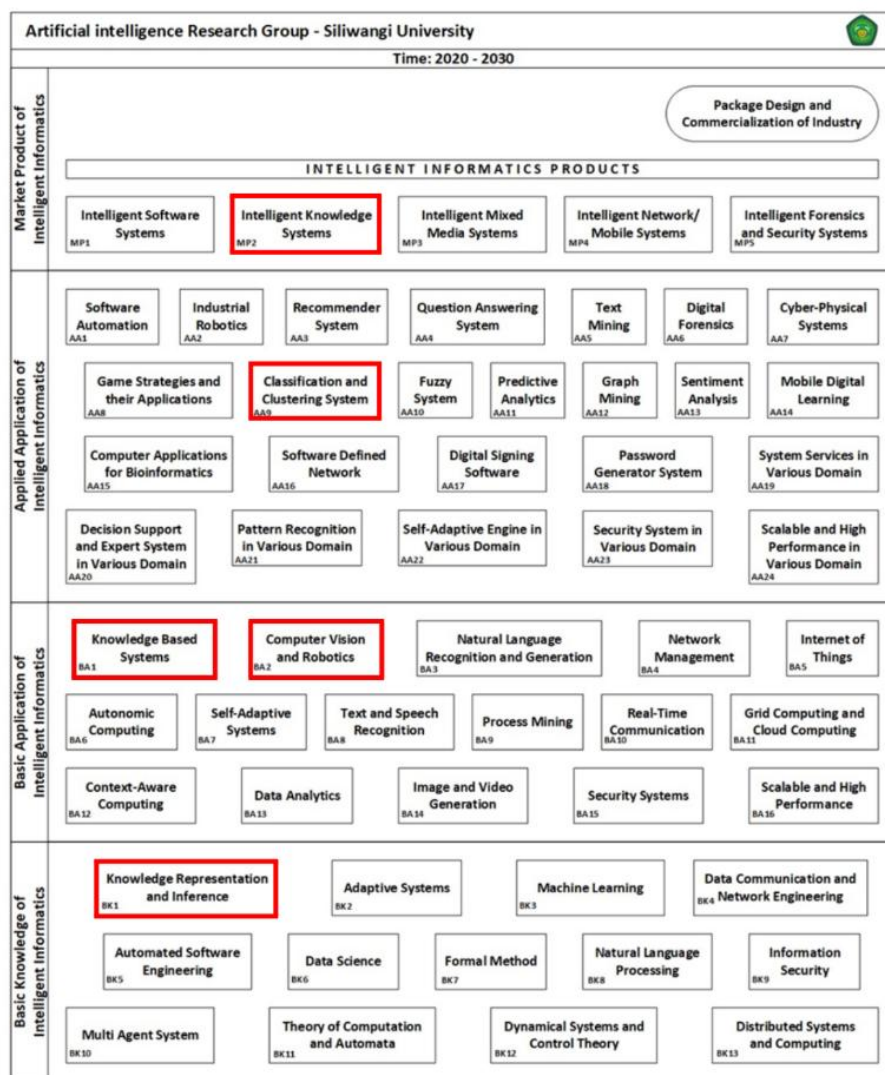


BAB III METODOLOGI

3.1. Peta Jalan Penelitian

Roadmap Penelitian pada Gambar 3.1 yang digunakan merujuk pada *Roadmap Artificial Intelligence Research Group Universitas Siliwangi Tahun 2020-2030*.



Gambar 3.1. Roadmap dan Kontribusi terhadap Penelitian AIS (AIS Universitas Siliwangi, 2024)

Roadmap tersebut disusun dalam kolaborasi antara Kelompok Keahlian (KK) di Jurusan Informatika Universitas Siliwangi, yaitu Kelompok Keahlian Informatika dan Sistem Inteligen (ISI), dengan Kelompok Keahlian Jaringan, Keamanan, dan Digital Forensik (JKF). Arah penelitian kecerdasan buatan melalui kolaborasi tersebut telah disusun dengan sistematis, komprehensif dan berkesinambungan untuk periode tahun 2020 hingga 2030. Penelitian ini berkaitan dengan area pengembangan yang menggambarkan teknologi *Artificial Intelligence* dari konsep dasar hingga tahap *Market Product* yang ditunjukkan pada Gambar 3.1.

