada subjek.

EAR berfungsi sebagai pengukur tingkat keterbukaan mata yang dihitung dari jarak vertikal dan horizontal titik fitur mata (*facial landmarks*) [12]. Penurunan nilai EAR secara konsisten di bawah suatu ambang batas merupakan indikasi yang jelas bahwa mata sedang tertutup atau terjadi *microsleep* [13]. Metrik ini menjadi salah satu indikator primer dan sangat penting dalam sistem identifikasi dini kondisi kantuk.

Sementara ini, MAR adalah parameter visual yang mengukur keterbukaan mulut, didasarkan pada perhitungan jarak antara bibir atas dan bawah. Peningkatan nilai MAR yang signifikan dan berlangsung dalam durasi tertentu biasanya menandakan adanya aktivitas menguap [14]. Aktivitas menguap, terutama bila dikombinasikan dengan penurunan nilai EAR, merupakan indikator kantuk yang kuat [15]. Penggunaan kedua parameter ini terbukti mampu meningkatkan akurasi deteksi secara keseluruhan [21].

2.4. Teknologi Deep Learning untuk Deteksi Kelelahan

Kemajuan signifikan dalam *deep learning* telah merevolusi sistem deteksi kelelahan, terutama melalui penggunaan arsitektur *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM). CNN secara spesifik dirancang untuk mengenali pola spasial yang kompleks dari data citra, menjadikannya ideal untuk analisis ekspresi dan pengenalan wajah [16]. Sementara itu, LSTM merupakan jenis *Recurrent Neural Network* (RNN) yang memiliki kemampuan untuk mengingat informasi dalam jangka panjang dan mempelajari pola temporal [22]. Kombinasi dari CNN dan LSTM menggabungkan keunggulan analisis spasial dan temporal, sehingga sangat cocok untuk mendeteksi perubahan bertahap pada EAR dan MAR yang terjadi seiring waktu [17].

Selain arsitektur utama tersebut, *One-Dimensional CNN* (1DCNN) merupakan varian khusus dari CNN yang diaplikasikan untuk

memproses data deret waktu (*time-series*). 1DCNN bekerja dengan memproses urutan nilai numerik, seperti deret waktu dari nilai EAR dan MAR [18]. Keunggulan utamanya adalah efisiensi komputasi yang tinggi dalam mengolah data numerik ini dibandingkan harus memproses citra mentah secara langsung.

Untuk melatih model *deep learning* ini, dibutuhkan *dataset* yang komprehensif, salah satunya adalah *Dataset NITYMED* (NI-TYME Drowsiness Dataset). *Dataset* ini terdiri dari 126 video pengemudi yang diambil dalam berbagai kondisi pencahayaan dan sudut kamera, serta telah dianotasi dengan label "lelah" dan "normal" [19]. Variasi kegiatan pengemudi, seperti menguap, berkedip, dan menoleh dalam *dataset* tersebut, menjadikannya sumber daya yang ideal untuk melatih dan menguji model deteksi kelelahan yang berbasis pada parameter EAR dan MAR [23].

2.5. Penelitian Terdahulu

Petrellis *et al.* [19] melatih model *Ensemble of Regression Trees* (ERT) pada NITYMED untuk mendeteksi menguap dan memperoleh sensitivitas 93%. Civik dan Yuzgec [23] mengembangkan sistem CNN berbasis fitur mata dan mulut dengan akurasi 96%. Gupta *et al.* [24] membuktikan bahwa kombinasi EAR dan MAR lebih akurat dibanding penggunaan tunggal. Namun, penelitian khusus penggunaan 1DCNN-LSTM pada NITYMED masih jarang ditemukan.

3. METODE PENELITIAN


3.1. Gambaran Umum Metode

Penelitian ini mengembangkan sistem deteksi kelelahan pengemudi berbasis dua parameter visual, yaitu *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR), dengan memanfaatkan arsitektur *1-Dimensional Convolutional Neural Network* (1DCNN) yang dipadukan dengan *Long Short-Term Memory* (LSTM). EAR dan MAR dipilih karena keduanya dapat memberikan indikasi yang jelas terkait tanda-tanda mengantuk, seperti penurunan pembukaan mata (*eye closure*) dan peningkatan pembukaan mulut akibat menguap [12], [14].

