

BAB II

LANDASAN TEORI


2.1 *Convolutional Neural Network*

Sebelum berkembangnya *deep learning*, proses klasifikasi citra umumnya mengandalkan ekstraksi fitur secara manual yang kemudian diproses menggunakan algoritma pembelajaran mesin konvensional. Pada pendekatan tersebut, performa sistem sangat ditentukan oleh kualitas serta kemampuan fitur yang dirancang secara manual dalam merepresentasikan karakteristik objek pada citra. Seiring munculnya pembelajaran mendalam (*deep learning*), terjadi perubahan pendekatan yang signifikan, di mana proses ekstraksi fitur dan klasifikasi tidak lagi dipisahkan, melainkan diintegrasikan dalam satu arsitektur terpadu sehingga alur pemrosesan menjadi lebih efisien dan otomatis. (S. Rahman dkk., 2024)

Salah satu arsitektur yang berperan penting dalam perubahan paradigma tersebut adalah *Convolutional Neural Network* (CNN), yaitu jaringan saraf berlapis yang dirancang khusus untuk menangani data visual dan terinspirasi dari mekanisme pemrosesan visual pada sistem biologis. CNN memungkinkan proses pembelajaran fitur dan klasifikasi berlangsung secara simultan dalam satu model, sehingga sangat sesuai untuk berbagai aplikasi analisis citra, termasuk dalam bidang pencitraan medis. (S. Rahman dkk., 2024)

Convolutional Neural Network (CNN) banyak digunakan dalam analisis citra medis karena kemampuannya mengekstraksi fitur visual secara otomatis dan hierarkis langsung dari data citra. CNN mampu mengenali pola penting seperti tekstur, warna, dan struktur jaringan tanpa memerlukan proses ekstraksi fitur

manual, sehingga memberikan akurasi dan konsistensi yang lebih baik dalam tugas klasifikasi citra dibandingkan metode konvensional (Kanchana dkk., 2024).




Gambar 2.1 Lapisan layer Arsitektur CNN (Gupta dkk., 2022)

Gambar 2.1 menunjukkan lapisan arsitektur *Convolutional Neural Network* (CNN) dimana dibangun berdasarkan prinsip aljabar linier, dimana data dan parameter (*weights*) direpresentasikan melalui operasi perkalian matriks dan vektor. Dalam prosesnya, setiap lapisan CNN mengekstraksi representasi fitur yang berbeda dari citra masukan, dimulai dari fitur dasar seperti tepi, kontras terang-gelap, dan pola geometris sederhana pada lapisan awal, hingga fitur yang lebih kompleks dan spesifik pada lapisan yang lebih dalam. Proses ekstraksi fitur dilakukan melalui operasi konvolusi menggunakan filter (misalnya 3×3) yang digeser pada bagian-bagian kecil citra untuk menghasilkan *feature map*, kemudian dilanjutkan dengan tahap *pooling* seperti *max pooling* untuk mereduksi dimensi fitur tanpa menghilangkan informasi penting. Selanjutnya, fungsi aktivasi seperti *Rectified Linear Unit* (ReLU) diterapkan untuk meningkatkan sifat non-linear model, dan rangkaian proses konvolusi, aktivasi, serta pooling dapat dilakukan berulang (*deep stacking*) agar jaringan mampu mempelajari kombinasi fitur yang semakin kompleks. Pada tahap akhir, fitur yang telah diekstraksi diteruskan ke *fully*

connected layer untuk proses klasifikasi, sementara pembaruan parameter jaringan dilakukan melalui mekanisme *backpropagation*. (Gupta dkk., 2022).

2.2 EfficientNet


EfficientNet dikembangkan berdasarkan prinsip *compound scaling*, yaitu metode penskalaan yang secara sistematis dan seimbang meningkatkan kedalaman (*depth*), lebar (*width*), dan resolusi citra menggunakan koefisien tetap untuk mencapai akurasi dan efisiensi yang lebih optimal. Berbeda dengan pendekatan konvensional yang hanya menskalakan satu dimensi jaringan, *EfficientNet* menyeimbangkan ketiga dimensi tersebut sehingga menghasilkan performa yang lebih baik dengan kompleksitas komputasi yang lebih efisien. Melalui pendekatan *neural architecture search* untuk merancang arsitektur dasar, kemudian dilakukan penskalaan menjadi keluarga model *EfficientNet*-B0 hingga B7, yang terbukti mencapai akurasi *state-of-the-art* pada *ImageNet* dengan ukuran model yang lebih kecil dan kecepatan inferensi yang lebih tinggi dibandingkan *ConvNet* sebelumnya, serta menunjukkan kemampuan *transfer learning* yang baik pada berbagai dataset lain. (Kanchana dkk., 2024)



Gambar 2.2 Visualisasi Metode Compound Scaling (Tan & Le, n.d.).