Pada bagian *Basic Knowledge of Intelligent Informatics*, berhubungan dengan bidang *Knowledge Representation and Inference*. Hal ini disebabkan oleh penggunaan *Transfer Learning* dan *Attention Mechanism* yang secara fundamental merupakan representasi pengetahuan suatu model. Penelitian ini menerapkan *Transfer Learning* dan *Dual Block Attention Mechanism* pada objek penelitian yaitu bentuk wajah.

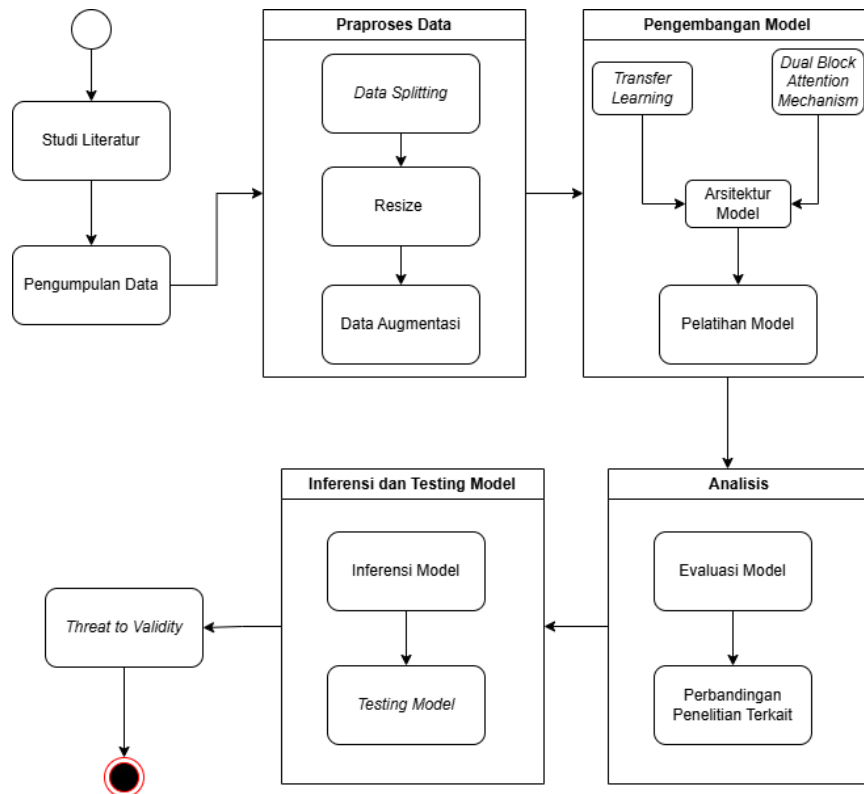
Pada *Basic Application of Intelligent Informatics*, penelitian ini berkontribusi pada *Knowledge Based Systems* dan *Computer Vision and Robotics*. Model yang dikembangkan bekerja sebagai dasar pembentukan pengetahuan dan keputusan pada representasi fitur hasil ekstrasi CNN pralatih. Penelitian ini menghasilkan sebuah sistem berbasis pengetahuan yang dapat diterapkan ke perangkat *edge* untuk melakukan klasifikasi gambar sehingga dapat dikaitkan dengan bagian *Computer Vision and Robotics*.

Bagian *Applied Application of Intelligent Informatics* termasuk ke dalam kategori *Classification and Clustering System* ditunjukkan dari hasil klasifikasi bentuk wajah yang diaplikasikan pada inferensi model. Implementasi yang dibangun pada penelitian ini adalah *website* sederhana yang menunjukkan hasil klasifikasi dan rekomendasi kacamata. Bagian *Market Product of Intelligent Informatics* termasuk ke dalam kategori *Intelligent Knowledge Systems*. Kategori tersebut diambil dari pendekatan rekomendasi untuk bingkai kacamata menggunakan *rule based approach* berdasarkan hasil klasifikasi bentuk wajah.

