

Perbandingan Model CNN-PERCLOS dan SVM-HOG untuk Deteksi Kantuk Mahasiswa

Dodik Ariyanto ², Raden Muhammad Raditya Rahman ^{1,*}, Muhammad Rafi Alexander Prayoga ¹, Rafii Khairan Saragih ¹, Faldiena Marcelita ²

¹ Teknologi Rekayasa Perangkat Lunak; Sekolah Vokasi IPB University; Kota Bogor, Jawa Barat, (0251) 8348007; e-mail: radttyarahman@apps.ipb.ac.id, alexanderafi@apps.ipb.ac.id, rafiisaraqih@apps.ipb.ac.id.

² Teknologi Rekayasa Komputer; Sekolah Vokasi IPB University; Kota Bogor, Jawa Barat, (0251) 8348007; e-mail: dodikariyanto@apps.ipb.ac.id, faldiena.m@apps.ipb.ac.id

* Korespondensi: e-mail: radttyarahman@apps.ipb.ac.id

Diterima: 25-05-2026; Review: 02-06-2026; Disetujui: 30 -07-2026

Abstrak: Pembelajaran daring menuntut mahasiswa untuk mempertahankan perhatian visual dalam durasi yang panjang, sedangkan pola tidur yang kurang baik dan kelelahan dapat menurunkan konsentrasi serta meningkatkan risiko kantuk. Penelitian ini membandingkan metode CNN-PERCLOS dan SVM-HOG untuk mendeteksi kantuk mahasiswa menggunakan data citra wajah. Dataset yang digunakan diperoleh dari Kaggle Drowsiness Dataset dan terdiri atas empat kelas, yaitu Closed_Eyes, Open_Eyes, Yawn, dan No_yawn. Tahapan penelitian meliputi akuisisi dataset, pra-pemrosesan, klasifikasi visual berbasis CNN, perhitungan PERCLOS, ekstraksi fitur HOG, klasifikasi SVM, dan evaluasi model. Evaluasi dilakukan menggunakan akurasi, presisi, recall, F1-score, dan confusion matrix. Hasil pengujian menunjukkan bahwa CNN-PERCLOS memperoleh performa lebih baik dibandingkan SVM-HOG, dengan akurasi 92.5%, presisi 92.9%, recall 92.5%, dan F1-score 92.5%. Sementara itu, SVM-HOG memperoleh akurasi 82.7%, presisi 83.2%, recall 82.7%, dan F1-score 82.6%. Hasil tersebut menunjukkan bahwa CNN-PERCLOS lebih efektif dalam mengenali pola visual kantuk dibandingkan fitur manual HOG dengan SVM.

Kata kunci: CNN, PERCLOS, SVM, HOG, deteksi kantuk

Abstract: Online learning required students to maintain visual attention for long periods, while poor sleep patterns and fatigue could reduce concentration and increase drowsiness. This study compared CNN-PERCLOS and SVM-HOG methods for detecting student drowsiness using facial image data. The dataset was obtained from the Kaggle Drowsiness Dataset and consisted of four classes, namely Closed_Eyes, Open_Eyes, Yawn, and No_yawn. The research stages included dataset acquisition, preprocessing, CNN-based visual classification, PERCLOS calculation, HOG feature extraction, SVM classification, and model evaluation. The evaluation used accuracy, precision, recall, F1-score, and confusion matrix. The experimental results showed that CNN-PERCLOS achieved better performance than SVM-HOG, with an accuracy of 92.5%, precision of 92.9%, recall of 92.5%, and F1-score of 92.5%. Meanwhile, SVM-HOG obtained an accuracy of 82.7%, precision of 83.2%, recall of 82.7%, and F1-score of 82.6%. These results indicated that CNN-PERCLOS was more effective in recognizing visual drowsiness patterns than handcrafted HOG features with SVM.

Keywords: CNN, PERCLOS, SVM, HOG, drowsiness detection

1. Pendahuluan

Pembelajaran daring menjadi salah satu bentuk pembelajaran yang banyak digunakan pada pendidikan tinggi karena mampu memperluas akses belajar dan mendukung fleksibilitas

waktu. Namun, pembelajaran daring juga menimbulkan tantangan baru, terutama berkaitan dengan kemampuan mahasiswa mempertahankan konsentrasi ketika berinteraksi dengan layar komputer dalam waktu lama. Paparan video conference yang berulang, durasi perkuliahan yang panjang, serta rendahnya interaksi fisik dapat meningkatkan kelelahan belajar. Salim dkk. menemukan bahwa zoom fatigue pada mahasiswa Indonesia berkaitan dengan kualitas tidur yang buruk, durasi video conference yang panjang, serta faktor psikologis seperti stres, kecemasan, dan depresi [1].

Kondisi kantuk pada mahasiswa tidak hanya dipengaruhi oleh aktivitas pembelajaran daring, tetapi juga oleh pola tidur yang kurang baik. Azizah menjelaskan bahwa mahasiswa rentan mengalami gangguan tidur akibat tekanan akademik, jadwal belajar yang tidak teratur, penggunaan gawai secara berlebihan pada malam hari, serta stres akademik [2]. Kualitas tidur yang rendah dapat berdampak pada penurunan konsentrasi, kelelahan fisik, ketidakstabilan suasana hati, dan penurunan performa akademik. Oleh karena itu, deteksi kantuk pada mahasiswa saat pembelajaran daring menjadi topik yang relevan untuk dikaji, terutama dengan pendekatan berbasis kecerdasan buatan dan computer vision.

Deteksi kantuk berbasis citra umumnya dilakukan dengan menganalisis ciri visual pada wajah, khususnya kondisi mata dan mulut. Indikator yang sering digunakan meliputi penutupan mata, frekuensi kedipan, durasi mata tertutup, serta perilaku menguap. Pengukuran kedipan mata juga telah digunakan dalam penelitian sebelumnya untuk mendeteksi kelelahan berbasis citra, sehingga area mata menjadi salah satu indikator penting dalam sistem deteksi kantuk [3]. Selain itu, pendekatan berbasis fitur wajah juga telah diterapkan dalam sistem peringatan dini kantuk dengan memanfaatkan facial landmark detection untuk mengamati kondisi mata secara otomatis [4]. Salah satu parameter yang banyak digunakan untuk mengukur kantuk adalah Percentage of Eye Closure atau PERCLOS, yaitu persentase waktu mata berada dalam kondisi tertutup selama periode tertentu [5]. PERCLOS relevan digunakan karena memiliki hubungan langsung dengan kondisi penurunan kewaspadaan visual, sehingga sesuai untuk sistem deteksi kantuk berbasis kamera.