Gambar 2.2 menjelaskan inovasi utama *EfficientNet* dalam meningkatkan performa model secara efisien. Cara kerjanya dimulai dari model (a) *baseline* sebagai acuan standar, yang kemudian dapat dikembangkan melalui (b) *width scaling* dengan menambah jumlah saluran fitur, (c) *depth scaling* dengan menambah jumlah lapisan, atau (d) *resolution scaling* dengan memperbesar resolusi gambar masukan. Namun, keunggulan utama *EfficientNet* terletak pada metode (e) *compound scaling*, di mana ketiga dimensi tersebut lebar, kedalaman, dan resolusi ditingkatkan secara bersamaan dan seimbang menggunakan koefisien tetap. Pendekatan terintegrasi ini memungkinkan model untuk menangkap detail tekstur dan pola yang lebih kaya dengan efisiensi parameter yang jauh lebih baik dibandingkan hanya meningkatkan salah satu dimensi secara terpisah (Kanchana dkk., 2024).

Metode *compound scaling* pada *EfficientNet* dilakukan dengan meningkatkan kedalaman jaringan sebesar α^n , lebar sebesar β^n , dan resolusi input sebesar γ^n , di mana α , β , dan γ merupakan koefisien konstan yang ditentukan melalui pencarian grid pada model dasar. Pendekatan ini didasarkan pada prinsip bahwa peningkatan resolusi citra memerlukan penyesuaian yang seimbang pada kedalaman untuk memperluas *receptive field* serta pada lebar jaringan untuk menangkap pola visual yang lebih kompleks. Melalui pemanfaatan *neural architecture search*, dikembangkan arsitektur dasar yang kemudian diskalakan menjadi keluarga *EfficientNet* (B0–B7) (Tan & Le, 2019).



Gambar 2.3 Lapisan EfficientNetB0 (Khairunnisa dkk., 2025).


Arsitektur *EfficientNet* sesuai pada Gambar 2.3 bekerja dengan menerima input citra luka bakar berukuran 224 x 224 piksel yang kemudian diproses melalui lapisan konvolusi awal untuk ekstraksi fitur dasar. Proses utama dilakukan secara hierarkis melalui serangkaian blok MBConv (*Mobile Inverted Bottleneck Convolution*), di mana blok MBConv1 dan MBConv6 dengan ukuran *kernel* 3 x 3 serta 5 x 5 digunakan secara bergantian untuk menangkap detail tekstur jaringan luka pada berbagai skala spasial. Selama data mengalir melalui tahapan ini, resolusi citra direduksi secara bertahap hingga menjadi 7 x 7 piksel, sementara kedalaman saluran fitur ditingkatkan hingga 320 saluran guna menghasilkan representasi informasi yang padat dan kaya akan karakteristik klinis. Pada tahap akhir, kumpulan fitur yang telah terabstraksi ini dikonversi menjadi vektor fitur tunggal melalui lapisan global yang kemudian digunakan oleh pengklasifikasi untuk menentukan kategori luka bakar yang tepat (Khairunnisa dkk., 2025).

2.3 YOLO (You Only Look Once)

YOLO (*You Only Look Once*) adalah algoritma deteksi objek berbasis *deep learning* yang dirancang untuk melakukan deteksi dan lokalisasi objek secara *real-time*, pertama kali diperkenalkan pada tahun 2015 oleh (Redmon dkk., t.t.). Model ini bekerja dengan membagi citra input menjadi beberapa grid berukuran sama, di mana setiap grid secara simultan memprediksi kemungkinan keberadaan objek


beserta koordinat *bounding box*, ukuran (lebar dan tinggi), serta kelas objek. Prediksi lokasi dilakukan menggunakan pendekatan *regresi*, sedangkan tingkat akurasi posisi objek dievaluasi menggunakan metrik *Intersection over Union* (IoU) untuk mengukur tumpang tindih antara *bounding box* prediksi dan *ground truth*. Dataset yang digunakan pada YOLO harus memiliki format anotasi khusus yang mencakup kelas objek serta koordinat dan dimensi *bounding box* agar dapat diproses oleh model (Ferdinand dkk., 2023).

Pendekatan YOLO mereformulasi deteksi objek sebagai satu permasalahan regresi tunggal yang secara langsung memetakan piksel citra ke koordinat *bounding box* dan probabilitas kelas. Berbeda dengan metode sebelumnya seperti *sliding window* dan *region proposal* yang memisahkan tahapan deteksi dan klasifikasi, YOLO menggunakan satu jaringan konvolusional untuk memprediksi seluruh *bounding box* dan probabilitas kelas dalam satu kali proses inferensi. Pendekatan ini memungkinkan pelatihan secara *end-to-end*, meningkatkan efisiensi komputasi, serta memberikan kemampuan bagi model untuk memahami konteks global citra secara keseluruhan (Inan dkk., 2025).



Gambar 2.4 Gambar Proses Prediksi Global YOLO (Huang & Cheng, 2025).


