

BAB III

METODOLOGI PENELITIAN

3.1 Gambaran Umum Objek Penelitian

Penelitian ini bertujuan untuk mengidentifikasi dini tanda-tanda kelelahan pada wajah mahasiswa dengan menganalisis fitur wajah, khususnya pada area mata dan mulut untuk menentukan tingkat kelelahan mahasiswa yang dikategorikan ke dalam tiga kondisi utama untuk mata, yaitu *active*, *unfocused*, dan *sleep*, serta 2 kondisi untuk mulut, yaitu *normal* dan *yawn*. Objek penelitian yang digunakan dalam penelitian ini diperoleh secara mandiri dari 22 subjek dalam bentuk video [105] yang menampilkan 4 kondisi, yaitu *active*, *unfocused*, *sleep*, dan *yawn* [19]. Kemudian video diekstrak dan didapatkan sebanyak 1886 *frame* untuk seluruh kondisi dari masing-masing subjek. Namun, tidak semua *frame* dapat digunakan. Oleh karena itu, dilakukan seleksi *frame* dengan menghilangkan *frame* yang tidak dapat digunakan atau tidak sesuai dengan kriteria kondisi, sehingga didapatkan 1802 *frame*. Selanjutnya, dilakukan proses deteksi fitur wajah serta seleksi kondisi mata dan mulut dari seluruh *frame* tersebut, dan menghasilkan total 2024 gambar fitur yang mewakili semua kondisi mata dan mulut, sebagaimana rangkaian proses ditunjukkan pada Gambar 3. 1. Gambar fitur yang diseleksi dan dideteksi merupakan gambar fitur yang sesuai karakteristik kondisi kelelahan pada fitur mata dan mulut. Objek penelitian ini menggunakan dataset primer yang didasari dengan kurangnya sumber data yang relevan dengan penelitian ini. Penggunaan dataset primer diharapkan dapat memenuhi kebutuhan akan variasi gambar, seperti keberagaman ras dan warna kulit, serta variasi pengambilan gambar sudut gambar dan pencahayaan, yang berpotensi mempengaruhi performa model [106]. Gambar yang diseleksi dan deteksi berformat .jpg, diperoleh dari hasil ekstrak video menjadi sekumpulan *frame* serta melalui metode seleksi dan deteksi yang dirancang khusus untuk penelitian ini.



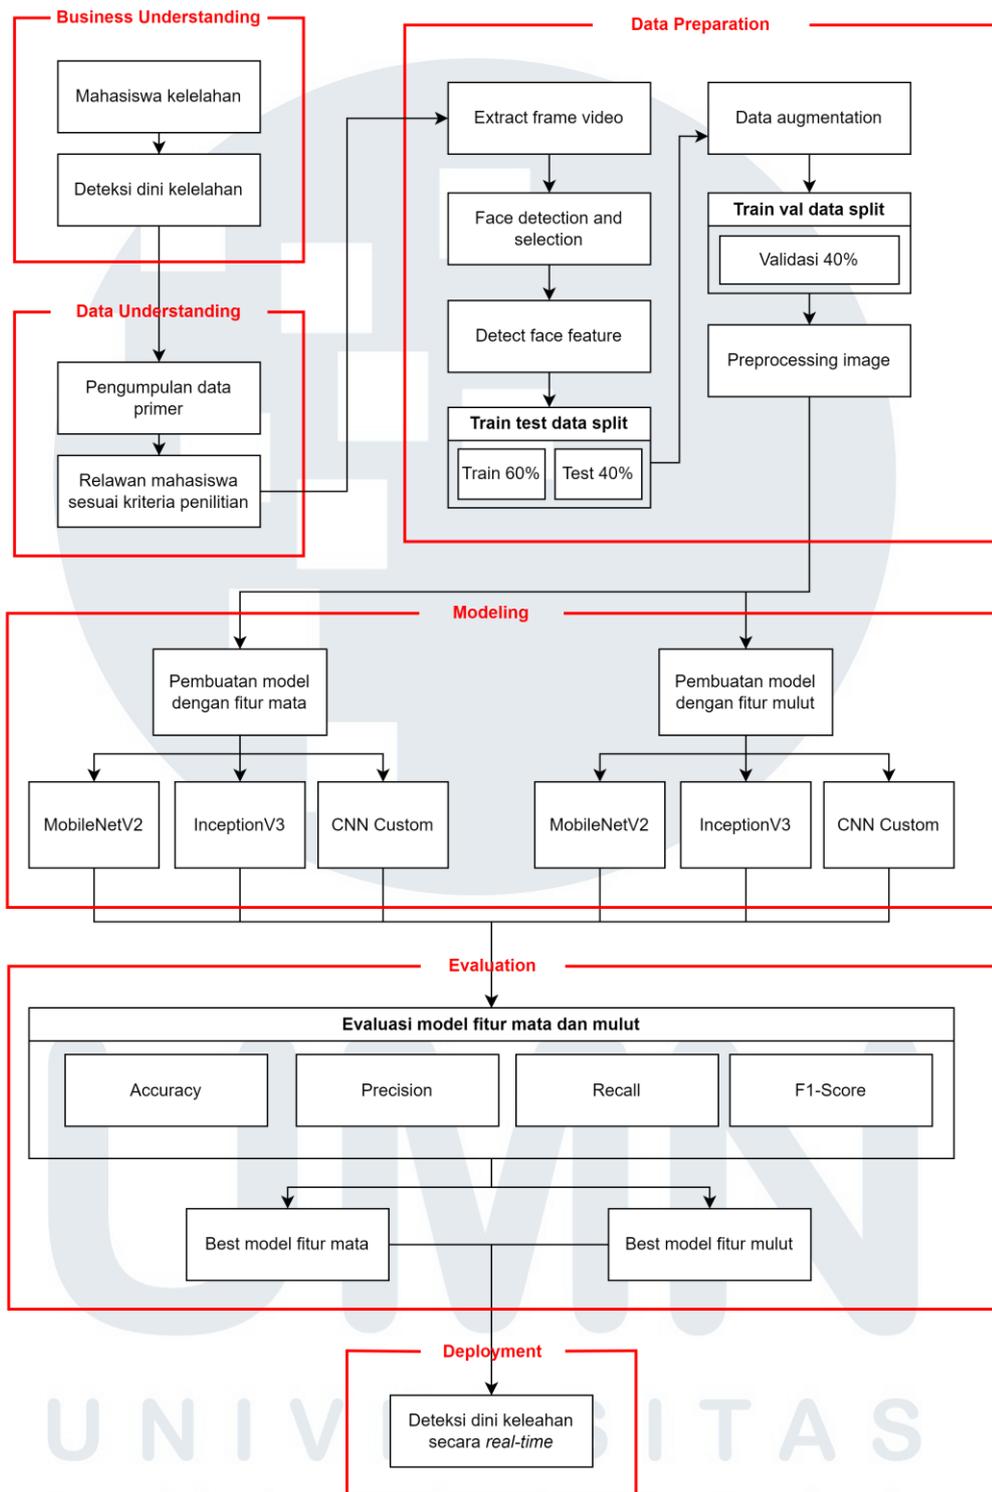
Gambar 3. 1 Proses seleksi dan deteksi fitur wajah dengan kondisi (a) *unfocused*, (b) *sleep*, (c) *active*, (d) *yawn*

