

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Tinjauan Pustaka**

##### **2.1.1 Luka Luar**

Luka adalah terputusnya kontinuitas jaringan oleh karena adanya cedera atau proses pembedahan (Sriwiyati dkk., 2020). Menurut ilmu kesehatan, luka dapat dikategorikan ke dalam berbagai jenis berdasarkan sejumlah indikator, termasuk kondisi fisik luka (tampilan), durasi penyembuhan, penyebab, jenis benda yang menyebabkan luka, kedalaman luka, dan sebagainya. Pada penelitian ini, kategori luka yang akan dijadikan sampel data adalah yang didasarkan pada kondisi fisik atau tampilan luka. Jenis-jenis luka yang akan digunakan pada penelitian ini adalah sebagai berikut:

##### **a. *Abrasions* (Luka Lecet)**

*Abrasions* atau luka lecet adalah cedera kulit dangkal yang terjadi akibat gesekan antara kulit dan permukaan kasar atau benda keras, sehingga lapisan epidermis terkikis tanpa penetrasi ke lapisan lebih dalam yang ditandai dengan perdarahan minimal, rasa nyeri atau perih, keluarnya cairan bening atau sedikit darah, dan risiko infeksi jika tidak dibersihkan dengan baik (Limpat Wihastyoko dkk., 2024).

##### **b. *Bruises* (Luka Memar)**

*Bruises* atau luka memar adalah cedera tertutup di mana pembuluh darah kecil di bawah kulit pecah akibat benturan benda tumpul, tanpa merusak lapisan kulit.

Darah yang merembes ke jaringan subkutan menyebabkan perubahan warna kulit misalnya ungu atau biru, bengkak, dan nyeri (Riset dkk., 2024).

**c. Burns (Luka Bakar)**

*Burns* atau luka bakar adalah cedera pada kulit dan jaringan di bawahnya akibat panas, bahan kimia, listrik, radiasi, atau gesekan, yang merusak integritas kulit dan menimbulkan gangguan fisiologis. Karakteristiknya meliputi kedalaman yang bervariasi dari *superficial* hingga *full thickness*, perubahan warna kulit seperti kemerahan, lepuh, atau menghitam, nyeri terutama pada luka dangkal, serta risiko komplikasi seperti infeksi, kehilangan cairan, kontraktur, dan parut (Saputra, 2023).

**d. Cut (Luka Sayat)**

*Cut* atau luka sayat adalah luka dengan tepi potong bersih yang berisiko jika cukup dalam hingga memotong pembuluh darah besar. Ciri khasnya meliputi tepi tajam, kemungkinan terbuka lebar, dan sering ditemukan bersamaan dengan cedera lain seperti memar atau luka pembela (*defensive wounds*) (Ul Hoq Chowdury dkk., 2023).

**e. Laceration (Luka Robek)**

*Laceration* atau luka robek adalah cedera terbuka pada kulit dan jaringan di bawahnya yang terjadi akibat trauma tumpul atau tekanan kuat, sehingga tepi luka tampak tidak teratur dan bergelombang. Luka ini biasanya menimbulkan perdarahan yang bervariasi sesuai kedalaman cedera, rasa nyeri terutama bila saraf atau jaringan sensitif terlibat, serta risiko infeksi lebih tinggi dibanding luka sayat (Colio dkk., 2025).

#### **f. *Stab Wound* (Luka Tusuk)**

*Stab Wound* atau luka tusuk terjadi ketika benda tajam atau runcing menembus tubuh sehingga kedalaman luka lebih besar daripada panjang luka di permukaan, dan sering berpotensi mengenai organ dalam atau struktur vital. Tepi luka cenderung rapi/bersih karena penetrasi oleh benda tajam, berbeda dengan luka akibat benturan ataupun robekan (Hendri Meirialdi dkk., 2025).