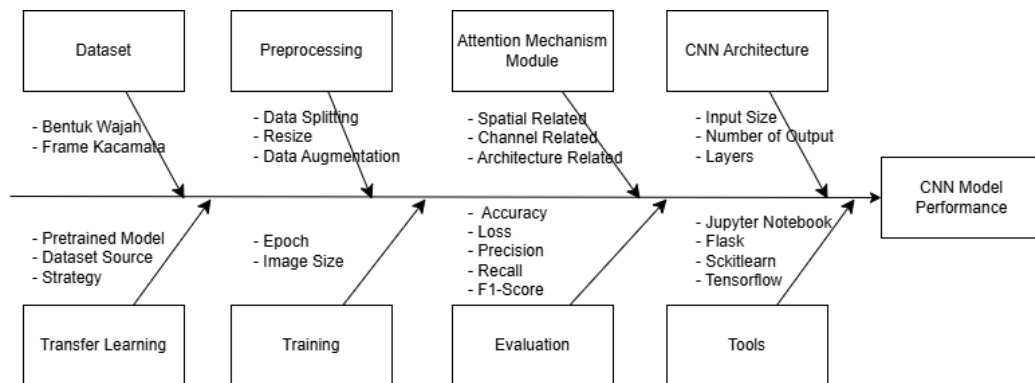
3.2. Tahapan Penelitian

Penelitian ini bertujuan untuk membangun model yang mampu melakukan klasifikasi bentuk wajah dan memberikan hasil akhir berupa rekomendasi *frame* kacamata yang sesuai berdasarkan hasil klasifikasi bentuk gambar. Tahapan penelitian ini menggunakan *machine learning workflow* yang dimodifikasi dari sisi pengembangan model dan penambahan pada tahap inferensi model (DeHart dkk., 2021). Rangkaian tahapan penelitian yang akan dilakukan ada dalam Gambar 3.2.

Komponen-komponen penting pada penelitian ini dapat dilihat di Gambar 3.3 sebagai diagram *fishbone*. Diagram *fishbone* tersebut menunjukkan faktor utama dan faktor turunan untuk mencapai target penelitian. Komponen utama dalam penelitian ini terdiri dari *dataset, preprocessing, attention mechanism module, CNN architecture, tools, evaluation, training, dan transfer learning*. Komponen tersebut menunjukkan faktor utama untuk mencapai keberhasilan penelitian ini. Selain itu, pendukung dari komponen utama, yaitu komponen turunan yang menjelaskan komponen utama secara lebih detail (Madić M & Radovanović M, 2012).



Gambar 3.2. Tahapan Penelitian



Gambar 3.3. Fishbone Diagram

3.2.1. Studi Literatur

Tahapan yang pertama adalah studi literatur. Tahapan ini merupakan proses untuk mengumpulkan, membaca, dan menganalisis literatur ilmiah. Tujuannya adalah untuk memahami landasan konsep atau konsep teori, menelusuri penelitian

terdahulu, dan mengidentifikasi *gap research* yang akan menjadi dasar perumusan penelitian ini. Gambaran penelitian dapat dipahami secara menyeluruh terhadap ruang lingkup permasalahan dan menetapkan arah metodologi yang tepat.

3.2.2. Pengumpulan Data

Tahapan selanjutnya adalah pengumpulan data yang dapat digunakan sebagai dasar pengembangan dan pengujian model. Data yang digunakan pada penelitian ini terdiri dari kumpulan gambar yang berisi sorotan berbagai bentuk wajah yang didapatkan dari *platform* penyedia *dataset public* yang sering digunakan untuk penelitian yaitu *Kaggle* (Niten Lama, 2020). Penelitian ini akan menunjukkan rekomendasi dari bingkai kacamata sehingga dataset yang kedua adalah dataset yang berisi *frame* kacamata yang didapatkan dari *Peep Optic Tasikmalaya* yang terdiri dari *Oval Frame*, *Cat-Eye Frame*, *Circle Frame*, *Square Frame*, *Aviator Frame*, dan *Oversized Frame* (Optik PEEP, 2026).

3.2.3. Praproses Data

Praproses data adalah tahapan yang dilakukan untuk menyiapkan dataset sebelum masuk ke proses pelatihan dan evaluasi model. Tahapan ini dilakukan melalui beberapa langkah yaitu *data splitting*, *resize*, serta data augmentasi.

1. *Data Splitting*

Tahapan *data splitting* pada praproses dilakukan dengan membagi dataset menjadi *data training*, *data validation*, dan *data testing* sesuai rasio pembagian yang diperlukan. Rasio skema 80:20 adalah pembagian yang umum digunakan sebelum *training data* sebagai standar pembagian data pada sebagian besar kasus.

Data splitting yang akan dilakukan pada penelitian ini adalah menggunakan skema 80:20, pada konteks klasifikasi gambar pada CNN skema yang digunakan adalah 80% untuk *data training*, 10% untuk *data testing*, dan 10% untuk *data validation* (Bichri dkk., 2024).