3.2 Metode Penelitian

Penelitian ini menerapkan pendekatan kuantitatif dengan metode *data mining* seperti analisis data yang melibatkan perhitungan matematis, klasifikasi, serta pembuatan model untuk memperoleh pemahaman tentang kondisi kelelahan berdasarkan fitur wajah [107].

3.2.1 Alur Penelitian

Alur penelitian ini berperan sebagai acuan untuk memastikan bahwa proses penelitian berlangsung dengan teratur dan sistematis. Seperti yang digambarkan pada Gambar 3. 2, penelitian ini diawali dengan *business understanding*, yaitu mengidentifikasi sebuah permasalahan yang seringkali muncul dalam kehidupan mahasiswa, yaitu kelelahan. Identifikasi awal ini mengungkapkan bahwa, akhir-akhir ini mahasiswa sangat rentan mengalami stress hingga *academic burnout* [108], kondisi yang dapat mengakibatkan terganggunya kesehatan mental.



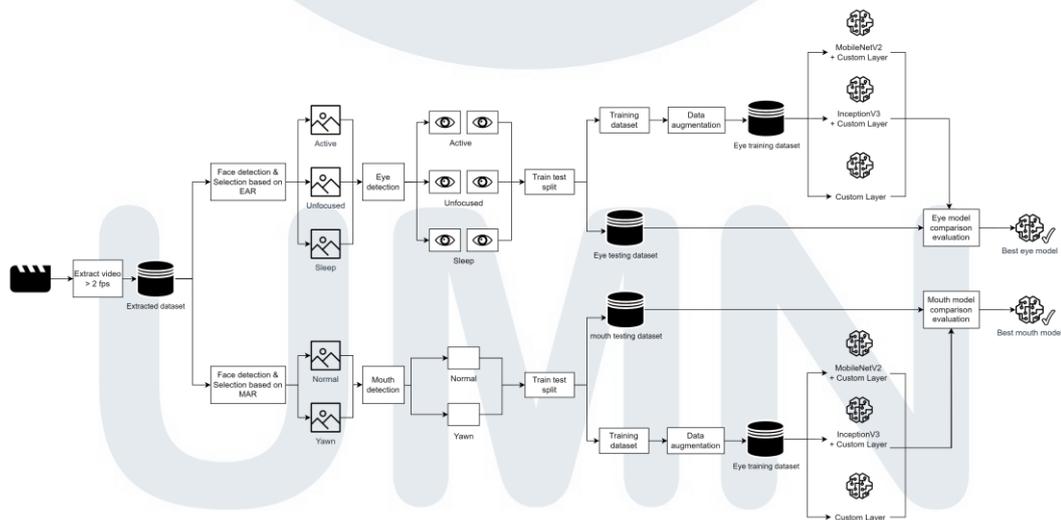
Gambar 3. 2 Alur penelitian

Fenomena tersebut kerap kali diawali dengan munculnya rasa lelah yang signifikan, meskipun begitu, para mahasiswa sering kali merasa bahwa tubuh mereka masih mampu untuk melanjutkan berbagai aktivitas, meskipun otak telah