#### **2.1.2 Klasifikasi Citra Digital**

Klasifikasi citra digital merupakan proses yang melibatkan pengelompokan piksel atau elemen gambar dalam sebuah citra ke dalam berbagai kategori. Setiap kategori ini mewakili suatu entitas dengan karakteristik spesifik, sehingga dapat dikenali dengan mudah (Herdiansah dkk., 2022). Klasifikasi citra digital memberikan kemampuan kepada komputer untuk meniru cara manusia dalam memahami informasi visual, seperti mengenali objek, pola, atau tulisan tangan dalam gambar. Dengan metode ini, komputer dapat mengenali dan membedakan berbagai elemen dalam citra, sama seperti yang dilakukan oleh penglihatan manusia (A'ayunnisa dkk., 2022). Proses klasifikasi citra mencakup beberapa langkah, yaitu *preprocessing*, ekstraksi fitur, dan pemilihan model klasifikasi yang menggunakan *Machine Learning* atau *Deep Learning*. Setelah model dilatih, evaluasi dilakukan dengan menggunakan metrik seperti akurasi, *F1-Score*, dan metrik lainnya (Nugroho dkk., 2021). Teknik ini diterapkan di berbagai bidang, salah satunya adalah dalam diagnosis medis.

### 2.1.3 *Convolutional Neural Network (CNN)*

*Convolutional Neural Network (CNN)* merupakan salah satu tipe jaringan saraf yang digunakan untuk pengenalan dan klasifikasi gambar. CNN dapat secara otomatis mempelajari hierarki fitur dari gambar tanpa memerlukan ekstraksi fitur secara manual. Proses ini melibatkan konvolusi gambar input dengan filter yang telah dipelajari, yang menghasilkan peta fitur yang lebih kompleks di lapisan-lapisan yang lebih tinggi. CNN sangat efektif dalam berbagai tugas, seperti pengenalan objek, pemrosesan gambar, dan pengenalan wajah (Taye, 2023).

CNN dapat dibangun dari awal atau menggunakan model yang sudah ada (*pre-trained*) dan dimodifikasi untuk tujuan tertentu. Dalam banyak aplikasi model *pre-trained* lebih umum digunakan karena dapat mempercepat pengembangan aplikasi. CNN telah menunjukkan hasil yang sangat baik dalam berbagai aplikasi dengan akurasi mencapai 100% dalam beberapa kasus (Naranjo-Torres dkk., 2020). CNN juga memiliki keunggulan dalam mengurangi kebutuhan pra-pemrosesan dibandingkan dengan algoritma klasifikasi gambar lainnya, karena dapat belajar secara otomatis untuk meningkatkan filter tanpa bergantung pada pengetahuan sebelumnya atau interaksi manusia (Galety dkk., 2021).

### 2.1.4 *Transfer Learning*

*Transfer learning* merupakan pendekatan dalam *machine learning* yang memanfaatkan model yang telah dilatih pada suatu tugas sebagai titik awal untuk menyelesaikan tugas lain yang berbeda namun masih memiliki keterkaitan. Pendekatan ini sangat bermanfaat, khususnya ketika data untuk tugas baru terbatas, karena memungkinkan penggunaan pengetahuan yang telah diperoleh dari dataset

yang lebih besar (Zhuang dkk., 2021). Dalam praktiknya, *transfer learning* sering diterapkan pada bidang pengenalan citra dengan model yang dilatih pada dataset berskala besar yang dapat disesuaikan untuk tugas klasifikasi spesifik.

Salah satu keunggulan utama dari *transfer learning* adalah kemampuannya dalam mengurangi waktu pelatihan serta meningkatkan akurasi model. Dengan memanfaatkan parameter dari model yang telah dilatih sebelumnya, proses pelatihan dapat dilakukan lebih efisien tanpa harus mulai dari awal, yang umumnya memerlukan sumber daya komputasi dan waktu yang cukup besar. Keunggulan ini menjadi sangat signifikan dalam bidang medis, karena ketersediaan data sering kali terbatas dan proses pengumpulan data membutuhkan waktu serta biaya yang tidak sedikit (Abou Baker dkk., 2022b).

Secara keseluruhan, *transfer learning* menjadi teknik yang krusial dalam pengembangan model *machine learning*, terutama dalam konteks klasifikasi citra medis. Dengan memanfaatkan pengetahuan yang telah diperoleh dari model pra-latih, dapat meningkatkan kinerja model dalam mendukung proses diagnosis dan pengambilan keputusan klinis secara lebih akurat (Peng dkk., 2022).