Mengimplementasi pendekatan tersebut, dengan citra input dibagi menjadi grid berukuran $S \times S$ di mana setiap sel grid bertanggung jawab mendeteksi objek yang pusatnya berada dalam area sel tersebut. Setiap sel memprediksi sejumlah *bounding box* yang terdiri atas koordinat pusat (x,y), lebar (w), tinggi (h) serta nilai *confidence* yang merepresentasikan probabilitas keberadaan objek dan tingkat kesesuaian prediksi berdasarkan nilai IoU. Selain itu, setiap sel juga memprediksi probabilitas kelas bersyarat yang kemudian dikombinasikan dengan nilai *confidence* untuk menghasilkan skor deteksi akhir. Desain arsitektur yang terpadu ini memungkinkan YOLO mencapai kecepatan deteksi *real-time* dengan tetap mempertahankan tingkat presisi yang kompetitif, meskipun pada kondisi tertentu masih menghadapi tantangan dalam mendeteksi objek berukuran kecil secara lebih akurat (Redmon dkk., t.t.).



Gambar 2.5 Kerangka Kerja Detektor pada YOLO (Sayed Amer, 2025).

Memahami implementasi arsitektur YOLO secara lebih komprehensif dengan model detektor ini dapat dijelaskan berdasarkan tiga komponen utama, yaitu *backbone*, *neck*, dan *head*. Ketiga komponen tersebut bekerja secara terintegrasi

dalam kerangka detektor satu tahap (*one-stage detector*) yang memungkinkan proses deteksi dilakukan secara efisien dalam satu kali inferensi. *Backbone* berfungsi sebagai ekstraktor fitur yang bertugas mengekstraksi representasi visual dari citra input melalui lapisan konvolusional. *Neck* berperan dalam menggabungkan dan memperkaya fitur dari berbagai skala untuk meningkatkan kemampuan deteksi objek dengan ukuran yang berbeda. Sementara itu, *head* atau *dense prediction layer* bertanggung jawab menghasilkan prediksi akhir berupa koordinat *bounding box*, skor kepercayaan, dan probabilitas kelas. Struktur terpadu ini membedakan YOLO dari pendekatan *two-stage detector* seperti R-CNN, yang memisahkan proses proposal wilayah dan klasifikasi objek dalam dua tahapan terpisah (Sayed Amer, 2025).



Gambar 2.6 Arsitektur layer YOLO (Redmon dkk., t.t.).

Proses ekstraksi fitur yang dilakukan pada komponen *backbone* dan *neck* secara lebih mendalam, perlu dijelaskan struktur lapisan jaringan yang membentuk arsitektur YOLO. Model ini diimplementasikan sebagai jaringan saraf konvolusional CNN yang terdiri atas serangkaian lapisan konvolusi yang bertugas mengekstraksi fitur secara hierarkis dari citra input. Lapisan konvolusi awal


berfungsi menangkap fitur tingkat rendah seperti tepi dan tekstur, sedangkan lapisan yang lebih dalam mengekstraksi fitur tingkat tinggi yang merepresentasikan bentuk dan pola objek. (Huang & Cheng, 2025)

Arsitektur awal YOLO sesuai pada Gambar 2.6 terdiri atas 24 lapisan konvolusi yang diikuti oleh 2 lapisan *fully connected* untuk menghasilkan prediksi akhir berupa probabilitas kelas dan koordinat *bounding box*. Struktur ini terinspirasi dari model *GoogLeNet* pada tugas klasifikasi citra, namun tanpa menggunakan modul *inception*. Sebagai gantinya, YOLO menerapkan kombinasi lapisan konvolusi 1×1 untuk reduksi dimensi fitur yang diikuti oleh lapisan konvolusi 3×3 untuk ekstraksi fitur spasial. Pendekatan ini memungkinkan pengurangan kompleksitas komputasi sekaligus mempertahankan representasi fitur yang kuat (Redmon dkk., t.t.).

Pada tahap awal pelatihan, lapisan konvolusi terlebih dahulu dilatih menggunakan dataset *ImageNet* untuk tugas klasifikasi dengan resolusi input 224×224 piksel, kemudian resolusi ditingkatkan untuk kebutuhan deteksi objek. Output akhir dari jaringan ini berbentuk tensor berukuran $7 \times 7 \times 30$ yang merepresentasikan prediksi *bounding box*, nilai *confidence*, dan probabilitas kelas pada setiap sel grid. Selain arsitektur utama, dikembangkan pula versi Fast YOLO yang menggunakan jumlah lapisan konvolusi yang lebih sedikit guna meningkatkan kecepatan deteksi, dengan tetap mempertahankan prinsip kerja yang sama. (Huang & Cheng, 2025).