memberikan sinyal ketidakmampuan karena kelelahan. Berdasarkan identifikasi permasalahan ini, penelitian ini menerapkan deteksi dini kelelahan yang didasarkan pada fitur wajah menggunakan RetinaFace dan CNN. Pendekatan ini memungkinkan untuk mengidentifikasi tanda-tanda awal kelelahan dengan cara yang efisien melalui analisis fitur wajah, yaitu kondisi mata dan mulut. Selanjutnya, dengan memanfaatkan proses *data mining* berdasarkan *framework* CRISP-DM (*Cross-Industry Standard Process for Data Mining*), penelitian ini berfokus pada pembuatan model serta implementasi model dengan menggabungkan kedua model untuk dapat mengidentifikasi tanda-tanda dini kelelahan. Berdasarkan kerangka proses CRISP-DM, keputusan selanjutnya yang dilakukan adalah pengumpulan data primer berupa video yang mendukung pengembangan model, yaitu wajah relawan mahasiswa dengan kriteria tertentu, memasuki tahap *data preparation*, data mentah akan diproses dengan melakukan ekstraksi frame video, lalu menjalankan proses deteksi dan seleksi pada setiap frame, mendeteksi titik koordinat fitur wajah serta membagi data menjadi dua dataset untuk mata dan mulut, melakukan pembagian data *training* dan data *testing*, menerapkan teknik augmentasi data pada data *training*, melakukan pembagian data kembali untuk data validasi dari data *training*, serta mempersiapkan data agar dapat diproses oleh model. Pada tahap *modelling*, akan dibuat tiga model arsitektur CNN, yaitu MobileNetV2, InceptionV3, dan CNN Custom untuk model mata dan model mulut, setelah itu ketiga model akan dibandingkan pada tahap *evaluation* untuk mendapatkan model terbaik. Model terbaik yang didapatkan dari hasil evaluasi, diimplementasikan pada tahap *deployment* untuk proses deteksi kelelahan secara *real-time*.

Secara lebih rinci, proses pengolahan data dalam penelitian ini diilustrasikan melalui Gambar 3. 3, yang menunjukkan pembuatan model untuk klasifikasi kondisi mata dan kondisi mulut. Proses dimulai dengan melakukan deteksi serta seleksi kondisi mata dan mulut dari sebuah frame yang diambil dari hasil ekstrak video. Seleksi ini dilaksanakan dengan cara mendeteksi *landmark* wajah menggunakan Dlib, kemudian menghitung *Eye Aspect Ratio* (EAR) dan *Mouth Aspect Ratio* (MAR) untuk menentukan serta menyeleksi kondisi mata dan mulut, sehingga menghasilkan tiga kondisi untuk mata, yaitu *active*,

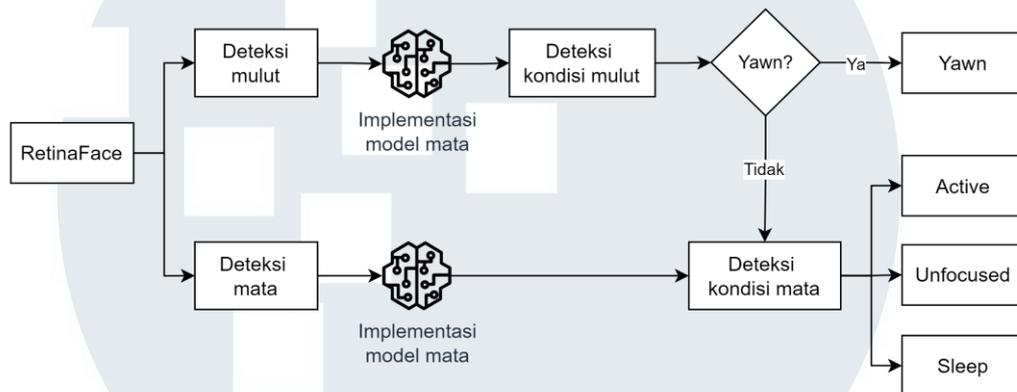
unfocused, dan *sleep*, serta 2 kondisi untuk mulut, yaitu normal dan *yawn*. Selanjutnya, proses deteksi dilakukan untuk mendeteksi lokasi mata dan mulut dengan RetinaFace sehingga *output* objek yang dihasilkan adalah gambar mata kanan-kiri dan gambar mulut. Dalam tahap pembuatan model, dilakukan perbandingan antara dua arsitektur CNN, yaitu InceptionV3 dan MobileNetV2. Kedua arsitektur tersebut kemudian dimodifikasi dengan menambahkan lapisan (*custom layer*) yang dirancang untuk meningkatkan kemampuan model dalam mengklasifikasikan kondisi mata dan mulut. Selain itu, CNN *custom layer* yang umum digunakan pada karakteristik dataset serupa juga diuji secara independen menggunakan data yang sama, agar hasilnya dapat dibandingkan dengan dua model lain yang telah dikembangkan. Setiap model akan dievaluasi berdasarkan *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi ini bertujuan untuk mengukur efektivitas model dalam mengklasifikasikan kondisi mata dan mulut dengan tepat. Setelah itu, model masuk ke tahap *deployment* untuk penggabungan kedua model.