### 2.1.5 *EfficientNet*

*EfficientNet* merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang untuk mencapai akurasi tinggi dengan jumlah parameter yang lebih sedikit dibandingkan dengan model lain. Arsitektur ini menggunakan pendekatan yang disebut *compound scaling*, yang secara bersamaan mengubah tiga dimensi model: kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) dari jaringan (Perdani dkk., 2022). *EfficientNet* memiliki 8 arsitektur, yaitu *EfficientNetB0*

hingga *EfficientNetB7*. Perbedaan antara *EfficientNetB0* hingga *EfficientNetB7* terletak pada skala kedalaman (*depth*), lebar (*width*), dan resolusi input (*input resolution*) dari model tersebut. Setiap versi dari *EfficientNet* dirancang dengan menggunakan metode *scaling* yang disebut *compound scaling*, yang mengoptimalkan ketiga dimensi tersebut untuk mencapai performa yang lebih baik dengan penggunaan sumber daya yang lebih efisien (Wang dkk., 2020).



Gambar 2. 1 Arsitektur *EfficientNet*

Gambar 2.1 menunjukkan arsitektur model *EfficientNet*. Pertama, citra masukan diproses melalui lapisan konvolusi awal berukuran 3x3 untuk mengekstraksi fitur dasar. Selanjutnya, jaringan terdiri dari tujuh blok utama (Blok 1 hingga Blok 7), di mana setiap blok berisi beberapa unit konvolusi yang disebut MBConv (*Mobile Inverted Bottleneck Convolution*). Setiap blok memiliki konfigurasi kernel yang berbeda, mulai dari ukuran 3x3 hingga 5x5, untuk menangkap fitur spasial dengan skala yang beragam.

Blok pertama menggunakan MBConv dengan kernel 3x3 tanpa ekspansi saluran. Blok kedua hingga keempat terdiri atas MBConv dengan kernel 3x3 dan

5x5. Blok kelima dan keenam merupakan bagian terdalam dari jaringan, terdiri atas unit-unit MBConv 5x5 dalam jumlah yang lebih banyak. Hal ini bertujuan untuk melakukan ekstraksi fitur kompleks dan mendalam dari citra masukan. Blok ketujuh kemudian menyempurnakan hasil ekstraksi dengan beberapa MBConv 3x3 sebelum menghasilkan *feature map* sebagai keluaran akhir dari jaringan.

### 2.1.6 Confusion Matrix

Ada banyak cara untuk mengevaluasi model yang telah dibuat, menggunakan berbagai ukuran kinerja yang dapat memberikan wawasan mendalam tentang efektivitas model tersebut. Beberapa ukuran kinerja yang umum digunakan meliputi *accuracy*, *recall*, *precision*, *sensitivity*, *specificity*, *f1-score*, dan *dice coefficient* (Gunawan & Setiawan, 2022b).

|                 |          | Actual Class           |                        |
|-----------------|----------|------------------------|------------------------|
|                 |          | Positive               | Negative               |
| Predicted Class | Positive | TP<br>(True Positive)  | FN<br>(False Positive) |
|                 | Negative | FP<br>(False Negative) | TN<br>(True Negative)  |

Gambar 2. 2 Confusion Matrix

Gambar 2.2 menampilkan *Confusion Matrix* yang terdiri dari empat istilah yang merepresentasikan hasil dari proses klasifikasi, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Selanjutnya, dilakukan perhitungan jumlah data untuk masing-masing kategori tersebut dengan tujuan untuk memperoleh hasil evaluasi terhadap data positif dan negatif

berdasarkan prediksi yang dihasilkan oleh sistem yang telah dibangun (Marcella & Devella, 2022).

### 2.1.7 *Adam Optimizer*

Adam (*Adaptive Moment Estimation*) adalah algoritma optimasi adaptif yang banyak dipakai dalam melatih model *deep learning*. Cara kerjanya yaitu menyesuaikan *learning rate* setiap parameter secara otomatis dengan memanfaatkan perhitungan rata-rata gradien dan perubahan gradien sebelumnya. Pendekatan ini membantu model mencapai konvergensi lebih cepat (Sudewo dkk., 2025). Secara garis besar, Adam memadukan prinsip kerja dua metode optimasi populer, yaitu Momentum dan RMSProp. Momentum membantu mempercepat pembaruan bobot dengan menjaga arah perubahan gradien tetap konsisten, sementara RMSProp menyesuaikan *learning rate* menggunakan rata-rata kuadrat gradien terbaru. Dengan mengintegrasikan kedua pendekatan tersebut, Adam dapat melakukan pembaruan bobot secara adaptif sehingga proses pelatihan berlangsung lebih stabil dan efisien (Kartowisastro & Latupapua, 2023).