2.4 YoloV11


YOLOv11 merupakan versi terbaru dari keluarga YOLO yang dikembangkan oleh *Ultralytics* dengan berbagai penyempurnaan arsitektur untuk meningkatkan efisiensi dan performa deteksi objek (Inan dkk., 2025). Model ini dirancang untuk mencapai keseimbangan optimal antara akurasi dan kecepatan (*accuracy-speed trade-off*) dibandingkan dengan versi YOLO sebelumnya. YOLOv11 tersedia dalam beberapa varian, yaitu YOLOv11, YOLOv11s, YOLOv11m, YOLOv11l, dan YOLOv11x, yang dirancang untuk menyesuaikan kebutuhan komputasi dan kompleksitas tugas, serta dilaporkan mampu mempertahankan akurasi deteksi yang kompetitif dengan jumlah parameter dan beban komputasi yang lebih efisien dibandingkan beberapa versi sebelumnya (Inan dkk., 2025).



Gambar 2.7 Performa dan Perbandingan YOLO version ultralytics [Ultralytics YOLO11 - Ultralytics YOLO Docs](#).

Berdasarkan Gambar 2.7 YOLOv11 versi terbaru YOLO, ditemukan memiliki tingkat akurasi yang lebih tinggi daripada versi lainnya. Hal ini menunjukkan bahwa model tersebut efektif dalam melokalisasi dan mendeteksi objek dengan presisi dan recall yang tinggi. Secara arsitektural, YOLOv11 menggunakan struktur

backbone–neck–head, di mana backbone bertugas mengekstraksi fitur hierarkis dari citra input, neck mengintegrasikan fitur multi-skala untuk meningkatkan kemampuan deteksi objek dengan berbagai ukuran, dan *head* menghasilkan prediksi akhir berupa bounding box, skor kepercayaan, serta probabilitas kelas (Avena-Caro dkk., 2025).



Gambar 2.8 Backbone YOLOv11 (Avena-Caro dkk., 2025)

YOLOv11 merupakan model deteksi objek satu tahap (single-stage detector) yang tersusun atas tiga komponen utama, yaitu backbone, neck, dan head, yang bekerja secara terintegrasi untuk melakukan ekstraksi fitur, fusi multiskala, serta prediksi objek. Pada bagian backbone, YOLOv11 menggunakan lapisan konvolusi dan blok C3K yang mengadopsi struktur bottleneck guna meningkatkan efisiensi komputasi sekaligus mempertahankan kualitas representasi fitur. Fitur yang dihasilkan backbone kemudian diproses pada bagian neck melalui mekanisme upsampling dan concatenation untuk menggabungkan informasi dari berbagai resolusi, sehingga objek dengan ukuran berbeda tetap dapat terdeteksi dengan baik.

Selanjutnya, bagian head menghasilkan prediksi akhir berupa koordinat bounding box, skor kepercayaan, dan probabilitas kelas, serta pada varian tertentu mendukung segmentasi instansi melalui jalur paralel untuk deteksi dan segmentasi secara simultan. Dalam proses pelatihan, YOLOv11 mengoptimalkan kinerjanya menggunakan kombinasi beberapa fungsi kehilangan, yaitu Box Loss untuk regresi bounding box, Classification Loss untuk prediksi kelas, Distribution Focal Loss (DFL) untuk meningkatkan akurasi lokalisasi, serta tambahan Segmentation Loss pada varian segmentasi, sehingga model mampu mencapai keseimbangan antara akurasi dan efisiensi komputasi (Avena-Caro dkk., 2025).

Selama proses pelatihan, model menghitung nilai kesalahan (*loss*) berdasarkan perbedaan antara prediksi model dan data ground truth. Pada YOLOv11, proses optimasi melibatkan beberapa komponen loss, yaitu:

1. *Box Loss*

Digunakan untuk mengukur tingkat kesalahan posisi bounding box prediksi terhadap *bounding box ground truth*.

2. *Classification Loss*

Digunakan untuk mengukur kesalahan klasifikasi objek berdasarkan kelas latar belakang.

3. *Distribution Focal Loss (DFL)*

Digunakan untuk meningkatkan presisi prediksi koordinat *bounding box*.

Nilai total loss secara umum dapat dinyatakan pada Persamaan (2.1)

$$Loss_{total} = Loss_{box} + Loss_{cls} + Loss_{dfl} \quad (2.1)$$

Keterangan

$Loss_{total}$ = Total keseluruhan loss pada proses training .

$Loss_{box}$ = Loss untuk mengukur akurasi *bounding box* .

$Loss_{cls}$ = Loss untuk mengukur akurasi klasifikasi class objek.

$Loss_{dfl}$ = Distribution Focal Loss untuk meningkatkan presisi

lokasi *bounding box*.