Alur penelitian ini dibagi menjadi lima tahap utama:

- a. Pengumpulan dan Pemilihan *Dataset* NITYMED
- b. Pra-pemrosesan Data
- c. Ekstraksi Fitur EAR dan MAR
- d. Perancangan dan Pelatihan Model 1DCNN-LSTM
- e. Evaluasi Model

Gambaran umum alur sistem ditunjukkan pada Gambar 1.



Gambar 1. Diagram alur sistem deteksi kelelahan pengemudi berbasis EAR dan MAR

3.2. Dataset NITYMED

Dataset NITYMED merupakan kumpulan video pengemudi yang direkam dalam berbagai kondisi pencahayaan dan sudut kamera. *Dataset* ini memiliki anotasi yang menandai kondisi pengemudi sebagai “lelah” atau “normal” berdasarkan observasi perilaku seperti frekuensi berkedip dan aktivitas menguap [19]. Tabel 1 menampilkan deskripsi *dataset NITYMED* yang digunakan pada penelitian ini. Sebelum digunakan, setiap video dikonversi menjadi *frame* citra dengan resolusi yang disesuaikan, kemudian dilakukan proses deteksi wajah untuk memastikan area analisis hanya pada wajah pengemudi.

Tabel 1. Deskripsi *Dataset NITYMED*

Kategori	Jumlah Video	Jumlah Frame	Kondisi
Normal	63	31.500	Siang/Malam
Lelah	63	32.248	Siang/Malam
Total	126	63.748	

3.3. Pra-Pemrosesan Data

Dalam penelitian ini, *Preprocessing* digunakan untuk mengolah data foto agar menjadi data yang rapi dan mudah diproses oleh sistem, yaitu dengan mengubahnya ke dalam bentuk file CSV dan memberi label 0 dan 1; dari total 44.107 data pada *DataNity.csv*, sebanyak 25% digunakan sebagai data pengujian, sedangkan 75% sisanya digunakan sebagai data pelatihan. Tahapan pra-pemrosesan meliputi:

- Konversi Video ke *Frame*: Setiap video dipecah menjadi *frame* dengan *frame rate* tertentu (misalnya 30 fps) untuk memperoleh urutan citra.
- Deteksi Wajah: Algoritma *Histogram of Oriented Gradients* (HOG) atau *Multi-task*

Cascaded Convolutional Networks (MTCNN) digunakan untuk mendeteksi area wajah [25].

- Ekstraksi *Facial Landmarks*: *Dlib's facial landmark detector* dengan model 68-point shape predictor digunakan untuk memperoleh koordinat titik mata dan mulut [26].

3.4. Ekstraksi Fitur EAR dan MAR

EAR dan MAR adalah parameter kunci yang diekstraksi menggunakan koordinat titik *facial landmarks* pada mata dan mulut. EAR, yang berfungsi untuk mendeteksi penurunan pembukaan mata (indikasi mengantuk), dihitung menggunakan rumus [13],

$$EAR = \frac{||p_2 - p_6|| + ||p_3 - p_5||}{2 * ||p_1 - p_4||}$$

dimana p adalah koordinat titik mata sesuai *facial landmarks*. Bagian pembilang untuk mengukur jarak vertikal dan penyebut mengukur jarak horizontal antara titik-titik mata.

Sementara itu, MAR digunakan untuk mendeteksi peningkatan pembukaan mulut (indikasi menguap) dengan rumus [15],

$$MAR = \frac{||p_{\{51\}} - p_{\{59\}}|| + ||p_{\{53\}} - p_{\{57\}}|| + ||p_{\{49\}} - p_{\{55\}}||}{3 * ||p_{\{49\}} - p_{\{55\}}||}$$

dimana p adalah koordinat sudut bibir dan bibir atas/bawah. yang membandingkan jarak vertikal bibir dengan jarak horizontal antara sudut bibir. EAR digunakan untuk mendeteksi penurunan pembukaan mata (indikasi mengantuk), sedangkan MAR digunakan untuk mendeteksi peningkatan pembukaan mulut (indikasi menguap).