Salah satu kekuatan utama Adam terletak pada kemampuan algoritma ini untuk menetapkan *learning rate* yang berbeda bagi setiap parameter, sehingga lebih fleksibel dalam menghadapi data berukuran besar maupun yang memiliki keragaman tinggi. Selain itu, metode ini umumnya tidak memerlukan banyak penyesuaian hiperparameter, sehingga lebih praktis digunakan. Karena alasan tersebut, Adam kerap dijadikan optimasi standar dalam berbagai studi yang melibatkan arsitektur CNN, termasuk pada tugas klasifikasi citra medis (Sun dkk., 2024)



## 2.2 State-of-the-Art

Penelitian mengenai klasifikasi luka telah mengalami kemajuan yang signifikan dalam beberapa tahun terakhir. Berbagai metode dan algoritma telah digunakan untuk meningkatkan akurasi dan efisiensi. *State of the art* yang disajikan pada Tabel 2.1 berisi tentang hasil penelitian yang sudah dilakukan sebelumnya untuk menggambarkan berbagai pendekatan yang telah diteliti untuk menciptakan sistem klasifikasi luka luar yang lebih akurat.

Tabel 2. 1 *State Of The Art* Penelitian

| No | Nama Peneliti/Journal                                                                        | Hasil Penelitian |                                                 |                                                                                                                                           |                                                               |
|----|----------------------------------------------------------------------------------------------|------------------|-------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------|
|    |                                                                                              | Akurasi          | Hasil                                           | Kelebihan                                                                                                                                 | Kekurangan                                                    |
| 1  | (Alruwaili & Mohamed, 2025)<br><i>Fusion-based: EfficientNetB0, EfficientNetB2, ResNet50</i> | 99.14%           | Sistem klasifikasi penyakit kulit.              | Menghasilkan akurasi sangat baik dengan <i>fusion</i> tiga arsitektur. Baik dalam generalisasi dan atasi <i>imbalance</i> .               | Waktu eksekusi lama dan memerlukan daya komputasi signifikan. |
| 2  | (Makineni, 2025)<br><i>EfficientNetB0, EfficientNetB3, EfficientNetB4 EfficientNetV2B0</i>   | 91.53%           | Aplikasi diagnosis gigitan ular <i>mobile</i> . | Meraih <i>recall</i> 100% untuk gigitan berbisa (minimalisir <i>false negative</i> fatal). Cocok untuk aplikasi <i>mobile on-device</i> . | Dataset relatif kecil dan variasi kulit/lingkungan terbatas.  |

| No | Nama Peneliti/Journal                                                                       | Hasil Penelitian                                                              |                                                                                |                                                                                                                                                                                         |                                                                                                                                                             |
|----|---------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------|--------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|
|    |                                                                                             | Akurasi                                                                       | Hasil                                                                          | Kelebihan                                                                                                                                                                               | Kekurangan                                                                                                                                                  |
| 3  | (Ezhilan dkk., 2024)<br><i>ResNet152</i> ,<br><i>EfficientNet-B7</i> ,<br><i>SE-ResNeXt</i> | 99,39% (ResNet152)<br>99,65% ( <i>EfficientNetB7</i> )<br>98,38% (SE-ResNeXt) | Sistem klasifikasi Ulkus Kaki Diabetik (DFU).                                  | Meraih hasil kinerja dengan akurasi tinggi yang menunjukkan kemampuannya dalam mengidentifikasi kasus DFU dengan tepat.                                                                 | Dengan akurasi yang sangat tinggi, ada risiko bahwa model mengalami <i>overfitting</i> .                                                                    |
| 4  | (Ramesh dkk., 2024)<br><i>EfficientNet-B7</i>                                               | 90%                                                                           | Pengembangan sistem klasifikasi lesi kulit.                                    | Penelitian ini menggabungkan beberapa model dasar dalam satu kerangka ensemble, yang memungkinkan performa analisis klasifikasi meningkat dibandingkan dengan penggunaan model tunggal. | Pendekatan <i>stacked ensemble</i> yang digunakan dapat menghasilkan model yang kompleks dan sulit untuk diinterpretasikan.                                 |
| 5  | (Kanchana dkk., 2024)<br><i>EfficientNet-B7</i>                                             | 97.1%                                                                         | Hasil penelitian ini berbentuk sistem klasifikasi otomatis untuk kanker kulit. | Penelitian ini menggunakan metode <i>multiclass</i> , yang memungkinkan untuk mengklasifikasikan berbagai jenis lesi kulit.                                                             | Kinerja model sangat bergantung pada kualitas dan ukuran dataset yang digunakan sehingga model mengalami kesulitan dalam mengklasifikasikan kelas tertentu. |