Beberapa penelitian di Indonesia telah mengembangkan sistem deteksi kantuk menggunakan pendekatan deep learning maupun machine learning. Akbar dkk. menggunakan Convolutional Neural Network untuk mendeteksi kantuk pengemudi berbasis citra [6]. Ritonga dan Muhandis mengombinasikan Viola-Jones dan CNN pada sistem deteksi kantuk real-time [7], sedangkan Larasati mengembangkan deteksi kantuk berbasis CNN dan landmark wajah [8]. Selain itu, Lubis dkk. menerapkan metode Haar Cascade untuk mendeteksi kantuk berbasis computer vision melalui pengamatan kondisi wajah atau mata [9]. Di sisi lain, pendekatan machine learning juga banyak digunakan, seperti PCA dan SVM [10], SVM berbasis citra real-time [11], serta HOG dan Linear SVM untuk analisis rasio mata [12].

Penelitian internasional juga menunjukkan arah pengembangan yang serupa. Li dkk. mengusulkan sistem berbasis CNN untuk mendeteksi kantuk melalui perangkat wearable [13]. Owen dan Surantha membahas deteksi kantuk berbasis computer vision menggunakan handcrafted feature extraction pada perangkat edge computing [14]. Vázquez-Santana dan Argüelles-Cruz mengembangkan pendekatan non-intrusive yang membandingkan fitur visual seperti HOG-SVM dan CNN untuk pencegahan kecelakaan [15]. Essahraoui dkk. juga membahas pemanfaatan analisis wajah dan teknik machine learning untuk deteksi kantuk secara real-time [16].

Berdasarkan kajian tersebut, terdapat dua pendekatan utama yang dapat dibandingkan. Pendekatan pertama adalah CNN-PERCLOS, yaitu kombinasi deep learning untuk klasifikasi kondisi mata dan PERCLOS untuk mengukur persentase penutupan mata. Pendekatan kedua adalah SVM-HOG, yaitu kombinasi fitur manual HOG sebagai deskriptor bentuk dan tekstur, kemudian diklasifikasikan menggunakan Support Vector Machine. CNN memiliki keunggulan dalam ekstraksi fitur otomatis, sedangkan SVM-HOG memiliki keunggulan pada proses yang lebih sederhana dan dapat menjadi baseline yang kuat untuk dataset citra berukuran terbatas.

Permasalahan utama dalam penelitian ini adalah belum adanya perbandingan yang spesifik antara CNN-PERCLOS dan SVM-HOG untuk konteks deteksi kantuk mahasiswa saat pembelajaran daring dengan menggunakan dataset citra mata dan mulut. Penelitian yang berfokus pada pengemudi sudah cukup banyak, namun konteks mahasiswa saat pembelajaran daring memiliki karakteristik berbeda, seperti posisi duduk yang lebih statis, intensitas paparan layar, kondisi pencahayaan ruang belajar, serta variasi ekspresi wajah ketika mengikuti kelas daring.

Tujuan penelitian ini adalah membandingkan performa model CNN-PERCLOS dan SVM-HOG dalam mendeteksi kantuk mahasiswa berbasis citra. Perbandingan dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan confusion matrix. Kontribusi penelitian ini adalah memberikan rancangan evaluasi komparatif yang dapat digunakan untuk menentukan pendekatan yang lebih sesuai dalam sistem deteksi kantuk mahasiswa saat pembelajaran daring.

2. Metode Penelitian

Penelitian ini menggunakan desain eksperimen komparatif untuk membandingkan performa dua pendekatan deteksi kantuk, yaitu CNN-PERCLOS sebagai model utama dan SVM-HOG sebagai model pembanding atau baseline. Desain ini dipilih karena tujuan penelitian bukan membangun proses bisnis data mining, melainkan menguji dua metode klasifikasi pada dataset, skenario pra-pemrosesan, dan data uji yang sama. Dengan rancangan tersebut, perbedaan performa yang diperoleh dapat dikaitkan secara lebih jelas dengan karakteristik masing-masing metode.


Objek penelitian berupa citra mata dan mulut yang merepresentasikan indikator visual kantuk. Dataset yang digunakan adalah Drowsiness Dataset dari Kaggle yang telah dikelompokkan ke dalam folder train, validation, dan test [18]. Dataset terdiri atas empat kelas, yaitu Open_Eyes, Closed_Eyes, Yawn, dan No_yawn. Kelas Open_Eyes dan Closed_Eyes digunakan untuk mendeteksi kondisi mata sebagai dasar perhitungan PERCLOS, sedangkan kelas Yawn dan No_yawn digunakan sebagai informasi pendukung terkait perilaku menguap.[18]

Tahapan penelitian terdiri atas akuisisi dataset, pra-pemrosesan citra, ekstraksi region of interest (ROI) pada area mata dan mulut, pelatihan model CNN, perhitungan PERCLOS, ekstraksi fitur HOG, pelatihan model SVM, pengujian berbasis data test, pengujian real-time menggunakan kamera, dan perbandingan performa. Seluruh model dievaluasi menggunakan data uji yang sama untuk menjaga keadilan perbandingan. Evaluasi dilakukan menggunakan accuracy, precision, recall, F1-score, dan confusion matrix.