3.5. Pembentukan Urutan Data


Nilai EAR dan MAR dari setiap *frame* disusun menjadi deret waktu (*time-series*) yang mencakup beberapa detik per sampel. Panjang urutan (*sequence length*) diatur, misalnya 30 *frame*, sehingga setiap input ke model berisi data EAR dan MAR selama 1 detik [17].

3.6. Arsitektur Model 1DCNN-LSTM

Pemilihan 1DCNN-LSTM dilakukan untuk memanfaatkan keunggulan 1DCNN dalam mengekstraksi pola spasial dari data deret waktu dan serta kemampuan LSTM dalam menangkap hubungan temporal jangka panjang [16], [22]. Gambar 2 memperlihatkan struktur arsitektur model.

3.7. Pelatihan Model

Pelatihan dilakukan dengan optimizier Adam, *learning rate* awal 0,001, dan fungsi kehilangan *categorical cross-entropy*. *Dataset* dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian menggunakan *stratified split* untuk menjaga proporsi kelas [27].



Gambar 2. Arsitektur Model 1DCNN-LSTM untuk Deteksi Kelelahan

3.8. Evaluasi Model

Kinerja model diukur dengan metrik dari rumus Evaluasi Klasifikasi

- a. Akurasi (Accuracy)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

- b. Presisi (Precision)

$$Precision = \frac{TP}{TP+FN}$$

- c. Recall

$$Recall = \frac{TP}{TP+FN}$$

- d. F1-score

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Keterangan: TP = True Positive, TN = True Negative, FP = False Positive, FN = False Negative.

3.9. Perangkat dan Lingkungan Pengujian

Eksperimen dilakukan pada perangkat dengan spesifikasi:

- CPU: Intel Core i7-12700H
- GPU: NVIDIA RTX 3060 (6GB)
- RAM: 16 GB DDR4
- OS: Ubuntu 22.04 LTS
- Bahasa Pemrograman: Python 3.10
- Library: TensorFlow, Keras, OpenCV, Dlib.

4. HASIL DAN PEMBAHASAN

Penelitian ini mengevaluasi performa sistem deteksi kelelahan pengemudi berbasis fitur *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR) menggunakan arsitektur *1-Dimensional Convolutional Neural Network* (1DCNN) yang dipadukan dengan *Long Short-Term Memory* (LSTM). Pengujian dilakukan pada dataset NITYMED, yang terdiri dari rekaman video pengemudi dengan kondisi “lelah” dan “normal” dalam berbagai variasi pencahayaan dan posisi kepala. Hasil pengujian ditunjukkan pada Tabel 2.

Tabel 2. Hasil Evaluasi Model pada Dataset NITYMED

Kategori	Akurasi %	Presisi %	Recall %	F1-Score %
EAR	94,2	94,5	93,8	94,1
Maret	95,1	95,3	94,7	95,0
EAR+Maret	96,8	97,1	96,5	96,8

4.1. Analisis Kinerja Berdasarkan Fitur Tunggal

Penggunaan fitur EAR secara tunggal menghasilkan akurasi 94,2%. Nilai ini sudah cukup tinggi, mengingat EAR secara langsung merepresentasikan tingkat pembukaan mata, yang merupakan indikator utama tanda kantuk atau *microsleep* [12]. EAR efektif dalam mengidentifikasi periode mata tertutup lebih lama dari biasanya (*prolonged eye closure*), yang umumnya terjadi sebelum pengemudi memasuki fase kantuk berat.