| No | Nama Peneliti/Journal                         | Hasil Penelitian |                                                                                                                                                 |                                                                                                                                                                         |                                                                                                                                                             |
|----|-----------------------------------------------|------------------|-------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|
|    |                                               | Akurasi          | Hasil                                                                                                                                           | Kelebihan                                                                                                                                                               | Kekurangan                                                                                                                                                  |
| 6  | (Liu dkk., 2024)<br><i>EfficientNet-B0</i>    | 90%              | Pengembangan sistem analisis gambar luka kronis berbasis <i>smartphone</i> SmartWAnDS ( <i>Smartphone Wound Analysis and Decision-Support</i> ) | Menghasilkan sistem SmartWAnDS yang memberikan umpan balik dan rekomendasi yang dapat meningkatkan manajemen luka di rumah.                                             | Pengumpulan dan pelabelan data gambar luka yang memadai sering kali tidak seimbang sehingga membatasi akurasi model klasifikasi luka yang dikembangkan.     |
| 7  | (Harumy dkk., 2024)<br><i>EfficientNet-B7</i> | 94%              | Sistem berbasis web yang dirancang untuk mendeteksi penyakit kulit.                                                                             | Sistem berbasis web yang dikembangkan memungkinkan pengguna mengunggah gambar untuk klasifikasi penyakit kulit yang mudah diakses oleh tenaga kesehatan dan masyarakat. | Model ini lebih berfokus pada karakteristik gambar dermatoskopi yang dapat membatasi kemampuannya dalam mengklasifikasikan jenis penyakit kulit yang mirip. |

| No | Nama Peneliti/Journal                                                                  | Hasil Penelitian                                                                       |                                                                       |                                                                                                                                                                                                           |                                                                                                                                                                                                                                                                                 |
|----|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|    |                                                                                        | Akurasi                                                                                | Hasil                                                                 | Kelebihan                                                                                                                                                                                                 | Kekurangan                                                                                                                                                                                                                                                                      |
| 8  | (Huong dkk., 2023)<br><i>AlexNet</i> ,<br><i>GoogleNet</i> ,<br><i>EfficientNet-B0</i> | 0.99 ( <i>AlexNet</i> )<br>0.98 ( <i>GoogleNet</i> )<br>0.98 ( <i>EfficientNetB0</i> ) | Sistem klasifikasi infeksi dan iskemia pada luka kaki diabetik (DFU). | Model yang dioptimalkan menunjukkan performa klasifikasi yang baik dibandingkan dengan studi sebelumnya yang menggunakan pendekatan tradisional.                                                          | Proses optimasi dan <i>training</i> model memerlukan sumber daya komputasi yang signifikan, yang mungkin tidak tersedia di semua fasilitas kesehatan, membatasi aksesibilitas teknologi ini.                                                                                    |
| 9  | (Hridoy dkk., 2021)<br><i>EfficientNet-B7</i>                                          | 97.10%                                                                                 | Sistem identifikasi gangguan kulit.                                   | Dataset yang digunakan bersifat besar dan terdapat 21 kelas beragam, mencakup berbagai jenis gangguan kulit yang cukup representatif untuk mendukung proses pelatihan dan pengujian model secara efektif. | Meskipun performa model secara keseluruhan sangat baik, namun terdapat kelas-kelas seperti <i>erythrodermic psoriasis</i> yang menunjukkan tingkat akurasi dan sensitivitas lebih rendah dibandingkan kelas lainnya, menunjukkan adanya ketidakseimbangan performa antar kelas. |

Berdasarkan analisis berbagai penelitian yang telah dipaparkan pada Tabel 2.1 dapat disimpulkan bahwa meskipun model canggih seperti *Eff-ReLU-Net* dan arsitektur *fusion* telah mencapai akurasi tinggi dalam klasifikasi luka dan penyakit kulit, penelitian sebelumnya menunjukkan adanya risiko *overfitting* pada model besar ketika digunakan dengan dataset yang terbatas. Hal ini menyoroti kurangnya kejelasan

mengenai varian model *EfficientNet* mana yang paling seimbang antara akurasi, efisiensi, dan kemampuan generalisasi untuk klasifikasi enam jenis luka luar. Oleh karena itu, penelitian ini bertujuan untuk menutup kekurangan tersebut dengan mengevaluasi seluruh varian *EfficientNet* secara komparatif, untuk menemukan arsitektur yang paling stabil dan cocok digunakan dalam sistem klasifikasi luka luar.