Gambar 3. 3 Kerangka proses pengolahan data

Gambar 3. 4 adalah proses yang diterapkan dalam implementasi model. Proses ini diawali dengan penggunaan algoritma RetinaFace sebagai model deteksi *real-time* untuk mata dan mulut kanan-kiri. Model terbaik untuk mata dan mulut yang telah didapatkan pada proses sebelumnya, diimplementasikan pada *website*

yang digunakan ketika mulut atau mata telah berhasil dideteksi. Penggabungan kedua model dilakukan dengan cara, melakukan klasifikasi kondisi pada mulut terlebih dahulu, lalu jika kondisi *yawn* tidak terdeteksi, maka deteksi kondisi mata akan dilakukan. Proses ini memastikan bahwa *output* yang dihasilkan hanya meliputi 4 kondisi, yaitu *active*, *unfocused*, *sleep*, dan *yawn*.



Gambar 3. 4 Proses implementasi model

3.2.2 Metode Data Mining

Penelitian ini bertujuan untuk mengembangkan model deteksi dini kelelahan dengan memanfaatkan prinsip-prinsip ilmu pengolahan data melalui teknik *data mining*. Dalam proses ini terdapat beberapa metodologi kerja yang dapat diadopsi untuk pelaksanaan proses *data mining* secara efisien dan efektif, diantaranya *Cross-Industry Standard Process for Data Mining* (CRISP-DM) [109] dan *Knowledge Discovery in Database* (KDD) [110].

Tabel 3. 1 Perbandingan *Framework Data Mining*

Indikator	CRISP-DM	KDD
Tahapan	<ol style="list-style-type: none"> 1. <i>Business understanding</i> 2. <i>Data understanding</i> 3. <i>Data preparation</i> 4. <i>Modeling</i> 5. <i>Evaluation</i> 6. <i>Deployment</i> 	<ol style="list-style-type: none"> 1. <i>Data collection</i> 2. <i>Data preprocessing</i> 3. <i>Data reduction</i> 4. <i>Data mining</i> 5. <i>Interpretation and evaluation</i>
Fleksibilitas	Lebih terstruktur sehingga lebih mudah diimplementasikan dalam proyek data mining	Lebih fleksibel dan kurang terikat pada langkah tertentu
Kelebihan	1. CRISP-DM menyediakan langkah-langkah yang terstruktur dan jelas,	1. KDD membantu pengambilan keputusan berdasarkan data melalui identifikasi pola, tren,

	<p>sehingga memudahkan pelaksanaannya</p> <ol style="list-style-type: none"> 2. Berfokus pada tujuan bisnis, sehingga membuat hasil analisis data menjadi lebih relevan 3. Dapat diterapkan untuk berbagai jenis proyek analisis data 4. Pendekatan iteratif sehingga memungkinkan revisi setiap tahap untuk meningkatkan kualitas model 	<p>dan hubungan tersembunyi di dalam data</p> <ol style="list-style-type: none"> 2. Meningkatkan efisiensi melalui otomatisasi proses analisis data yang relevan secara berulang 3. Menghasilkan pengetahuan sebagai hasil akhir dari analisis data
Kekurangan	<ol style="list-style-type: none"> 1. Tidak menyediakan tahapan yang spesifik untuk mengelola <i>big data</i> 	<ol style="list-style-type: none"> 1. KDD dapat menimbulkan kesimpulan yang bias jika data tidak dipahami atau diolah dengan tepat 2. Membutuhkan penyimpanan sebelum dapat diproses 3. Tidak mencakup tahapan <i>deployment</i> sebagai bagian dari implementasi model 4. Data yang berlebihan dalam proses KDD dapat mengurangi kinerja sistem
Implementasi	Umum digunakan sebagai model proses yang memberikan panduan langkah demi langkah data mining	Umum digunakan sebagai konsep yang mencakup seluruh rangkaian untuk pengetahuan dari data

Berdasarkan perbandingan *framework* yang dilakukan pada Tabel 3. 1, terlihat bahwa kerangka kerja dari CRISP-DM dan KDD memiliki pendekatan, tahapan, dan tujuan implementasi yang berbeda dalam proses *data mining*. CRISP-DM dirancang sebagai *framework* yang komprehensif, meliputi seluruh proses dari pemahaman bisnis hingga *deployment* model, menjadikannya cocok untuk proyek yang bertujuan pada penerapan praktis model yang dikembangkan, Sedangkan *framework* KDD lebih terfokus pada ekstraksi pengetahuan, pencarian pola, dan informasi dari data, tanpa adanya tahapan khusus yang berfokus pada *deployment* model.