Sementara itu, fitur MAR tunggal memberikan akurasi sedikit lebih tinggi, yaitu 95,1%. MAR memiliki keunggulan dalam mendeteksi aktivitas menguap, yang sering menjadi tanda awal menurunnya kewaspadaan [14]. Menguap biasanya terjadi sebelum penutupan mata yang berkepanjangan, sehingga MAR mampu memberikan deteksi dini terhadap indikasi kelelahan. Keunggulan MAR ini konsisten dengan penelitian Omidyeganeh *et al.* and Fan *et al.* [14] [15] yang menunjukkan bahwa analisis pembukaan mulut secara *real-time* dapat menjadi indikator efektif untuk deteksi kantuk pada pengemudi.

4.2. Analisis Kinerja Kombinasi Fitur

Kombinasi fitur EAR dan MAR menghasilkan performa deteksi kelelahan yang optimal, dengan mencapai akurasi 96,8%, presisi 97,1%, *recall* 96,5%, dan *F1-score* 96,8%. Hasil yang unggul ini menunjukkan peningkatan kinerja sebesar 2,6% dibandingkan hanya menggunakan EAR tunggal dan 1,7% dibandingkan MAR tunggal. Peningkatan signifikan ini disebabkan oleh sifat komplementer kedua fitur, dimana EAR secara spesifik mendeteksi perubahan pada mata (seperti kedipan lambat dan penutupan mata), sedangkan MAR fokus mendeteksi perubahan pada mulut (seperti aktivitas menguap).

Dengan memproses kedua indikator ini secara simultan, sistem menjadi mampu menangkap lebih

banyak variasi perilaku yang mengindikasikan kelelahan. Hal ini sejalan dengan temuan penelitian Rahmawati et al. [13] yang juga menyimpulkan bahwa penggabungan indikator mata dan mulut dapat meningkatkan akurasi deteksi kelelahan hingga 3% dibandingkan dengan penggunaan salah satu indikator tunggal. Oleh karena itu, pendekatan kombinasi EAR dan MAR terbukti sangat efektif untuk membangun sistem deteksi kelelahan yang robust.

4.3. Keunggulan Pendekatan 1DCNN-LSTM

Arsitektur 1DCNN-LSTM memberikan keuntungan signifikan dalam memproses data *time-series* dari EAR dan MAR. 1DCNN mampu mengekstraksi pola lokal dari perubahan nilai EAR dan MAR dalam jangka pendek. LSTM mampu mengidentifikasi pola temporal jangka panjang, seperti transisi dari kondisi normal menuju kantuk berat. Hasil ini konsisten dengan temuan Karim et al. [17] yang melaporkan bahwa kombinasi CNN dan LSTM dapat meningkatkan kemampuan model dalam mengenali pola sekuensial yang kompleks, terutama pada data fisiologis dan perilaku.

4.4. Evaluasi Confusion Matrix

Analisis lebih lanjut dilakukan dengan menggunakan *confusion matrix* untuk kombinasi fitur EAR+MAR. Dari Tabel 3 terlihat bahwa model mampu mengidentifikasi kondisi lelah dan normal dengan tingkat kesalahan yang sangat rendah. Tingkat *False Negative* (kondisi lelah yang tidak terdeteksi) sebesar 3,0% menjadi perhatian penting, karena kesalahan tipe ini berpotensi membahayakan keselamatan. Namun, nilainya sudah tergolong rendah dibandingkan beberapa penelitian terdahulu seperti Zhao et al.; Lan et al. [8] [28] yang melaporkan *False Negative* di atas 5% untuk metode berbasis satu fitur.

Tabel 3. *Confusion Matrix* Kombinasi fitur EAR+MAR

	Prediksi Lelah %	Prediksi Normal %
Aktual Lelah	97,0	3,0
Aktual Normal	2,7	97,3

4.5. Perbandingan dengan Penelitian Sebelumnya

Jika dibandingkan dengan penelitian terdahulu, metode ini memberikan hasil yang kompetitif terlihat pada Tabel 4. Peningkatan kinerja dapat dikaitkan dengan penggunaan model *deep learning* yang memanfaatkan informasi spasial dan temporal secara bersamaan, serta penggunaan *dataset* NITYMED yang memiliki variasi lebih luas dalam ekspresi wajah, pencahayaan, dan sudut pandang kamera.