### 2.3 Matriks Penelitian

Tabel 2. 2 Matriks Penelitian

| No | Penelitian                  | Tujuan penelitian       |                    |                     |                 | Penerapan Algoritma |                 |                 |                 |                 |                 |                 |                 |                  |         |           |       |           |          |            |
|----|-----------------------------|-------------------------|--------------------|---------------------|-----------------|---------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|------------------|---------|-----------|-------|-----------|----------|------------|
|    |                             | Sistem Berbasis Website | Sistem Klasifikasi | Sistem Identifikasi | Aplikasi Mobile | EfficientNet-B0     | EfficientNet-B1 | EfficientNet-B2 | EfficientNet-B3 | EfficientNet-B4 | EfficientNet-B5 | EfficientNet-B6 | EfficientNet-B7 | EfficientNetV2B0 | AlexNet | GoogleNet | VGG16 | ResNet152 | ResNet50 | SE-ResNeXt |
| 1  | (Alruwaili & Mohamed, 2025) |                         | ✓                  |                     |                 | ✓                   |                 | ✓               |                 |                 |                 |                 |                 |                  |         |           |       |           | ✓        |            |
| 2  | (Makineni, 2025)            |                         |                    |                     | ✓               | ✓                   |                 |                 | ✓               | ✓               |                 |                 |                 | ✓                |         |           |       |           |          |            |
| 3  | (Ezhilan dkk., 2024)        |                         | ✓                  |                     |                 |                     |                 |                 |                 |                 |                 |                 | ✓               |                  |         |           |       | ✓         |          | ✓          |
| 4  | (Ramesh dkk., 2024)         |                         | ✓                  |                     |                 |                     |                 |                 |                 |                 |                 |                 | ✓               |                  |         |           |       |           |          |            |
| 5  | (Kanchana dkk., 2024)       |                         | ✓                  |                     |                 |                     |                 |                 |                 |                 |                 |                 | ✓               |                  |         |           |       |           |          |            |
| 6  | (Liu dkk., 2024)            |                         | ✓                  |                     |                 | ✓                   |                 |                 |                 |                 |                 |                 |                 |                  |         |           |       |           |          |            |
| 7  | (Harumy dkk., 2024)         | ✓                       |                    |                     |                 |                     |                 |                 |                 |                 |                 |                 | ✓               |                  |         |           |       |           |          |            |

|    |                     |  |   |   |  |   |   |   |   |   |   |   |   |  |   |   |  |  |  |  |
|----|---------------------|--|---|---|--|---|---|---|---|---|---|---|---|--|---|---|--|--|--|--|
| 8  | (Huong dkk., 2023)  |  | ✓ |   |  |   |   |   |   |   |   |   | ✓ |  | ✓ | ✓ |  |  |  |  |
| 9  | (Hridoy dkk., 2021) |  |   | ✓ |  |   |   |   |   |   |   |   | ✓ |  |   |   |  |  |  |  |
| 10 | Usulan Penelitian   |  | ✓ |   |  | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |  |   |   |  |  |  |  |

Berdasarkan perbandingan model pada matriks penelitian yang ditunjukkan pada Tabel 2.2 dapat dilihat bahwa setiap penelitian menggunakan algoritma yang berbeda, mulai dari arsitektur CNN klasik seperti VGG-16, *AlexNet*, dan *ResNet*, hingga arsitektur modern seperti *EfficientNet*. Meskipun beberapa model, seperti arsitektur fusion, mampu mencapai akurasi sangat tinggi pada klasifikasi luka, minimnya penelitian yang membandingkan seluruh varian *EfficientNet* dari *EfficientNetB0* hingga *EfficientNetB7* secara langsung untuk menemukan kombinasi akurasi dan efisiensi terbaik. Model besar seperti *EfficientNetB7* atau arsitektur fusion cenderung mudah overfitting pada dataset terbatas, sehingga memerlukan evaluasi lebih mendalam. Oleh karena itu, penelitian ini fokus melatih dan membandingkan semua varian *EfficientNet* dari *EfficientNetB0* hingga *EfficientNetB7* untuk menentukan arsitektur yang paling stabil dan efektif dalam mengklasifikasikan enam jenis luka luar.