Penelitian ini memiliki tujuan untuk membentuk model deteksi dini kelelahan dan mengembangkan model tersebut dengan mengimplementasikan model untuk penggunaan nyata. Oleh karena itu, CRISP-DM menjadi *framework* yang paling sesuai. Hal ini didasarkan pada fitur CRISP-DM yang menyediakan pedoman yang jelas dan terstruktur untuk mengelola data,

termasuk *deployment* model, yang merupakan fokus dari penelitian ini. Melalui penggunaan CRISP-DM, diharapkan proses pembentukan dan penerapan model deteksi dini kelelahan dapat berjalan lebih efisien dan efektif. Berikut ini adalah penjelasan tahapan CRISP-DM secara rinci dalam penelitian ini,

a. *Business Understanding*

Tahapan awal dalam *framework* CRISP-DM pada penelitian ini adalah *Business Understanding*. Penelitian ini berfokus pada identifikasi salah satu masalah yang dihadapi oleh mahasiswa, yaitu kelelahan. Penelitian ini diawali oleh adanya dampak negatif dari kelelahan pada performa akademik mahasiswa, sehingga dipilihlah satu solusi untuk menangani hal tersebut dengan membuat sebuah model yang dapat mendeteksi dini tanda-tanda kelelahan. Model deteksi dini ini diharapkan dapat memberikan manfaat langsung dalam mencegah penurunan performa akademis akibat kelelahan, juga memberikan wawasan lebih lanjut bagi mahasiswa dan universitas. Hasil akhir deteksi ini dapat dijadikan *insight* bagi mahasiswa untuk menjadi lebih proaktif dalam mengelola kesehatan dengan menyadari kondisi tubuh yang sudah mulai lelah, serta pembuatan model deteksi kelelahan ini diharapkan menjadi fondasi di masa depan bagi universitas bagian *student support* yang berfokus pada pemantau kesejahteraan mahasiswa serta para pengembang aplikasi pendukung pembelajaran untuk mengembangkan model menjadi *website* atau fitur tambahan yang memungkinkan memonitor tanda-tanda dini kelelahan secara *real-time*, serta menyediakan sistem pengingat yang intuitif.

b. *Data Understanding*

Tahapan kedua CRISP-DM pada penelitian ini adalah *Data Understanding*, tahap ini melibatkan pengumpulan data dan eksplorasi untuk memahami struktur data. Penelitian ini menggunakan data primer yang disesuaikan dengan karakteristik penelitian. Data tersebut berupa rekaman video dari 22 relawan mahasiswa semester awal hingga akhir yang terdiri dari berbagai kampus di Jabodetabek dengan beragam jurusan yang

tidak ditentukan secara spesifik, masing-masing dari mereka menyumbangkan rekaman video yang merepresentasikan empat kondisi wajah berbeda, yaitu *active*, *unfocused*, *yawn*, dan *sleep*.

c. *Data Preparation*

Tahapan ketiga CRISP-DM dalam penelitian ini merupakan *Data Preparation*, sebuah tahapan yang memastikan data siap untuk analisis dan pembuatan model. Data yang digunakan dalam penelitian ini berupa video, yang memerlukan serangkaian proses transformasi dan modifikasi untuk dapat digunakan pada pembuatan model, sehingga dapat menghasilkan model deteksi dan klasifikasi yang akurat. Proses persiapan data pada penelitian ini melibatkan langkah-langkah berikut,

1) *Extract video to frame*

Tahap ini adalah langkah awal data video diekstrak menjadi *frame* individu dengan perhitungan dua *frame* per detik. Proses ini menghasilkan sekumpulan gambar yang merepresentasikan berbagai kondisi yang terekam dalam setiap video.

2) *Face Detection and Selection*

Frame yang dihasilkan setelah diekstrak perlu untuk seleksi sesuai dengan kondisi wajah. Sebelum melewati tahap seleksi, setiap *frame* akan dideteksi untuk menentukan keberadaan wajah dalam setiap *frame*. Setiap wajah yang dideteksi akan diseleksi dan disimpan sesuai dengan kondisi-nya, yaitu *active*, *unfocused*, *yawn*, dan *sleep*. Proses ini dilakukan dengan menggunakan Dlib untuk mendeteksi *landmark* dan menghitung titik koordinat mata kanan-kiri dengan *Eye Aspect Ratio* (EAR) dan mulut dengan *Mouth Aspect Ratio* (MAR). Setiap *frame* akan diseleksi sesuai dengan hasil perhitungan EAR dan MAR.

3) *Detect face feature*

Frame yang telah diseleksi sesuai dengan kondisi, perlu untuk di potong sesuai dengan fitur wajah yang diperlukan untuk penelitian,

yaitu mata kanan-kiri dan mulut. Proses ini dilakukan dengan RetinaFace dengan mengambil titik koordinat mata kanan-kiri dan mulut. Setelah titik koordinat ditemukan, akan dilakukan pemotongan fitur wajah sesuai dengan titik koordinat, dengan menambahkan *padding* untuk memastikan setiap gambar memiliki dimensi yang seragam yaitu, 224x224 piksel.

4) *Train-test data split*

Tahap selanjutnya adalah pembagian untuk data *training* dan data *testing*. Dataset mata dan mulut akan dipisahkan untuk keperluan pelatihan dan pengujian model. Data tersebut dibagi secara acak dengan persentase 60% untuk data *training* dan 40% untuk data *testing*. Pembagian ini bertujuan untuk menguji kinerja model pada data yang tidak pernah dilihat sebelumnya. Proses ini akan dilakukan secara manual dengan menggunakan fungsi `shutil.move`.