2. *Resize*

Dataset gambar yang digunakan dapat terdiri dari bermacam-macam resolusi sehingga tahapan ini melakukan *resize* untuk menyeragamakan ukuran resolusi. Selain itu, *resize* dilakukan unruk mempercepat proses komputasi agar mencapai konvergensi lebih cepat dan mengurangi *noise* terhadap gambar. *Noise* pada citra wajah biasanya ditandai dengan adanya bintik dan blur yang memiliki ukuran besar pada gambar yang mengakibatkan komputasi semakin berat. Sehingga pada tahapan ini, *resize* melakukan penyeragaman menjadi resolusi 128 x 128 yang dipilih sebagai kompromi antara efisiensi komputasi dan mempertahankan informasi yang penting. Penggunaan resolusi tersebut memungkinkan proses komputasi berjalan dengan waktu yang jauh lebih cepat dibandingkan dengan resolusi standar (Fitria dkk., 2025; Pitaloka dkk., 2017).

3. Data Augmentasi

Permasalahan penelitian ini adalah keterbatasan jumlah dan variasi data sehingga diperlukan pendekatan agar model dapat memahami kondisi visual terhadap dunia nyata. Data augmentasi dilakukan dengan memberikan transformasi seperti *flip*, kontras dan kecerahan yang digunakan untuk menciptakan data baru yang bervariasi (Kumar dkk., 2025).

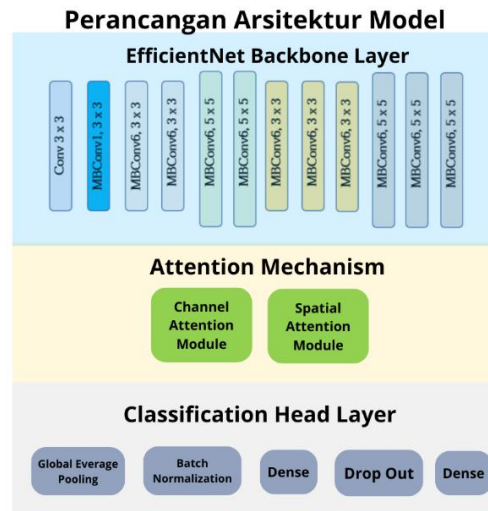
Data augmentasi hanya diterapkan khusus untuk *data training*. Tujuannya adalah untuk mengantisipasi *data leakage* agar informasi dari data *testing* tidak diketahui oleh model pada saat proses pelatihan model untuk menjaga keadilan dalam hasil evaluasi model. Data augmentasi tidak mengubah rasio pembagian data 80:10:10 secara eksplisit karena proses data augmentasi dilakukan secara *on the fly*, yaitu teknik yang dilakukan secara dinamis tanpa menyimpan data gambar secara permanen pada jumlah sampel asli. Di sisi lain, dataset validasi dan pengujian tetap tidak diubah untuk memastikan bahwa evaluasi kinerja secara akurat mencerminkan kondisi data dunia nyata (Ricky Putra Sardika & Widhiarso, 2025).

3.2.4. Pengembangan Model

Proses pengembangan model pada penelitian ini adalah menggunakan *Deep Learning* yang dimodifikasi dengan *Transfer Learning* dan *Attention Mechanism* dengan arsitektur *EfficientNet*. Tahapan pada pengembangan model diawali dengan memanfaatkan *pre-trained* yang telah dilatih menggunakan *dataset ImageNet-1K* yang digunakan sebagai dataset standar *pretraining* CNN. Sehingga, model *pre-trained* tersebut akan menghasilkan fitur-fitur awal sebagai pengetahuan dasar untuk mempelajari pola visual pada bentuk objek secara umum.

Selanjutnya akan dilakukan penambahan *attention module* pada model yang digunakan sebagai penyempurna performa *EfficientNet* yang akan memberikan penekanan pada fitur-fitur yang dianggap penting. Penambahan dilakukan setelah *back bone layer* dari *EfficientNet* dan sebelum *classification head layer* seperti yang ditunjukkan pada Gambar 3.4 sehingga ekstrasi fitur yang dihasilkan dari fungsi

backbone dapat diperkuat oleh *attention module* sehingga model yang akan semakin paham berdasarkan dataset sesuai prediksi kelasnya.