Tabel 1. Struktur Dataset yang digunakan

Subset	Jumlah Citra	Kelas	Keterangan
Train	8.548	Open_Eyes, Closed_Eyes, Yawn, No_yawn	Data untuk pelatihan model
Validation	1.554	Open_Eyes, Closed_Eyes, Yawn, No_yawn	Data validasi parameter model
Test	1.464	Open_Eyes, Closed_Eyes, Yawn, No_yawn	Data pengujian akhir
Total	11.566	4 kelas	Dataset seimbang menurut deskripsi sumber

Sumber: Hasil Penelitian (2026)



Sumber: Hasil Penelitian (2026)

Gambar 1. Alur penelitian komparatif CNN-PERCLOS dan SVM-HOG

2.1 Pra-pemrosesan data

Pra-pemrosesan dilakukan agar citra memiliki ukuran, format, dan skala nilai piksel yang konsisten sebelum masuk ke model. Tahapan yang dilakukan meliputi pemilihan kelas, perubahan ukuran citra, normalisasi piksel, konversi warna sesuai kebutuhan model, pelabelan data, dan ekstraksi region of interest (ROI) pada area mata serta mulut. Pada model CNN, citra diubah ke ukuran 64 x 64 piksel dan nilai piksel dinormalisasi ke rentang 0 sampai 1. Pada model SVM-HOG, citra dikonversi ke grayscale sebelum fitur HOG diekstraksi. Untuk pengujian real-time, MediaPipe Face Mesh digunakan untuk membantu memperoleh landmark wajah sehingga area mata dan mulut dapat diproses secara lebih terarah.

Dalam konteks deteksi kantuk mahasiswa saat pembelajaran daring, citra mata tertutup diperlakukan sebagai indikasi awal kantuk, sedangkan citra mata terbuka diperlakukan sebagai kondisi tidak kantuk. Kelas Yawn dan No_yawn digunakan sebagai informasi tambahan karena perilaku menguap dapat memperkuat indikasi kantuk. Penggunaan ROI dilakukan agar model

lebih fokus pada area visual yang paling relevan dan mengurangi pengaruh latar belakang atau bagian wajah lain yang tidak diperlukan.

2.2 Model CNN-PERCLOS

Model CNN-PERCLOS digunakan sebagai pendekatan berbasis deep learning untuk mendeteksi indikasi kantuk melalui kondisi mata. CNN berperan dalam mempelajari pola visual pada citra secara otomatis, sedangkan PERCLOS digunakan sebagai parameter untuk mengukur tingkat kecenderungan kantuk berdasarkan persentase kondisi mata tertutup dalam suatu interval pengamatan. Pendekatan ini dipilih karena CNN mampu mengenali pola visual pada citra mata tanpa memerlukan proses ekstraksi fitur manual [6].

Arsitektur dasar CNN pada penelitian ini terdiri atas beberapa lapisan utama, yaitu convolution layer, pooling layer, flatten layer, fully connected layer, dan output layer. Convolution layer berfungsi untuk mengekstraksi fitur penting dari citra, seperti tepi, tekstur, dan pola bentuk mata. Selanjutnya, pooling layer digunakan untuk mereduksi dimensi fitur agar proses komputasi menjadi lebih efisien dan mengurangi risiko overfitting. Setelah itu, hasil ekstraksi fitur diubah menjadi vektor melalui flatten layer dan diproses oleh fully connected layer untuk menghasilkan keputusan klasifikasi.

Pada penelitian ini, output CNN digunakan untuk mengklasifikasikan kondisi citra ke dalam beberapa kelas, yaitu Closed_Eyes, Open_Eyes, Yawn, dan No_yawn. Kelas Closed_Eyes dan Open_Eyes digunakan untuk merepresentasikan kondisi mata, sedangkan kelas Yawn dan No_yawn digunakan sebagai indikator tambahan yang berkaitan dengan gejala kantuk. Penggunaan CNN pada deteksi kantuk relevan karena metode ini mampu mempelajari fitur citra secara adaptif dari data pelatihan [13].

Setelah kondisi mata berhasil diklasifikasikan, nilai PERCLOS dihitung untuk mengetahui persentase kondisi mata tertutup dalam interval tertentu. PERCLOS merupakan salah satu indikator yang banyak digunakan dalam deteksi kantuk karena merepresentasikan durasi mata tertutup atau hampir tertutup selama periode pengamatan [5]. Secara umum, nilai PERCLOS dapat dihitung menggunakan persamaan sebagai berikut [17].

$$PERCLOS = \frac{\text{The sum of frame when eye is close}}{\text{Interval of frame}} \tilde{A} - 100\% \dots\dots\dots (1)$$

Nilai PERCLOS yang semakin tinggi menunjukkan bahwa mata berada dalam kondisi tertutup lebih lama, sehingga dapat mengindikasikan kecenderungan kantuk yang lebih kuat. Dalam konteks pembelajaran daring, indikator ini dapat digunakan untuk membantu mengamati penurunan kewaspadaan mahasiswa selama mengikuti proses belajar melalui perangkat kamera. Oleh karena itu, CNN-PERCLOS tidak hanya berfungsi sebagai model klasifikasi citra, tetapi juga sebagai pendekatan untuk mengukur kondisi kantuk berdasarkan pola visual mata.

Pada dataset Kaggle yang digunakan, data pelatihan dan pengujian model masih berbentuk citra. Namun, implementasi sistem juga telah diuji secara real-time dengan mengambil frame dari video kamera. Setiap frame diklasifikasikan terlebih dahulu oleh CNN, kemudian hasil klasifikasi mata tertutup dihitung menggunakan rumus PERCLOS dalam interval waktu tertentu. Apabila indikasi kantuk terdeteksi, sistem memberikan peringatan berupa bunyi alarm. Dengan demikian, model CNN-PERCLOS tidak hanya diuji pada data citra statis, tetapi juga telah dicoba dalam skenario pemantauan kantuk berbasis video.

2.3 Model SVM-HOG

Model SVM-HOG digunakan sebagai metode pembandingan berbasis machine learning klasik. Berbeda dengan CNN yang melakukan ekstraksi fitur secara otomatis, metode SVM-HOG memerlukan proses ekstraksi fitur terlebih dahulu sebelum data diklasifikasikan. Pada penelitian ini, HOG digunakan untuk mengambil informasi bentuk dan orientasi gradien dari citra mata, sedangkan SVM digunakan sebagai algoritma klasifikasi berdasarkan fitur yang telah diperoleh.