5) *Data augmentation*

Untuk meningkatkan variasi dataset pelatihan dan meningkatkan *robustness* model yang sudah terbukti pada beberapa penelitian [45] [111], teknik augmentasi data diterapkan pada gambar yang telah diproses. Proses ini melibatkan penerapan variasi pada gambar untuk memperkaya rentang kondisi yang dapat dikenali oleh model, seperti perubahan skala, rotasi, *zoom*, dan modifikasi pencahayaan, sehingga menghasilkan dataset yang lebih variatif dan mencakup banyak perspektif.

6) *Train-val data split*

Pada tahap ini, dataset *training* mata dan mulut yang telah diterapkan teknik augmentasi akan dipisahkan untuk keperluan evaluasi model. Dataset *training* dibagi secara acak dengan persentase 80% untuk data *training* dan 20% untuk data *validation*. Pembagian data ini dilakukan untuk mengukur kinerja model secara objektif sebelum diuji pada data *testing*. Hasil akhir pembagian serupa dengan berbagai pembagian data yang telah diterapkan pada penelitian terdahulu.

7) *Preprocessing Image*

Pada tahap ini, gambar yang telah dipersiapkan sebelumnya akan diolah agar dapat menjadi input model CNN. Pemrosesan ini meliputi, memastikan gambar memiliki 3 kanal warna (RGB) dan gambar telah berukuran 224x224 piksel, lalu mengubah gambar yang semula memiliki nilai piksel berupa integer, menjadi *array numpy* dengan tipe data float32. Label juga akan diubah menjadi bentuk *one-hot-encoding*.

d. *Modeling*

Tahapan ke-empat pada penelitian ini merupakan *Modeling*. Setelah melalui proses persiapan data, berbagai model dan algoritma akan diterapkan pada data tersebut. Pada penelitian ini, RetinaFace digunakan untuk mendeteksi fitur wajah dengan mengambil titik koordinat mata kanan-kiri dan mulut yang kemudian diubah kedalam bentuk *array* yang kompatibel dengan model CNN. Arsitektur model CNN yang ideal digunakan karena efisiensi dan keakuratannya dalam pengolahan citra adalah InceptionV3 dan MobileNetV2. Untuk meningkatkan akurasi dan performa, kedua arsitektur ini ditambahkan *custom layer* yang telah dirancang khusus dengan menyesuaikan jumlah neuron yang didapatkan melalui serangkaian uji coba iteratif untuk mendapatkan hasil yang optimal. Penelitian ini juga menguji CNN *custom layer* yang biasa digunakan pada dataset serupa dengan memodifikasi beberapa *layer* untuk menilai performa pada dataset penelitian ini.

Proses pemodelan dilakukan secara terpisah, untuk klasifikasi kondisi mata kanan-kiri dan untuk klasifikasi kondisi mulut. Hal tersebut dilakukan guna memastikan bahwa model dapat secara akurat mengidentifikasi dan membedakan antara berbagai kondisi kelelahan. Untuk pemodelan ini, dataset dibagi menjadi dua, 60% untuk *training* dan 40% untuk *testing*. Data *training* diimplementasikan teknik augmentasi data dan dipisahkan 20% untuk dialokasikan sebagai *validation*. Hasil akhir dari implementasi

tersebut, menghasilkan rasio pembagian dataset yang serupa pada penelitian terdahulu [32] [45]. Pembagian dataset ini diaplikasikan pada kedua model klasifikasi.

e. Evaluation

Tahapan kelima CRISP-DM pada penelitian ini adalah *Evaluation*. Tahapan ini mengevaluasi model yang telah diterapkan serta memastikan bahwa hasilnya sudah sesuai dengan tujuan penelitian. Dalam penelitian ini, evaluasi performa kedua model klasifikasi kondisi dilakukan dengan menggunakan pengukuran nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Penggunaan metrik ini merupakan pendekatan yang bertujuan untuk memberikan gambaran menyeluruh mengenai kualitas dan efektifitas model dalam mengklasifikasikan kondisi wajah berdasarkan perbedaan fitur. Semakin tinggi nilai yang diperoleh oleh masing-masing metrik, menunjukkan bahwa model memiliki kemampuan yang lebih baik dalam melakukan klasifikasi kondisi secara akurat. Evaluasi ini dilakukan untuk memastikan bahwa model tidak hanya bisa mengidentifikasi kondisi wajah, tetapi juga dapat melakukannya dengan presisi, minim kesalahan positif maupun negatif. Evaluasi dilakukan dengan menggunakan data *testing* yang telah di-*split* dalam proses pembagian data, ini memastikan bahwa model diuji dalam kondisi yang serupa dengan penggunaan nyata. Setelah evaluasi pada setiap model dilakukan, hasil dari evaluasi akan dibandingkan untuk menentukan kinerja dari masing-masing model. Model yang menunjukkan performa terbaik berdasarkan hasil evaluasi, akan dipilih untuk melanjutkan ke tahap *deployment*.