2.5 ROI (Region of Interest)

Region of Interest (ROI) merupakan pendekatan yang berfokus pada pelestarian kualitas area citra yang memiliki informasi diagnostik atau informasi penting, sementara bagian lain yang kurang relevan dapat dikompresi atau diproses dengan tingkat prioritas yang lebih rendah. Berbeda dengan metode konvensional yang memperlakukan seluruh bagian citra secara seragam, teknik berbasis ROI memprioritaskan wilayah tertentu yang mengandung informasi signifikan sehingga area tersebut tetap memiliki kualitas tinggi. Pendekatan ini bertujuan untuk menyeimbangkan efisiensi penyimpanan dan transmisi data dengan tetap menjaga integritas informasi krusial. Dengan memusatkan perhatian pada bagian esensial dari suatu citra, metode ROI mampu meningkatkan efisiensi pemrosesan tanpa mengorbankan kualitas informasi utama yang dibutuhkan untuk analisis lebih lanjut (Srivastava & Fujii, t.t.).

Dalam implementasinya, pendeteksian ROI dapat dilakukan melalui berbagai pendekatan dalam kerangka kerja *computer vision*, seperti *object detection*, *tissue*

segmentation, klasifikasi, serta ekstraksi fitur berbasis *Convolutional Neural Network* (CNN). Pada beberapa metode konvensional, penentuan ROI masih bergantung pada anotasi manual oleh ahli, yang bersifat mahal, memakan waktu, dan memerlukan keahlian khusus. Oleh karena itu, pendekatan otomatis berbasis pembelajaran mesin dan jaringan saraf banyak diterapkan untuk mengidentifikasi area yang relevan secara lebih efisien dan konsisten (Ghezloo dkk., 2025).

Salah satu pendekatan yang dapat digunakan untuk meningkatkan kualitas ROI hasil deteksi objek adalah *adaptive padding*, yaitu teknik yang memperluas area *bounding box* secara proporsional terhadap ukuran objek sebelum dilakukan proses *cropping*. Tujuannya adalah agar ROI tidak hanya mencakup objek utama, tetapi juga mempertahankan sebagian kecil konteks visual di sekitarnya yang masih berkaitan dengan objek tersebut. Pendekatan ini disebut *adaptive* karena besar perluasan area tidak menggunakan nilai yang tetap, melainkan menyesuaikan ukuran setiap *bounding box* yang terdeteksi. Dengan demikian, objek berukuran kecil memperoleh penambahan area yang lebih kecil, sedangkan objek berukuran besar memperoleh penambahan area yang lebih besar secara proporsional. Berbeda dengan *fixed padding* yang menggunakan nilai penambahan area yang sama untuk seluruh objek, *adaptive padding* mampu menghasilkan ROI yang lebih fleksibel sehingga informasi penting di sekitar objek tetap dipertahankan tanpa memasukkan latar belakang secara berlebihan (Musaddid, 2024).

Konsep penyesuaian area hasil deteksi sebelum proses lanjutan juga diterapkan oleh Musaddid (2024) melalui pendekatan *adaptive bounding box coordinate adjustment* pada sistem deteksi karakter plat nomor kendaraan. Pada penelitian

tersebut, koordinat *bounding box* disesuaikan agar area hasil deteksi mampu mencakup seluruh karakter plat sebelum dilakukan proses pengenalan karakter. Meskipun diterapkan pada domain yang berbeda, prinsip yang digunakan memiliki kesamaan, yaitu memperbaiki hasil lokalisasi objek agar representasi objek menjadi lebih lengkap sebelum memasuki tahap analisis berikutnya. Pada penelitian ini, konsep tersebut diadaptasi pada hasil deteksi YOLOv11 dengan menerapkan adaptive padding, sehingga area ROI luka bakar tidak hanya mencakup bagian luka yang terdeteksi, tetapi juga mempertahankan sebagian kecil jaringan di sekitarnya sebagai konteks visual yang dapat membantu proses klasifikasi tingkat keparahan luka bakar.

proses adaptive padding pada penelitian ini dihitung sebagai berikut (Dinç & Kaya, 2025).

$$w = x_2 - x_1$$

$$h = y_2 - y_1$$

$$pad = 0.15 \times \min(w, h)$$

w = lebar bounding box

h = tinggi bounding box

pad = nilai adaptive padding

Selanjutnya koordinat bounding box diperbarui menggunakan persamaan berikut (Dinç & Kaya, 2025).

$$x'_1 = \max(0, x_1 - pad)$$

$$y'_1 = \max(0, y_1 - pad)$$

$$x'_2 = \min(W, x_2 + pad)$$

$$y'2 = \min(H, y2 + \text{pad})$$

$x'1$ = koordinat kiri atas setelah adaptive padding

$y'1$ = koordinat kiri atas setelah adaptive padding

$x'2$ = koordinat kanan bawah setelah adaptive padding

$y'2$ = koordinat kanan bawah setelah adaptive padding

W = lebar citra

H = tinggi citra

Melalui mekanisme tersebut, area ROI yang dihasilkan tidak hanya mencakup bagian luka yang berhasil dideteksi, tetapi juga mempertahankan sebagian kecil jaringan di sekitarnya sebagai konteks visual. Informasi tambahan tersebut diharapkan dapat membantu proses ekstraksi fitur sehingga model klasifikasi mampu membedakan karakteristik setiap tingkat keparahan luka bakar dengan lebih baik. Koordinat yang telah diperoleh dari proses *adaptive padding* selanjutnya digunakan untuk memotong area citra sesuai lokasi luka yang terdeteksi. Hasil pemotongan tersebut menghasilkan citra ROI yang kemudian digunakan pada tahapan penelitian berikutnya. Secara matematis, proses *cropping* ROI dapat dinyatakan sebagai berikut (Musaddid, 2024):