HOG merupakan metode ekstraksi fitur yang bekerja dengan menghitung distribusi orientasi gradien pada area citra. Fitur ini dapat merepresentasikan pola tepi, kontur, dan perubahan intensitas piksel yang terdapat pada citra mata. Dalam deteksi kantuk, pola tersebut penting karena kondisi mata terbuka dan tertutup memiliki perbedaan bentuk visual yang dapat diamati melalui perubahan kontur kelopak mata. Oleh karena itu, HOG relevan digunakan untuk merepresentasikan karakteristik visual pada citra wajah atau mata [12].

Setelah fitur HOG diperoleh, fitur tersebut digunakan sebagai input pada algoritma SVM. SVM bekerja dengan mencari bidang pemisah terbaik atau hyperplane yang dapat membedakan kelas data secara optimal. Pada penelitian ini, SVM digunakan untuk mengklasifikasikan citra berdasarkan fitur HOG ke dalam kelas yang sesuai. Metode SVM dipilih karena mampu menangani data berdimensi tinggi dan sering digunakan pada kasus klasifikasi citra berbasis fitur manual [10].

Model SVM-HOG berperan sebagai baseline untuk membandingkan performa pendekatan berbasis fitur manual dengan pendekatan berbasis deep learning. Perbandingan ini penting karena CNN umumnya memiliki kemampuan yang lebih baik dalam mempelajari pola visual kompleks, tetapi membutuhkan proses pelatihan yang lebih berat. Sebaliknya, SVM-HOG memiliki proses yang lebih sederhana dan relatif ringan, sehingga masih berpotensi digunakan pada perangkat dengan keterbatasan komputasi [14].

Pada penelitian ini, SVM-HOG digunakan untuk mengetahui sejauh mana fitur manual dapat mengenali kondisi mata dan gejala kantuk pada dataset yang sama. Dengan menggunakan dataset dan data uji yang sama, hasil evaluasi antara CNN-PERCLOS dan SVM-HOG dapat dibandingkan secara lebih adil. SVM-HOG tidak diposisikan sebagai sistem utama, tetapi sebagai baseline pembanding untuk melihat apakah ekstraksi fitur otomatis pada CNN-PERCLOS memberikan peningkatan performa yang signifikan dibandingkan pendekatan berbasis fitur manual.

2.4 Skenario pengujian

Skenario pengujian disusun agar kedua model diuji pada kondisi yang sebanding. Data train digunakan untuk melatih model, data validation digunakan untuk memantau kecenderungan overfitting dan penyesuaian parameter, sedangkan data test digunakan untuk evaluasi akhir. Pada CNN-PERCLOS, model mengklasifikasikan kondisi visual dari citra, kemudian hasil deteksi mata tertutup digunakan untuk menghitung nilai PERCLOS. Pada SVM-HOG, citra terlebih dahulu dikonversi ke grayscale, fitur HOG diekstraksi, kemudian klasifikasi dilakukan menggunakan SVM. Selain pengujian pada data test, sistem juga diuji secara real-time menggunakan kamera untuk memastikan alur deteksi, alarm, dan pencatatan hasil dapat berjalan.

Tabel 2. Skenario Pengujian dan Konfigurasi Model

Komponen	CNN-PERCLOS	SVM-HOG
Input	Citra mata/mulut	Citra mata/mulut grayscale
Fitur	Ekstraksi otomatis CNN	Fitur HOG
Klasifikasi	Softmax/sigmoid	Support Vector Machine
Indikator Kantuk	PERCLOS	Prediksi SVM per citra
Evaluasi	Accuracy, precision, recall, F1-score	Accuracy, precision, recall, F1-score
Pengujian Real-Time	Frame kamera, PERCLOS, dan alarm	Tidak digunakan sebagai sistem utama

2.5 Evaluasi Model

Evaluasi model dilakukan untuk mengetahui tingkat keberhasilan CNN-PERCLOS dan SVM-HOG dalam mengklasifikasikan kondisi kantuk berdasarkan citra. Evaluasi dilakukan menggunakan data uji yang tidak digunakan pada proses pelatihan model. Penggunaan data uji bertujuan untuk mengukur kemampuan model dalam mengenali data baru, sehingga hasil evaluasi dapat menggambarkan performa model secara lebih objektif.

Pada penelitian ini, evaluasi dilakukan menggunakan confusion matrix dan beberapa metrik pengukuran, yaitu accuracy, precision, recall, dan F1-score. Confusion matrix digunakan untuk menampilkan jumlah data yang diklasifikasikan dengan benar maupun salah pada setiap kelas. Kelas yang digunakan dalam penelitian ini terdiri atas Closed_Eyes, Open_Eyes, Yawn, dan No_yawn. Melalui confusion matrix, dapat diketahui pola kesalahan klasifikasi yang terjadi pada masing-masing model, misalnya citra mata tertutup yang diprediksi sebagai mata terbuka atau citra menguap yang diprediksi sebagai tidak menguap.

Akurasi digunakan untuk mengukur persentase jumlah prediksi benar dibandingkan seluruh data uji. Nilai akurasi dapat dihitung menggunakan persamaan sebagai berikut [17].

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

Presisi digunakan untuk mengetahui tingkat ketepatan model dalam memprediksi suatu kelas sebagai positif. Nilai presisi dapat dihitung menggunakan persamaan sebagai berikut [17].

$$Precision = \frac{TP}{TP + FP} \dots\dots\dots (3)$$

Recall digunakan untuk mengetahui kemampuan model dalam menemukan seluruh data positif yang sebenarnya. Nilai recall dapat dihitung menggunakan persamaan sebagai berikut [17].

$$Recall = \frac{TP}{TN + FN} \dots\dots\dots (4)$$

Sementara itu, F1-score merupakan nilai rata-rata harmonik antara precision dan recall. Metrik ini digunakan untuk melihat keseimbangan antara ketepatan prediksi dan kemampuan model dalam mengenali data pada setiap kelas. Nilai F1-score dapat dihitung menggunakan persamaan sebagai berikut [17].

$$F1 \text{ Score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \dots\dots\dots (5)$$

TP = *True Positive*, yaitu data positif yang diklasifikasikan dengan benar.