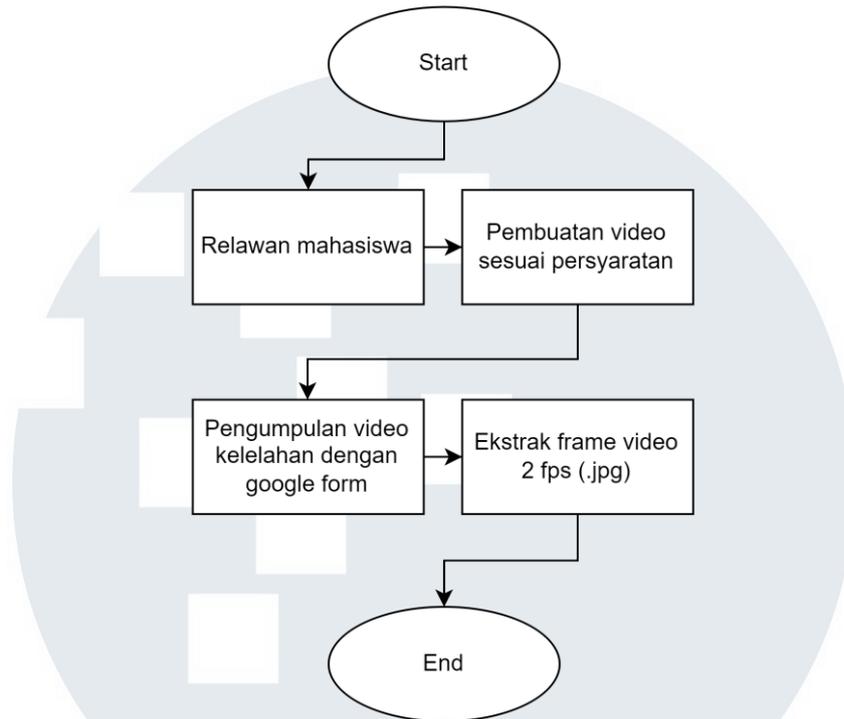
f. Deployment

Tahapan terakhir dalam penelitian ini adalah *Deployment*. Tahapan ini dilakukan apabila evaluasi model telah menghasilkan kesimpulan yang sesuai dengan kebutuhan penelitian. Tahapan ini menggabungkan kedua model menjadi satu dengan menambahkan kondisi untuk proses deteksi secara *real-time*. Hasil proses deteksi akan ditampilkan, ketika kondisi

terdeteksi selama 3 detik [106]. Tahap ini juga akan melakukan pengujian deteksi model dan mengevaluasi hasil proses deteksi dengan menerapkan deteksi *real-time* pada berbagai variasi situasi kondisi yang umum terjadi, yaitu dengan kacamata, tanpa kacamata, pencahayaan normal, pencahayaan kurang, dan variasi sudut pandang. Untuk lebih lanjut, model ini akan berpotensi maksimal ketika diintegrasikan sebagai *add-ons* atau fitur tambahan pada aplikasi yang sering digunakan oleh mahasiswa, seperti *E-learning*.

3.3 Teknik Pengumpulan Data

Penelitian ini menggunakan data berupa video yang dikumpulkan secara mandiri dari beberapa mahasiswa. Alur pengumpulan data dapat dilihat pada Gambar 3. 5. Pada proses pengumpulan data, dibutuhkan mahasiswa dengan berbagai karakteristik untuk mendapatkan dataset yang representatif serta untuk memastikan model deteksi kelelahan dapat bekerja dalam berbagai kondisi dan karakteristik mahasiswa. Karakteristik yang diperlukan adalah mahasiswa laki-laki dan perempuan, yang menggunakan kacamata serta yang tidak menggunakan kacamata, dan dari berbagai ras untuk memenuhi kebutuhan perbedaan warna kulit dan bentuk mata. Dalam pengambilan video, terdapat beberapa persyaratan yang perlu dipenuhi untuk memastikan data yang dikumpulkan sesuai dengan kebutuhan penelitian, yaitu pada saat pengambilan video untuk kondisi *unfocused*, dilakukan setelah beraktivitas atau saat merasa lelah, dan untuk kondisi *yawn* dilakukan senatural mungkin, meskipun tidak dapat dipastikan apakah semua kondisi terekam secara alami. Video diambil dengan cara mahasiswa duduk menghadap kamera depan perangkat mereka. Jarak pengambilan video, perangkat yang digunakan untuk pengambilan video, serta resolusi dari video tidak ditentukan, persyaratan yang fleksibel ini diberikan guna mendapatkan data video yang alami, serta pada tahap *modeling* orientasi gambar tidak akan mempengaruhi karena data yang digunakan hanya potongan gambar bagian mata dan mulut saja. Mahasiswa juga diharapkan menggunakan pakaian yang sopan, terutama jika wajah mereka bersedia dilampirkan dalam jurnal penelitian. Kemudian, data video dikumpulkan melalui *google form* yang telah disediakan.



Gambar 3. 5 Alur pengumpulan data

Video tersebut akan diekstrak kedalam bentuk *frame* dengan perhitungan dua *frame per second* karena informasi yang berdekatan hampir serupa serta untuk menghindari pemborosan kalkulasi dan efisiensi, sehingga menghasilkan sekumpulan data berupa gambar dengan format .jpg [106]. Selanjutnya, gambar akan melalui proses deteksi wajah serta seleksi kondisi dengan perhitungan *landmark* wajah menggunakan EAR dan MAR [5] untuk memastikan bahwa terdapat objek wajah pada gambar dan gambar telah terbagi sesuai dengan kondisi wajah yang ditentukan. Gambar kondisi wajah menjadi objek utama dalam proses analisis dan pembentukan model.