$$ROI = I[y'1 : y'2, x'1 : x'2]$$

I = citra asli

$x'1, y'1$ = koordinat kiri atas setelah adaptive padding

$x'2, y'2$ = koordinat kanan bawah setelah adaptive padding

ROI = citra hasil cropping area

Persamaan tersebut menunjukkan bahwa proses *cropping* hanya mempertahankan piksel yang berada di dalam koordinat *bounding box* hasil deteksi yang telah diperluas menggunakan *adaptive padding*, sedangkan piksel di luar area tersebut tidak disertakan pada citra ROI. Dengan demikian, citra hasil *cropping* menjadi lebih terfokus pada area objek yang akan digunakan pada proses analisis berikutnya (Musaddid, 2024).

2.6 Pelabelan Otomatis

Pembentukan label otomatis (*automatic labeling* atau *pseudo labeling*) merupakan salah satu pendekatan yang digunakan untuk menghasilkan label kelas pada data yang belum memiliki anotasi atau informasi kategori secara lengkap. Metode ini banyak diterapkan pada bidang pengolahan citra medis karena proses pelabelan secara manual umumnya memerlukan waktu yang lama, biaya yang tinggi, serta keterlibatan tenaga ahli untuk memastikan ketepatan label yang diberikan. Melalui pendekatan ini, karakteristik yang terkandung dalam data dimanfaatkan untuk membentuk kelompok-kelompok yang kemudian digunakan sebagai dasar dalam pemberian label secara otomatis (Salloum, 2025; Şevik dkk., 2019).

Pada pengolahan citra, proses pembentukan label otomatis umumnya diawali dengan ekstraksi fitur (*feature extraction*) untuk mengubah informasi visual menjadi representasi numerik yang lebih mudah dianalisis secara komputasional. Representasi fitur tersebut kemudian digunakan sebagai masukan bagi algoritma *clustering* untuk mengelompokkan data berdasarkan tingkat kemiripan karakteristik yang dimiliki. Data yang berada dalam kelompok yang sama

diasumsikan memiliki pola visual yang serupa sehingga dapat diberikan label yang sama setelah dilakukan proses interpretasi terhadap hasil pengelompokan (Cirillo dkk., 2019).

Pendekatan yang menggabungkan *feature extraction* dan *clustering* telah banyak digunakan pada berbagai penelitian pengolahan citra medis karena mampu menemukan pola yang tersembunyi pada data tanpa memerlukan label kelas pada tahap awal. Keberhasilan metode ini sangat dipengaruhi oleh kualitas fitur yang dihasilkan serta kemampuan algoritma *clustering* dalam membentuk kelompok data yang memiliki karakteristik homogen. Oleh karena itu, pemilihan metode ekstraksi fitur dan metode *clustering* menjadi faktor penting dalam menghasilkan label yang representatif terhadap kondisi sebenarnya (Shamia dkk., 2025).

Pada penelitian ini, pembentukan label otomatis dilakukan melalui tiga tahapan utama, yaitu ekstraksi fitur menggunakan *EfficientNetB0*, pengelompokan data menggunakan algoritma *KMeans Clustering*, dan pemberian label berdasarkan hasil pengelompokan yang diperoleh. Ketiga tahapan tersebut digunakan untuk menghasilkan label tingkat keparahan luka bakar yang selanjutnya dimanfaatkan sebagai target kelas pada proses klasifikasi.

2.7 Feature Extraction

Feature extraction merupakan proses mengubah informasi visual pada citra menjadi representasi numerik yang dapat diproses oleh algoritma pembelajaran mesin maupun *deep learning*. Representasi tersebut berisi informasi penting yang menggambarkan karakteristik objek pada citra, seperti warna, tekstur, bentuk, pola, dan struktur visual lainnya. Tujuan utama ekstraksi fitur adalah memperoleh

informasi yang relevan sehingga perbedaan maupun kemiripan antar citra dapat diidentifikasi secara lebih efektif (Şevik dkk., 2019).

Perkembangan *deep learning* memungkinkan proses ekstraksi fitur dilakukan secara otomatis menggunakan CNN. Berbeda dengan metode tradisional yang memerlukan perancangan fitur secara manual, CNN mampu mempelajari representasi fitur secara hierarkis mulai dari fitur tingkat rendah hingga fitur tingkat tinggi yang lebih kompleks. Pendekatan ini telah banyak digunakan pada berbagai bidang pengolahan citra medis karena mampu menghasilkan representasi yang lebih informatif dibandingkan metode ekstraksi fitur konvensional (Findia Jiven, 2025).