TN = *True Negative*, yaitu data negatif yang diklasifikasikan dengan benar.

FP = *False Positive*, yaitu data negatif yang salah diklasifikasikan sebagai positif.

FN = *False Negative*, yaitu data positif yang salah diklasifikasikan sebagai negatif.

Karena penelitian ini menggunakan empat kelas, nilai precision, recall, dan F1-score dihitung berdasarkan hasil klasifikasi pada setiap kelas, kemudian dirata-ratakan untuk memperoleh nilai performa akhir model. Hasil evaluasi dari CNN-PERCLOS dan SVM-HOG kemudian dibandingkan untuk menentukan model yang memiliki performa terbaik dalam mendeteksi kantuk. Model dengan nilai akurasi, presisi, recall, dan F1-score yang lebih tinggi menunjukkan kemampuan klasifikasi yang lebih baik. Selain itu, hasil confusion matrix juga dianalisis untuk melihat jenis kesalahan klasifikasi yang paling sering terjadi pada masing-masing model.

2.6 Implementasi dan Pengujian Real-Time

Selain pengujian berbasis dataset, sistem juga diuji menggunakan input kamera secara langsung. Pada tahap ini, video dari kamera diambil dalam bentuk frame, kemudian MediaPipe Face Mesh digunakan untuk mendeteksi landmark wajah. Area mata dan mulut dipotong sebagai ROI, diproses oleh model CNN, dan hasil klasifikasi digunakan untuk menentukan indikasi kantuk. Sistem tidak membunyikan alarm hanya berdasarkan satu frame, tetapi mempertimbangkan hasil beberapa frame terakhir agar kedipan normal tidak langsung dianggap sebagai kantuk.

Ketika mata terdeteksi tertutup dalam durasi tertentu atau nilai PERCLOS melewati ambang yang ditentukan, sistem memberikan peringatan berupa bunyi alarm. Pengujian real-time ini bertujuan memastikan bahwa alur deteksi tidak hanya berjalan pada dataset citra, tetapi juga dapat bekerja pada input video langsung. Meskipun demikian, implementasi real-time masih memiliki keterbatasan, seperti pencahayaan yang tidak stabil, wajah yang tidak terlihat, kamera tertutup, penggunaan kacamata, dan variasi bentuk mata. Kondisi tersebut menjadi dasar pengembangan fitur lanjutan seperti validasi kamera aktif, status wajah tidak terdeteksi, dan threshold yang lebih adaptif.

3. Hasil dan Pembahasan

Evaluasi performa sistem dalam penelitian ini difokuskan pada pengujian terhadap dua pendekatan utama, yaitu model CNN-PERCLOS yang berbasis *deep learning* dan model SVM-HOG yang berbasis *machine learning* konvensional. Model CNN-PERCLOS dievaluasi secara komprehensif berdasarkan kemampuan arsitektur jaringan saraf tiruan dalam mengenali karakteristik visual mata secara otomatis, yang kemudian diintegrasikan dengan perhitungan matematis proporsi durasi mata tertutup (PERCLOS) dalam kurun waktu tertentu. Di sisi lain, model SVM-HOG dievaluasi berdasarkan efektivitas deskriptor fitur *Histogram of Oriented Gradients* (HOG) dalam menangkap orientasi gradien lokal dan kemampuan *classifier Support*

Vector Machine (SVM) dalam menentukan garis pembatas (*hyperplane*) optimal untuk membedakan antara citra kondisi mata terbuka dan mata tertutup.

3.1. Hasil Pengujian CNN-PERCLOS

Model CNN-PERCLOS diuji menggunakan data test setelah proses pelatihan selesai. Pada pendekatan ini, CNN menghasilkan klasifikasi kondisi mata, kemudian hasil klasifikasi tersebut digunakan untuk menghitung nilai PERCLOS. Nilai PERCLOS yang tinggi menunjukkan bahwa mata lebih sering berada dalam kondisi tertutup selama periode pengamatan. Selain itu, CNN juga menghasilkan klasifikasi kondisi mulut sebagai pendukung indikator kantuk. Tabel 3 menunjukkan hasil Confusion Matrix dari model Convolutional Neural Network.

Tabel 3. Tabel Confusion Matrix CNN-PERCLOS

Kelas Aktual	Prediksi Benar	Prediksi Salah	Total Data Uji
Open_Eyes	150	36	186
Closed_Eyes	305	56	361
Yawn	443	5	448
No_yawn	452	17	469

Sumber: Hasil Pengujian Model (2026)

Berdasarkan Tabel 3, model CNN + PERCLOS menunjukkan performa klasifikasi yang cukup baik pada sebagian besar kelas. Kelas No_yawn dan Yawn memiliki jumlah prediksi benar yang tinggi, yaitu masing-masing 452 dan 443 data. Pada kelas Closed_Eyes, model mampu mengklasifikasikan 305 data dengan benar, namun masih terdapat kesalahan klasifikasi sebanyak 56 data. Hal ini menunjukkan bahwa perbedaan visual antara kondisi mata tertutup dan terbuka masih menjadi tantangan pada beberapa citra. Secara umum, model CNN + PERCLOS mampu mengenali pola kantuk dengan baik karena proses ekstraksi fitur dilakukan secara otomatis melalui lapisan konvolusi. Tabel 4 menunjukkan hasil pengujian menggunakan evaluasi metrik pada model Convolutional Neural Network.

Tabel 4. Hasil Pengujian CNN-PERCLOS

Accuracy	Precision	Recall	F1-Score
92.5%	92.9%	92.5%	92.5%

Sumber: Hasil Pengujian Model (2026)

Berdasarkan Tabel 4, model CNN-PERCLOS menunjukkan performa yang sangat luar biasa dengan tingkat akurasi global mencapai 92.5%. Nilai recall dan precision yang tinggi membuktikan bahwa integrasi antara pengenalan pola visual oleh CNN dan perhitungan durasi mata tertutup melalui PERCLOS berjalan sangat baik. Hal ini krusial untuk sistem deteksi kantuk mahasiswa, karena kombinasi ini tidak hanya akurat dalam mengenali tanda kantuk, tetapi juga berhasil menekan *false alarm* (salah tebak) sekaligus memastikan sistem tidak melewatkan kondisi kritis saat mahasiswa benar-benar tertidur di kelas.