3.3.1 Populasi dan Sampel

Proses pengambilan data gambar pada penelitian ini menggunakan metode *purposive sampling*. *Purposive Sampling* merupakan teknik pengambilan sampel dengan karakteristik yang disesuaikan dengan tujuan yang relevan dengan penelitian [112]. Alasan pengambilan sampel secara *purposive* karena pencocokan sampel yang lebih baik dan sesuai dengan maksud dan

tujuan penelitian [113]. Sampel penelitian ini adalah gambar wajah mahasiswa dengan kondisi mata *active, unfocused, sleep*, serta dengan kondisi mulut normal dan *yawn*. Sampel video yang digunakan sebanyak 88 dari 22 mahasiswa yang mengumpulkan masing-masing 4 video dengan representasi 4 kondisi yang dibutuhkan.

3.3.2 Periode Pengambilan Data

Proses pengumpulan data video dari para mahasiswa dilakukan sejak 7 Januari 2024 hingga 30 Januari 2024, tidak ada alasan spesifik terkait dengan waktu pengambilan data, lamanya pengambilan data dikarenakan alasan waktu pengerjaan penelitian, serta pengambilan data dilakukan dengan menggunakan metode observasi, sehingga dapat dipastikan bahwa data yang digunakan dalam penelitian ini adalah terkini dan belum pernah digunakan dalam studi manapun sebelumnya. Dataset video yang original memastikan keunikan dataset, sehingga menjadi faktor penting dalam kebaruan dari penelitian ini.

3.4 Implementasi Metode

Penelitian ini menggunakan CRISP-DM dengan algoritma *deep learning* untuk membangun model deteksi dini kelelahan mahasiswa. Algoritma yang dipilih pada penelitian ini adalah model dari arsitektur CNN, yaitu InceptionV3 dan MobileNetV2 dengan penambahan *custom layer*, serta CNN *custom layer* yang telah terbukti efektif pada dataset dengan karakteristik serupa. Dalam proses analisis dan pengolahan data, penelitian ini memanfaatkan bahasa pemrograman Python dalam *environment* Jupyter yang disediakan oleh *tools* Anaconda – Jupyter Labs.

Pada proses analisis data dan pengembangan model dapat dilakukan dengan bahasa pemrograman yang umum digunakan, yaitu Python dan R. Kedua bahasa pemrograman ini memiliki keunggulan masing-masing. Tabel 3. 2 adalah perbandingan antara bahasa pemrograman Python dan R [114], [115].

Tabel 3. 2 Perbandingan Python dan R

Indikator	Python	R
Definisi	Bahasa pemrograman tingkat tinggi yang interaktif dan berorientasi pada objek, serta terdiri dari berbagai <i>library</i> .	Bahasa pemrograman untuk pengolahan data secara statistik dan visualisasi data, serta terdiri dari berbagai <i>package</i> .
Lisensi	Python <i>Software Foundation Licence</i> , lisensi <i>open-source</i> yang kompatibel dengan GPL.	GNU <i>General Public Licence</i> , lisensi <i>open-source</i> yang memungkinkan penggunaan dan modifikasi gratis.
Kegunaan	Digunakan untuk pengembangan web, otomasi, pengembangan <i>software</i> , AI, <i>Machine Learning</i> , dan <i>Deep Learning</i> .	Digunakan untuk analisis statistik, model prediktif, dan visualisasi data.
Kelebihan	<ol style="list-style-type: none"> 1. Sintak untuk <i>coding</i> yang <i>simple</i> dan mudah 2. Dapat digunakan diberbagai macam keperluan dari pengolahan hingga pengembangan <i>web</i> 3. Kode yang lebih sederhana karena memiliki banyak <i>Library</i> 4. Fleksibel 	<ol style="list-style-type: none"> 1. Spesialisasi analisis data dan statistik 2. Memiliki banyak <i>Package</i>, sehingga kode lebih mudah digunakan
Kekurangan	<ol style="list-style-type: none"> 1. Terdapat dependensi pada beberapa <i>Library</i> 2. Kurang spesifik untuk analisis statistik dibandingkan R 	<ol style="list-style-type: none"> 1. R lebih sulit dipahami bagi pemula 2. Lebih sedikit pilihan untuk pengembangan <i>web</i> dan GUI

Berdasarkan perbandingan tersebut, dapat ditarik kesimpulan bahwa kedua bahasa pemrograman memiliki keunggulan masing-masing diarea tertentu. Python memiliki kegunaan yang beragam dan fleksibel, sedangkan R berfokus kepada perhitungan statistik. Oleh karena itu, bahasa pemrograman Python terpilih sebagai bahasa pemrograman pada penelitian ini. Pemilihan ini didasari karena kegunaannya yang beragam dan fleksibel, serta mendukung untuk *scripting*, pengolahan data, pengembangan model, hingga *deployment* model.

UNIVERSITAS
MULTIMEDIA
NUSANTARA