Salah satu arsitektur CNN yang banyak digunakan untuk ekstraksi fitur adalah *EfficientNet*. *EfficientNet* dikembangkan menggunakan konsep *compound scaling* yang menyeimbangkan kedalaman jaringan (*depth*), lebar jaringan (*width*), dan resolusi citra masukan (*resolution*) sehingga mampu menghasilkan performa tinggi dengan jumlah parameter yang relatif lebih sedikit dibandingkan arsitektur CNN lainnya. Selain itu, *EfficientNet* juga memanfaatkan *Mobile Inverted Bottleneck Convolution* (MBConv) dan *Squeeze-and-Excitation Block* untuk meningkatkan kualitas representasi fitur yang dihasilkan (Shamia dkk., 2025).

Dalam penelitian medis, *EfficientNet* telah digunakan untuk mengekstraksi fitur pada berbagai jenis citra, seperti citra lesi kulit dan citra *Magnetic Resonance Imaging* (MRI). Hasil penelitian menunjukkan bahwa fitur yang dihasilkan mampu merepresentasikan karakteristik visual objek secara efektif sehingga dapat digunakan pada proses klasifikasi maupun analisis lanjutan (Findia Jiven, 2025).

EfficientNetB0 dipilih sebagai *feature extractor* karena mampu menghasilkan representasi fitur visual yang kaya dengan kompleksitas model yang relatif efisien. Arsitektur ini telah dilatih pada dataset *ImageNet* sehingga memiliki kemampuan untuk mengekstraksi berbagai karakteristik visual penting, seperti warna, tekstur, bentuk, dan pola objek. Selain itu, *EfficientNetB0* menerapkan pendekatan *compound scaling* yang menyeimbangkan kedalaman jaringan, lebar jaringan, dan resolusi citra sehingga mampu menghasilkan fitur yang informatif dengan jumlah parameter yang lebih efisien dibandingkan banyak arsitektur CNN konvensional. Oleh karena itu, *EfficientNetB0* digunakan untuk menghasilkan representasi fitur citra ROI yang selanjutnya dimanfaatkan pada proses *clustering* menggunakan *K-Means*.

2.8 Clustering Menggunakan K-Means

Clustering merupakan teknik *unsupervised learning* yang bertujuan mengelompokkan data berdasarkan tingkat kemiripan karakteristik yang dimiliki. Pada metode ini, data yang memiliki karakteristik serupa akan ditempatkan dalam kelompok yang sama, sedangkan data yang memiliki karakteristik berbeda akan ditempatkan pada kelompok yang berbeda. *Clustering* banyak digunakan pada pengolahan citra medis untuk menemukan pola alami pada data tanpa memerlukan informasi label kelas sebelumnya (Salloum, 2025).

Salah satu algoritma *clustering* yang paling banyak digunakan adalah *K-Means*. Algoritma ini bekerja dengan membagi data ke dalam sejumlah cluster yang telah ditentukan sebelumnya berdasarkan kedekatan jarak antara data dan pusat cluster (*centroid*). Proses pengelompokan dilakukan secara iteratif hingga

posisi *centroid* menjadi stabil dan perubahan anggota cluster tidak lagi signifikan (Şevik dkk., 2019).

Pada bidang citra medis, *KMeans* telah digunakan untuk berbagai keperluan seperti segmentasi lesi kulit, segmentasi luka bakar, analisis citra kanker payudara, dan pengelompokan fitur citra medis lainnya. Penggunaan *KMeans* dinilai efektif karena memiliki implementasi yang sederhana, kebutuhan komputasi yang relatif rendah, serta kemampuan yang baik dalam mengelompokkan data berdasarkan kemiripan fitur visual (Salloum, 2025; Shamia dkk., 2025).

Kualitas hasil *clustering* sangat dipengaruhi oleh representasi fitur yang digunakan. Oleh karena itu, penggunaan fitur hasil ekstraksi CNN seperti *EfficientNet* dapat membantu menghasilkan kelompok data yang lebih representatif karena informasi visual yang digunakan telah melalui proses pembelajaran fitur secara mendalam (Findia Jiven, 2025).

Dalam penelitian ini, dataset citra luka bakar yang digunakan memiliki keterbatasan dalam hal ketersediaan anotasi label kelas yang karena dari awal dataset ini didapatkan tidak melakukan pelabelan. Oleh karena itu, untuk menjembatani hal tersebut, *K Means* digunakan sebagai metode pelabelan otomatis (*pseudo labeling*). Algoritma ini bertugas mengelompokkan representasi fitur hasil ekstraksi *EfficientNetB0* ke dalam tiga cluster yang disesuaikan dengan jumlah kategori tingkat keparahan luka bakar, yaitu derajat 1, derajat 2, dan derajat 3. Hasil clustering inilah yang kemudian dijadikan sebagai target kelas (label) untuk melatih model klasifikasi pada tahap selanjutnya.