3.2. Hasil Pengujian SVM-HOG

Model SVM-HOG diuji dengan fitur HOG yang diekstraksi dari citra mata grayscale. Hasil ekstraksi fitur kemudian diklasifikasikan menggunakan SVM. Pendekatan ini tidak mempelajari fitur secara otomatis seperti CNN, tetapi menggunakan representasi gradien yang menggambarkan bentuk dan arah tepi pada citra. Tabel 5 menunjukkan hasil Confusion Matrix dari model Support Vector Machine.

Tabel 5. Tabel Confusion Matrix SVM-HOG

Kelas Aktual	Prediksi Benar	Prediksi Salah	Total Data Uji
Open_Eyes	126	60	186
Closed_Eyes	285	76	361
Yawn	383	65	448

No_yawn	417	52	469
---------	-----	----	-----

Sumber: Hasil Pengujian Model (2026)

Berdasarkan Tabel 5, model SVM + HOG juga mampu melakukan klasifikasi kondisi kantuk, namun jumlah kesalahan prediksi lebih tinggi dibandingkan model CNN + PERCLOS. Pada kelas Closed_Eyes, terdapat 285 data yang berhasil diklasifikasikan dengan benar, tetapi 76 data salah diklasifikasikan. Pada kelas Yawn, model berhasil memprediksi 383 data dengan benar, tetapi masih terdapat 65 data yang juga salah diklasifikasikan. Kesalahan ini menunjukkan bahwa fitur HOG masih memiliki keterbatasan dalam merepresentasikan variasi ekspresi wajah dan kondisi mata, terutama ketika terdapat perbedaan pencahayaan, pose wajah, atau bentuk mata. Tabel 6 menunjukkan hasil pengujian menggunakan evaluasi metrik pada model Convolutional Neural Network.

Tabel 6. Hasil Pengujian SVM-HOG

Accuracy	Precision	Recall	F1-Score
82.7%	83.2%	82.7%	82.6%

Sumber: Hasil Pengujian Model (2026)

Berdasarkan Tabel 6, model SVM-HOG menunjukkan kemampuan yang sangat baik dalam mengenali pola visual kantuk melalui ekstraksi bentuk mata dan mulut. Nilai precision yang tinggi dikombinasikan dengan recall menunjukkan bahwa model memiliki akurasi yang seimbang dalam mengenali kondisi mahasiswa. Hal ini sangat penting dalam sistem deteksi kantuk mahasiswa, karena nilai recall yang tinggi memastikan sistem minim melewatkan kondisi mahasiswa yang sebenarnya mengantuk, sehingga risiko kegagalan sistem dalam memberikan peringatan pada situasi kritis dapat ditekan seminimal mungkin.

3.3 Perbandingan Performa Model

Pengujian komparatif antara metode CNN-PERCLOS dan metode SVM-HOG dilakukan untuk menentukan arsitektur terbaik dalam mendeteksi tingkat kantuk mahasiswa. Evaluasi dilakukan menggunakan empat metrik utama, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-score*. Hasil perbandingan performa dari kedua model tersebut disajikan secara rinci pada Tabel 7.

Tabel 7. Tabel Confusion Matrix SVM-HOG

Model	Accuracy	Precision	Recall	F1-Score
CNN-PERCLOS	92.5%	92.9%	92.5%	92.5%
SVM-HOG	82.7%	83.2%	82.7%	82.6%


Sumber: Hasil Pengujian Model (2026)

Berdasarkan Tabel 7, dapat disimpulkan bahwa model CNN-PERCLOS menunjukkan keunggulan performa yang signifikan di seluruh metrik evaluasi dibandingkan dengan SVM-HOG, dengan selisih akurasi mencapai 9.8%. Tingginya nilai *recall* (92.5%) pada CNN-PERCLOS menandakan bahwa integrasi ekstraksi fitur otomatis oleh CNN dan kalkulasi waktu kedipan melalui metrik PERCLOS jauh lebih sensitif dan akurat dalam mengenali kondisi mengantuk yang sebenarnya. Sementara itu, meskipun model SVM-HOG menghasilkan performa yang cukup stabil di kisaran 82%-83%, keterbatasan ekstraksi fitur HOG yang bersifat statis membuatnya kurang adaptif terhadap variasi dinamis visual wajah mahasiswa jika dibandingkan dengan pendekatan representasi hierarkis pada CNN. Dengan demikian, model CNN-PERCLOS menjadi representasi arsitektur yang paling ideal dan andal untuk diterapkan pada sistem deteksi kantuk mahasiswa guna menjamin efektivitas peringatan dini secara *real-time*.

3.4 Hasil Implementasi dan Pengujian Real-Time

Selain pengujian menggunakan dataset, penelitian ini juga mengimplementasikan sistem deteksi kantuk secara real-time menggunakan input kamera. Pada tahap ini, sistem membaca frame dari video secara langsung, kemudian mendeteksi area wajah menggunakan MediaPipe Face Mesh. Landmark wajah yang diperoleh digunakan untuk mengambil area mata dan mulut sebagai input klasifikasi model CNN-PERCLOS.


Gambar 2 menunjukkan tampilan sistem ketika kamera berhasil mendeteksi wajah pengguna secara real-time. Pada kondisi ini, sistem mampu membaca posisi wajah dan memproses area mata serta mulut untuk menentukan kondisi pengguna. Proses ini menunjukkan bahwa model tidak hanya diuji menggunakan citra statis dari dataset, tetapi juga telah diterapkan pada input video langsung.



Sumber: Hasil Penelitian (2026)

Gambar 2. Tampilan Deteksi Wajah Secara Real-Time

Ketika sistem mendeteksi indikasi kantuk, misalnya mata tertutup dalam durasi tertentu atau nilai PERCLOS melewati ambang batas yang ditentukan, sistem akan memberikan peringatan berupa bunyi alarm. Alarm ini berfungsi sebagai peringatan awal agar pengguna dapat kembali fokus. Gambar 5 menunjukkan tampilan sistem ketika kondisi kantuk terdeteksi dan alarm diaktifkan.