Tabel 4. Perbandingan Hasil Penelitian

Peneliti	Metode	Dataset	Akurasi (%)
Majeed et al. [29]	EAR + MAR + SVM	Khusus	94,0
Omidyeganeh et al. [14]	MAR + CNN	Khusus	95,3
Penelitian ini	EAR + MAR + 1DCNN-LSTM	NITYMED	96,8

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem deteksi kelelahan pengemudi berbasis analisis citra wajah dengan memanfaatkan kombinasi dua parameter visual utama, yaitu *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR), menggunakan arsitektur *1-Dimensional Convolutional Neural Network* (1DCNN) yang dipadukan dengan *Long Short-Term Memory* (LSTM). Model ini dievaluasi menggunakan *dataset* NITYMED yang memiliki keragaman tinggi dalam kondisi pencahayaan, sudut pandang kamera, dan ekspresi wajah, sehingga mampu memberikan gambaran performa model yang lebih realistis.

Berdasarkan hasil evaluasi, kombinasi fitur EAR dan MAR terbukti memberikan kinerja terbaik dibandingkan penggunaan salah satu fitur secara tunggal. Pada pengujian, kombinasi tersebut mencapai akurasi 96,8%, presisi 97,1%, *recall* 96,5%, dan *F1-score* 96,8%. Hasil ini menunjukkan bahwa kedua fitur tersebut bersifat saling melengkapi: EAR unggul dalam mendeteksi penutupan mata yang berkepanjangan (*prolonged eye closure*), sedangkan MAR efektif dalam mendeteksi aktivitas menguap sebagai tanda awal mengantuk. Integrasi keduanya memperluas cakupan deteksi, sehingga model mampu mengidentifikasi tanda-tanda kelelahan secara lebih akurat.

Keunggulan metode ini juga ditunjang oleh pemanfaatan arsitektur 1DCNN-LSTM yang memadukan kemampuan ekstraksi pola spasial (1DCNN) dan pemodelan hubungan temporal (LSTM). Pendekatan ini memungkinkan sistem mengenali pola perubahan nilai EAR dan MAR secara berurutan dari waktu ke waktu, yang merupakan karakteristik penting dalam deteksi kantuk. Hasil penelitian ini konsisten dengan temuan sebelumnya [30] [14] yang menegaskan bahwa penggabungan indikator mata dan mulut meningkatkan akurasi deteksi.

Secara praktis, model yang dihasilkan memiliki potensi besar untuk diimplementasikan dalam sistem driver monitoring pada kendaraan modern sebagai fitur keselamatan aktif. Dengan kemampuan bekerja secara *real-time* dan berbasis citra wajah yang non-invasif, sistem ini dapat memberikan peringatan dini kepada pengemudi sebelum kondisi kantuk menjadi

kritis, sehingga berpotensi mengurangi risiko kecelakaan lalu lintas.

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Pertama, kinerja model masih bergantung pada kualitas citra dan pencahayaan. Kondisi ekstrim seperti cahaya terlalu redup atau adanya obstruksi pada wajah (misalnya penggunaan kacamata hitam atau masker) dapat menurunkan akurasi deteksi. Kedua, sistem ini belum mengintegrasikan parameter fisiologis atau perilaku kendaraan, yang pada beberapa studi terbukti dapat meningkatkan akurasi. Ketiga, penelitian ini masih sebatas pada evaluasi menggunakan data dari *dataset* NITYMED, sehingga diperlukan uji coba lapangan untuk mengukur kinerja dalam kondisi berkendara nyata.