Gambar 3.4. Posisi Penambahan *Attention Module* pada Arsitektur Model (Modifikasi dari (Tan & Le, 2020))

Model *EfficientNet* memiliki *Attention Mechanism* bawaan sebagai *channel attention* yaitu *Squeeze and Excitation* (SE) pada layer MBConv (*Mobile Inverted Bottleneck Convolution*) sehingga upaya dalam memaksimalkan kinerja model, *channel attention* perlu dilengkapi dengan *spatial attention*. *Channel attention* akan berfokus kepada fitur mana yang penting dan dapat mengabaikan gangguan yang kemungkinan terjadi di input gambar. Sedangkan, *spatial attention* berfokus pada informasi lokasi mana yang penting dan melemahkan fokus terhadap area yang tidak relevan dalam memberikan informasi. Sehingga, model dapat menyoroti informasi mana yang penting dan kurang penting dengan pemahaman pada fitur penting di area penting untuk meningkatkan performa segmentasi (R. Liu dkk., 2025).

Dalam pelatihan model ada beberapa penerapan *training configuration* yang digunakan pada penelitian ini seperti *epoch*, *learning rate*, dan penerapan *callback*, ditunjukkan pada Tabel 3.1. Penentuan *training configuration* disesuaikan dengan penelitian sebelumnya yang telah dilakukan oleh (Fitria dkk., 2025) dengan penggunaan dataset yang serupa.

Tabel 3.1. *Training Configuration* Pelatihan Model

Konfigurasi	Nilai
<i>Epochs</i>	30
<i>Learning Rate</i>	0.0001
Fungsi Aktivasi	<i>Softmax</i>
<i>Callback</i>	<i>Early Stopping, ReduceLRonPlateau</i>

Epoch menunjukkan berapa kali penggunaan pengulangan *data training* oleh model selama proses pelatihan. Satu *epoch* adalah satu siklus penuh yang digunakan sekali untuk melatih model dengan menggunakan seluruh dataset pelatihan. Selain itu, *Learning rate* digunakan untuk menentukan seberapa besar bobot model diubah selama pelatihan. Nilai *learning rate* yang rendah dapat menyebabkan pelatihan menjadi lebih lambat, sementara laju pembelajaran yang tinggi dapat menyebabkan model melampaui bobot idealnya (Iiduka, 2020).

Permasalahan pada umumnya terjadi pada tahap tengah hingga akhir *training*. Ketika kinerja validasi tidak menunjukkan kecenderungan yang stagnan akibat *learning rate* yang sudah tidak sesuai. Oleh karena itu, proses pelatihan model dapat ditingkatkan menggunakan mekanisme *ReduceLRonPlateau* dan *Early Stopping*. *ReduceLRonPlateau* akan menurunkan *learning rate* disaat kinerja dari model mulai melambat dan stagnan pada *validation loss*. Sedangkan *Early Stopping* digunakan untuk menghindari *overfitting* dengan menghentikan proses pelatihan

ketika model tidak mengalami peningkatan kinerja yang signifikan di *validation loss* (Mahesh et al, 2024).