Sumber: Hasil Penelitian (2026)

Gambar 5. Tampilan Peringatan Kantuk dan Aktivasi Alarm

Hasil implementasi ini menunjukkan bahwa sistem CNN-PERCLOS telah dapat digunakan pada skenario real-time dengan input kamera. Sistem mampu melakukan deteksi wajah, mengambil area mata dan mulut, melakukan klasifikasi kondisi visual, serta memberikan peringatan ketika indikasi kantuk terdeteksi. Meskipun demikian, pengujian real-time masih perlu diperluas pada lebih banyak pengguna dan variasi kondisi lingkungan agar sistem dapat bekerja lebih stabil pada situasi pembelajaran daring yang sebenarnya.

3.5 Pembahasan Keterbatasan Penelitian

Keterbatasan utama penelitian ini adalah dataset pelatihan yang digunakan berasal dari platform publik dan tidak secara khusus dikumpulkan dari mahasiswa saat pembelajaran daring. Dengan demikian, konteks mahasiswa direpresentasikan melalui latar belakang penelitian dan skenario implementasi sistem, sedangkan data pelatihan model masih berasal dari dataset drowsiness umum. Penelitian lanjutan disarankan untuk mengumpulkan data aktual dari mahasiswa saat mengikuti pembelajaran daring dengan tetap memperhatikan etika penelitian, persetujuan partisipan, dan perlindungan privasi data.

Keterbatasan lain berkaitan dengan kondisi pencahayaan, kualitas kamera, posisi wajah, serta variasi bentuk mata. Pada pengguna dengan bentuk mata sipit, penggunaan kacamata, atau kondisi wajah yang tidak menghadap kamera dengan stabil, sistem dapat mengalami kesulitan dalam membedakan kondisi mata terbuka dan tertutup. Meskipun sistem telah diuji secara real-time menggunakan kamera, pengujian tersebut masih perlu diperluas pada jumlah pengguna dan kondisi lingkungan yang lebih beragam agar performa sistem dapat divalidasi secara lebih kuat pada situasi pembelajaran daring yang sebenarnya.

4. Kesimpulan

Penelitian ini berhasil membandingkan performa model CNN-PERCLOS dan SVM-HOG untuk sistem deteksi kantuk mahasiswa berbasis citra digital menggunakan Drowsiness Dataset. CNN-PERCLOS merepresentasikan pendekatan deep learning yang mempelajari fitur visual secara otomatis dan memanfaatkan metrik durasi penutupan mata (PERCLOS). Sementara itu, SVM-HOG merepresentasikan pendekatan machine learning konvensional yang mengandalkan ekstraksi fitur gradien manual HOG sebelum diklasifikasikan oleh SVM.

Hasil eksperimen aktual menunjukkan bahwa model CNN-PERCLOS memiliki performa yang signifikan lebih unggul dan efektif dibandingkan SVM-HOG di seluruh metrik evaluasi. Model CNN-PERCLOS berhasil mencapai nilai accuracy sebesar 92,5%, precision 92,9%, recall 92,5%, dan F1-score 92,5%. Di sisi lain, model SVM-HOG hanya memperoleh accuracy sebesar 82,7%, precision 83,2%, recall 82,7%, dan F1-score 82,6%. Nilai recall dan F1-score yang tinggi pada CNN-PERCLOS membuktikan bahwa integrasi fitur hierarkis dan perhitungan durasi kedipan mata jauh lebih andal dalam mengenali pola visual kantuk serta meminimalkan risiko kegagalan sistem dalam memberikan peringatan dini. Oleh karena itu, model CNN-PERCLOS direkomendasikan sebagai arsitektur utama untuk diterapkan pada sistem deteksi kantuk mahasiswa.

Selain memiliki performa yang lebih tinggi, model CNN-PERCLOS juga menunjukkan kemampuan yang lebih baik dalam menghadapi variasi kondisi citra, seperti perubahan ekspresi wajah, posisi kepala, dan tingkat pencahayaan yang berbeda. Kemampuan CNN dalam mengekstraksi fitur secara otomatis memungkinkan sistem mengenali karakteristik mata dan wajah secara lebih mendalam dibandingkan metode HOG yang hanya bergantung pada pola gradien tertentu. Integrasi metode PERCLOS juga memberikan nilai tambah karena sistem tidak hanya mendeteksi kondisi mata secara statis, tetapi juga memperhitungkan durasi penutupan mata dalam rentang waktu tertentu sebagai indikator utama kantuk. Dengan demikian, sistem mampu memberikan deteksi yang lebih stabil dan realistis untuk implementasi pada lingkungan pembelajaran mahasiswa.

Berdasarkan hasil penelitian, dapat disimpulkan bahwa kombinasi metode deep learning dan indikator fisiologis seperti PERCLOS memberikan hasil yang lebih optimal dibandingkan pendekatan machine learning konvensional. Sistem yang dikembangkan memiliki potensi untuk diterapkan sebagai media pendukung dalam meningkatkan konsentrasi dan keselamatan mahasiswa, khususnya pada aktivitas pembelajaran daring maupun aktivitas yang membutuhkan fokus tinggi dalam waktu lama. Selain itu, penelitian ini juga menunjukkan bahwa pemanfaatan teknologi *computer vision* dan *artificial intelligence* dapat memberikan kontribusi nyata dalam pengembangan sistem monitoring perilaku manusia secara otomatis dan real-time.

Untuk pengembangan penelitian selanjutnya, pengujian real-time perlu diperluas pada lebih banyak partisipan, variasi kamera, dan kondisi pencahayaan yang berbeda. Sistem juga dapat dikembangkan dengan menambahkan validasi kamera aktif, status wajah tidak terdeteksi, logging riwayat kantuk, serta dashboard monitoring yang menggunakan lebih banyak data aktual. Selain itu, penggunaan arsitektur deep learning yang lebih ringan seperti MobileNet atau EfficientNet dapat dipertimbangkan agar sistem lebih cepat dan stabil ketika dijalankan pada perangkat dengan spesifikasi terbatas.