Untuk penelitian selanjutnya, disarankan beberapa pengembangan. Pertama, melakukan pengujian multi-modal dengan menggabungkan data visual, fisiologis (misalnya detak jantung, EEG), dan perilaku kendaraan untuk meningkatkan robustness sistem. Kedua, mengoptimalkan model agar dapat berjalan secara efisien pada perangkat *edge computing* dengan sumber daya terbatas, sehingga memungkinkan penerapan langsung pada perangkat keras kendaraan. Ketiga, melakukan validasi pada skenario nyata dengan pengemudi yang memiliki latar belakang, usia, dan kebiasaan mengemudi yang beragam, guna memastikan generalisasi model.

Secara keseluruhan, penelitian ini telah menunjukkan bahwa deteksi kelelahan berbasis kombinasi EAR dan MAR dengan pendekatan 1DCNN-LSTM merupakan solusi efektif, efisien, dan aplikatif untuk meningkatkan keselamatan berkendara. Dengan pengembangan lebih lanjut, metode ini berpotensi menjadi salah satu komponen penting dalam teknologi kendaraan cerdas masa depan.

DAFTAR PUSTAKA

- [1] WHO, "Global Status Report on Road Safety 2023," *World Health Organization (WHO)*, 2023.
<https://www.who.int/publications/b/68866>.
- [2] G. Maycock, "Sleepiness and driving: The experience of U.K. car drivers," *Accident Analysis & Prevention*, vol. 29, no. 4, pp. 453–462, 1997, doi: 10.1016/s0001-4575(97)00024-9.
- [3] T. Åkerstedt, "Consensus Statement: Fatigue and accidents in transport operations," *Journal of Sleep Research*, vol. 9, no. 4, pp. 395–395, 2000, doi: 10.1046/j.1365-2869.2000.00228.x.
- [4] BPS, "Statistik Transportasi Darat 2023," BPS, 2023.
<https://www.bps.go.id/id/publication/2024/11/25/cdcf9b5e74dd2e9bb3458ee4/statistik-transportasi-darat-2023.html>
- [5] P. Philip *et al.*, "Fatigue, Sleepiness, and Performance in Simulated Versus Real Driving Conditions," *Sleep*, vol. 28, no. 12, pp. 1511–1516, 2005, doi: 10.1093/sleep/28.12.1511.
- [6] T. Åkerstedt and M. Gillberg, "Subjective and Objective Sleepiness in the Active Individual," *International Journal of Neuroscience*, vol. 52, no. 1–2, pp. 29–37, 1990, doi: 10.3109/00207459008994241.
- [7] R. Schleicher, N. Galley, S. Briest, and L. Galley, "Blinks and saccades as indicators of fatigue in sleepiness warnings: looking tired?," *Ergonomics*, vol. 51, no. 7, pp. 982–1010, 2008, doi: 10.1080/00140130701817062.
- [8] Z. Zhao, N. Zhou, L. Zhang, H. Yan, Y. Xu, and Z. Zhang, "Driver Fatigue Detection Based on Convolutional Neural Networks Using EM-CNN," *Computational Intelligence and Neuroscience*, vol. 2020, pp. 1–11, Nov. 2020, doi: 10.1155/2020/7251280.
- [9] B. T. Jap, S. Lal, P. Fischer, and E. Bekiaris, "Using EEG spectral components to assess algorithms for detecting fatigue," *Expert Systems with Applications*, vol. 36, no. 2, pp. 2352–2359, 2009, doi: 10.1016/j.eswa.2007.12.043.
- [10] R. Grace *et al.*, "A drowsy driver detection system for heavy vehicles," in *17th DASC. AIAA/IEEE/SAE. Digital Avionics Systems Conference. Proceedings (Cat. No.98CH36267)*, vol. 2, p. 136/1-136/8, doi: 10.1109/dasc.1998.739878.
- [11] P. Viola and M. J. Jones, "Robust Real-Time Face Detection," *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, 2004, doi: 10.1023/b:visi.0000013087.49260.fb.
- [12] L. Youwei, "Real-time eye blink detection using general cameras: a facial landmarks approach," *International Science Journal of Engineering & Agriculture*, vol. 2, no. 5, pp. 1–8, 2023, doi: 10.46299/j.isjea.20230205.01.
- [13] Y. Rahmawati, K. Woraratpanya, I. Ardiyanto, and H. Adi Nugroho, "Evaluating the effectiveness of facial actions features for the early detection of driver drowsiness in driving safety monitoring system," *Communications in Science and Technology*, vol. 10, no. 1, pp. 179–189, Jul. 2025, doi: 10.21924/cst.10.1.2025.1594.
- [14] M. Omidyeganeh *et al.*, "Yawning Detection Using Embedded Smart Cameras," *IEEE Transactions on Instrumentation and Measurement*, vol. 65, no. 3, pp. 570–582, Mar. 2016, doi: 10.1109/TIM.2015.2507378.
- [15] X. Fan, B.-C. Yin, and Y.-F. Sun, "Yawning Detection for Monitoring Driver Fatigue," in *2007 International Conference on Machine Learning and Cybernetics*, 2007, pp. 664–668, doi: 10.1109/icmlc.2007.4370228.
- [16] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998, doi: 10.1109/5.726791.