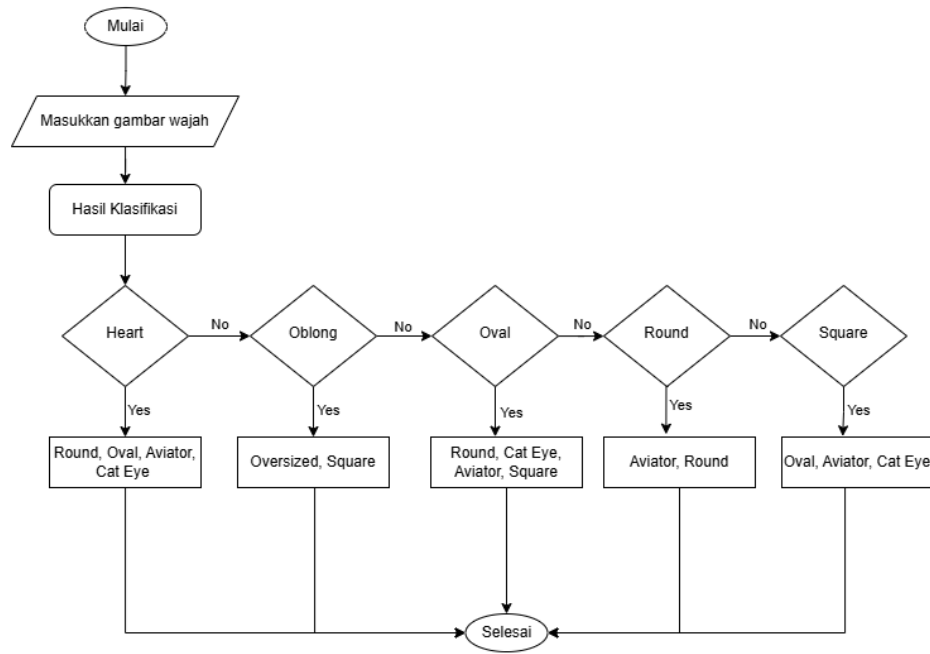
3.2.5. Analisis Model

Setelah melakukan *training data*, hasil model akan dievaluasi menggunakan berbagai metrik, seperti akurasi, *precision*, *recall*, dan *F1-Score*. Akurasi memiliki kelebihan dengan memberikan penjelasan yang mudah dimengerti tentang kinerja keseluruhan model. *Precision* digunakan untuk mengevaluasi ketepatan dalam memprediksi kelas positif, sehingga ideal digunakan dalam situasi dengan kesalahan positif yang harus diminimalkan. *Recall* unggul dalam menilai sejauh mana model dapat mengidentifikasi semua data positif. *F1-score* menggabungkan *precision* dan *recall* menjadi satu nilai yang seimbang menilai kinerja model ketika data memiliki distribusi kelas yang tidak seimbang (Miller dkk., 2024b). Evaluasi model dilakukan untuk menganalisis model yang sudah dilatih, mengetahui pengaruh dari *dual block attention mechanism*, dan membandingkan performa model dengan penelitian sebelumnya.

3.2.6. Inferensi dan *Testing Model*

Inferensi yang dilakukan dengan model yang sudah dilatih akan menghasilkan sebuah prediksi dengan hasil berupa klasifikasi dan rekomendasi. Rekomendasi dilakukan menggunakan *Rule Based Approach* (Masri dkk., 2019) dari hasil prediksi bentuk wajah. Pendekatan tersebut dilakukan secara teratur berdasarkan bentuk objek yang sesuai. Secara *output*, gambar sebagai *input* akan ditunjukkan kembali dengan memperlihatkan hasil klasifikasi yang sesuai. Jika klasifikasi objek sudah dilakukan, maka hasil dari rekomendasi akan diperlihatkan.

Gambar 3.5. menunjukkan *flowchart* untuk *Rule Based Approach* pada rekomendasi kacamata.



Gambar 3.5. *Flowchart* untuk *Rule Based Approach*

Inferensi model berbentuk *website* sederhana yang dibangun menggunakan *framework Flask* versi 3.0.3 dan *Python* versi 3.10.7 dengan *front-end* menggunakan *Bootstrap*. Perangkat lunak yang digunakan dengan spesifikasi yang terdiri dari Intel Core i3-1005G1, Intel UHD Graphics G1, RAM 4 GB.

Setelah membangun inferensi model, dilakukan percobaan dengan melakukan prediksi menggunakan gambar *testing* yang sama pada penelitian (Ramadhan dkk., 2024; Wicakson dkk., 2025). Selain itu, percobaan dilakukan dengan menggunakan gambar dengan wajah yang sama namun dengan kondisi yang bervariasi. Testing model ini berbeda dengan evaluasi model karena testing model menghasilkan *confidence* yang menunjukkan hasil klasifikasi dari gambar luar data latih.

3.2.7. *Threat To Validity*

Langkah selanjutnya adalah melakukan analisis validasi terhadap hasil eksperimen yang telah dilakukan. Analisis bertujuan untuk memahami dan mengidentifikasi hasil yang sudah dilakukan dari pengumpulan data sampai pengembangan model. Analisis validasi dilakukan dengan menggunakan *threat to validity*.

Threats to validity merupakan elemen-elemen yang dapat mempengaruhi ketepatan atau keakuratan berdasarkan hasil penelitian. Di dalam *Convolution Neural Network* khususnya model pada *EfficientNet*, *threats to validity* berasal dari berbagai faktor, seperti *internal validity*, *construct validity*, *conclusion validity*, dan *external validity* (Sjøberg & Bergersen, 2023; Slocum dkk., 2022).