Ucapan Terima Kasih

Penulis mengucapkan puji dan syukur kepada Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga penelitian ini dapat diselesaikan dengan baik. Penulis juga menyampaikan terima kasih kepada IPB University, khususnya Sekolah Vokasi IPB University dan dosen pembimbing yang telah memberikan arahan, masukan, serta dukungan selama proses penyusunan penelitian ini. Selain itu, penulis mengucapkan terima kasih kepada keluarga, teman-

teman, serta semua pihak yang telah membantu dan memberikan motivasi sehingga penelitian ini dapat terselesaikan dengan lancar.

Referensi

- [1] J. Salim, S. Tandy, J. N. Arnindita, J. J. Wibisono, M. R. Haryanto, dan M. G. Wibisono, "Zoom fatigue and its risk factors in online learning during the COVID-19 pandemic," *Medical Journal of Indonesia*, vol. 31, no. 1, hlm. 13–19, Jan 2022, doi: 10.13181/mji.oa.225703.
- [2] S. H. Azizah, "Pola Tidur Mahasiswa Di Tengah Kegiatan Kuliah: Kajian Literatur," vol. 4, 2026.
- [3] W. D. Rahayu, E. A. Pambudi, A. P. Wicaksono, dan F. Wibowo, "Sistem Deteksi Kelelahan Pengemudi Berdasarkan Pengukuran Kedipan Mata Menggunakan Metode Manhattan Distance," *Jutisi : Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 13, no. 1, hlm. 439, Apr 2024, doi: 10.35889/jutisi.v13i1.1852.
- [4] I. K. Y. T. Pranata, C. Ramadhani, dan G. W. Wiriasto, "Sistem Peringatan Dini Kantuk pada Pengemudi Malam Hari Menggunakan Metoda Facial Landmark Detection Berbasis Raspberry PI 3 Modul B," *Dielektrika: Department of Electrical Engineering University of Mataram*, vol. 10, no. 2, hlm. 100–111, Agu 2023.
- [5] T. Abe, "PERCLOS-based technologies for detecting drowsiness: current evidence and future directions," 2023, *Oxford University Press*. doi: 10.1093/sleepadvances/zpad006.
- [6] H. Akbar, D. Aryani, dan S. Junaedi, "Deteksi Kantuk Pengendara Mobil Berbasis Citra Menggunakan Convolutional Neural Networks," *INFORMATIKA*, vol. 10, no. 1, hlm. 13–20, Jan 2022, doi: 10.36987/informatika.v10i1.2454.
- [7] A. S. Ritonga dan I. Muhandhis, "Analisis dan Implementasi Metode Viola-Jones dan CNN pada Sistem Deteksi Kantuk Real-Time," *Jurnal Ilmiah IT CIDA*, vol. 10, no. 2, hlm. 53–66, Des 2024, doi: 10.55635/jic.v10i2.227.
- [8] L. Larasati, "Sistem Deteksi Kantuk Real-Time Berbasis Cnn Dan Landmark Wajah," *Kohesi: Jurnal Multidisiplin Saintek*, vol. 8, no. 1, Mei 2025, doi: 10.8734/Kohesi.v1i2.365.
- [9] A. A. Ramadana Lubis, S. I. Purnama, dan M. A. Afandi, "Sistem Pendeteksi Kantuk Berbasis Metode Haar Cascade Untuk Aplikasi Computer Vision," *Techno.Com*, vol. 22, no. 3, hlm. 589–598, Agu 2023, doi: 10.33633/tc.v22i3.8464.
- [10] N. Ramadhani, S. Aulia, E. Suhartono, dan S. Hadiyoso, "Deteksi Kantuk pada Pengemudi Berdasarkan Penginderaan Wajah Menggunakan PCA dan SVM," *Jurnal Rekayasa Elektroika*, vol. 17, no. 2, Jun 2021, doi: 10.17529/jre.v17i2.19884.
- [11] U. D. Maharani, A. S. Handayani, dan L. Lindawati, "Analisis Deteksi Mata Kantuk Di Wajah Pengemudi Menggunakan Support Vector Machine (SVM) Berbasis Citra Real-Time," *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 2, hlm. 940–949, Sep 2024, doi: 10.47065/bits.v6i2.5701.
- [12] A. A. M. Suradi, S. Alam, dan M. F. Rasyid, "Sistem Deteksi Kantuk Pengemudi Mobil Berdasarkan Analisis Rasio Mata Menggunakan Computer Vision," vol. 5, 2023.
- [13] Y. Li dkk., "A CNN-Based Wearable System for Driver Drowsiness Detection," *Sensors*, vol. 23, no. 7, hlm. 3475, Mar 2023, doi: 10.3390/s23073475.
- [14] V. Owen dan N. Surantha, "Computer Vision-Based Drowsiness Detection Using Handcrafted Feature Extraction for Edge Computing Devices," *Applied Sciences*, vol. 15, no. 2, hlm. 638, Jan 2025, doi: 10.3390/app15020638.
- [15] D. H. Vazquez-Santana dan A. J. Argüelles-Cruz, "Non-Intrusive Drowsiness Detection for Accident Prevention Using a Novel CNN," *Computación y Sistemas*, vol. 28, no. 3, Sep 2024, doi: 10.13053/cys-28-3-4981.
- [16] S. Essahraoui dkk., "Real-Time Driver Drowsiness Detection Using Facial Analysis and Machine Learning Techniques," *Sensors*, vol. 25, no. 3, hlm. 812, Jan 2025, doi: 10.3390/s25030812.
- [17] I. P. A. E. D. Udayana, N. P. E. Kherismawati, dan I. G. I. Sudipa, "Detection of Student Drowsiness Using Ensemble Regression Trees in Online Learning During a COVID-19 Pandemic," *Telematika*, vol. 19, no. 2, hlm. 229, Jun 2022, doi: 10.31315/telematika.v19i2.7044.
- [18] H. Tung, "Drowsiness Dataset," Kaggle, 2024. [Online]. Available: <https://www.kaggle.com/datasets/hoangtung719/drowsiness-dataset>.