- [17] F. Karim, S. Majumdar, H. Darabi, and S. Chen, "LSTM Fully Convolutional Networks for Time Series Classification," *IEEE Access*, vol. 6, pp. 1662–1669, 2018, doi: 10.1109/access.2017.2779939.
- [18] Z. Wang, W. Yan, and T. Oates, "Time series classification from scratch with deep neural networks: A strong baseline," in *2017 International Joint Conference on Neural Networks (IJCNN)*, 2017, pp. 1578–1585. doi: 10.1109/ijcnn.2017.7966039.
- [19] N. Petrellis, N. Voros, C. Antonopoulos, G. Keramidas, P. Christakos, and P. Mousoulitis, "NITYMED," 2022. doi: 10.21227/85xe-3f88.
- [20] WHO, "Road traffic injuries," *World Health Organization (WHO)*, 2023. <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- [21] J. Cui, S. Li, and Z. Hu, "Research on Fatigue Detection Technology based on Facial Feature Points," in *2024 4th International Symposium on Computer Technology and Information Science (ISCTIS)*, Jul. 2024, pp. 631–634. doi: 10.1109/ISCTIS63324.2024.10698829.
- [22] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [23] E. Civik and U. Yuzgec, "Real-time driver fatigue detection system with deep learning on a low-cost embedded system," *Microprocessors and Microsystems*, vol. 99, p. 104851, Jun. 2023, doi: 10.1016/j.micpro.2023.104851.
- [24] N. K. Gupta, A. K. Bari, S. Kumar, D. Garg, and K. Gupta, "Review Paper on Yawning Detection Prediction System for Driver Drowsiness," in *2021 5th International Conference on Trends in Electronics and Informatics (ICOEI)*, Jun. 2021, pp. 1–6. doi: 10.1109/ICOEI51242.2021.9453008.
- [25] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, vol. 1, pp. 886–893. doi: 10.1109/cvpr.2005.177.
- [26] V. Kazemi and J. Sullivan, "One millisecond face alignment with an ensemble of regression trees," in *2014 IEEE Conference on Computer Vision and Pattern Recognition*, Jun. 2014, pp. 1867–1874. doi: 10.1109/CVPR.2014.241.
- [27] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," *Conference Paper at the 3rd International Conference for Learning Representations*, 2015.
- [28] Z. Lan, J. Zhao, P. Liu, C. Zhang, N. Lyu, and L. Guo, "Driving fatigue detection based on fusion of EEG and vehicle motion information," *Biomedical Signal Processing and Control*, vol. 92, p. 106031, Jun. 2024, doi: 10.1016/j.bspc.2024.106031.
- [29] P. Majeed, S. P. Kumar, and M. Kumar, "Combining EAR and MAR for fatigue detection," *IEEE Access*, vol. 7, pp. 123–131, 2019.
- [30] A. Picot, S. Charbonnier, and A. Caplier, "On-Line Detection of Drowsiness Using Brain and Visual Information," *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 42, no. 3, pp. 764–775, 2012, doi: 10.1109/tsmca.2011.2164242.