2.9 *Pseudo Labeling*

Pseudo labeling merupakan teknik yang digunakan untuk memberikan label sementara (*pseudo label*) pada data yang belum memiliki anotasi. Label tersebut tidak berasal dari proses pelabelan manual oleh manusia, melainkan dibentuk secara otomatis berdasarkan hasil prediksi model atau hasil pengelompokan data yang memiliki karakteristik serupa. Pendekatan ini banyak digunakan pada kasus ketika jumlah data tidak berlabel jauh lebih besar dibandingkan data berlabel atau ketika proses anotasi memerlukan biaya dan waktu yang tinggi (Niu dkk., 2022).

Secara umum, *pseudo labeling* bertujuan untuk memanfaatkan informasi yang terdapat pada data tidak berlabel sehingga dapat digunakan dalam proses pembelajaran model. Melalui pendekatan ini, data yang semula tidak memiliki kelas dapat diberikan label sementara dan diperlakukan sebagai data berlabel pada tahap analisis berikutnya. Dengan demikian, *pseudo labeling* menjadi salah satu metode yang mampu menjembatani pendekatan *unsupervised learning* dan *supervised learning* dalam pengolahan data maupun citra digital (Niu dkk., 2022; Rahmati dkk., 2025).

Dalam konteks *clustering*, *pseudo labeling* dilakukan dengan mengubah hasil pengelompokan menjadi label kelas yang dapat digunakan pada proses klasifikasi. Algoritma *clustering* pada dasarnya hanya menghasilkan kelompok data berdasarkan tingkat kemiripan karakteristik yang dimiliki tanpa mengetahui arti atau kategori sebenarnya dari kelompok tersebut. Oleh karena itu, setiap cluster yang terbentuk perlu diinterpretasikan dan diberikan label tertentu sehingga hasil

clustering dapat dimanfaatkan sebagai target kelas pada proses pembelajaran berikutnya (Niu dkk., 2022).

Hubungan antara *clustering* dan *pseudo labeling* sangat erat karena hasil *clustering* sering digunakan sebagai dasar pembentukan *pseudo label*. Data yang berada pada cluster yang sama diasumsikan memiliki karakteristik yang serupa sehingga dapat diberikan label yang sama. Pendekatan ini memungkinkan struktur alami yang terdapat pada data dapat dimanfaatkan untuk menghasilkan label secara otomatis tanpa memerlukan anotasi manual pada seluruh sampel data (Rahmati dkk., 2025).

Penggunaan *pseudo labeling* memiliki beberapa keuntungan, antara lain mengurangi ketergantungan terhadap proses pelabelan manual, memanfaatkan data tidak berlabel secara lebih optimal, serta membantu pembentukan representasi data yang lebih baik pada proses pembelajaran selanjutnya. Selain itu, *pseudo labeling* juga dapat meningkatkan efisiensi pengembangan model karena jumlah data yang dapat digunakan untuk pelatihan menjadi lebih banyak dibandingkan hanya menggunakan data yang telah diberi label secara manual (Niu dkk., 2022; Rahmati dkk., 2025).

Meskipun demikian, kualitas *pseudo label* sangat bergantung pada kualitas proses pembentukannya. *Pseudo label* yang kurang akurat dapat menyebabkan kesalahan informasi yang berdampak pada penurunan performa model. Oleh karena itu, proses pembentukan *pseudo label* perlu didukung oleh representasi fitur yang baik serta metode *clustering* yang mampu menghasilkan kelompok data yang konsisten dan representatif. Semakin baik kualitas cluster yang terbentuk, semakin

besar kemungkinan *pseudo* label yang dihasilkan dapat merepresentasikan karakteristik sebenarnya dari data yang dianalisis (Niu dkk., 2022).

2.10 Evaluasi Model

Evaluasi kinerja model klasifikasi dalam sistem *machine learning* dan *deep learning* umumnya dilakukan menggunakan beberapa metrik utama untuk mengukur kemampuan model dalam membedakan kelas secara efektif. Metrik yang sering digunakan meliputi *precision*, *recall*, dan *F1-score* (Diptho & Basak, 2025).

a. Accuracy

Metrik ini menentukan persentase contoh yang diklasifikasikan dengan benar di antara total contoh, dengan definisinya dijelaskan dalam Persamaan (Diptho & Basak, 2025). Rumus *accuracy* dapat dilihat dengan Persamaan (2.1).

$$Accuracy = \frac{(TP + TN)}{Total Prediction} \quad (2.1)$$

Keterangan:

$TP = True Positive$;

$TN = True Negative$

b. Precision

Precision mengukur proporsi prediksi positif yang benar terhadap seluruh prediksi positif yang dihasilkan model, sehingga berkaitan dengan tingkat kesalahan *false positive* (Diptho & Basak, 2025). Rumus *Precision* dapat dilihat dengan Persamaan (2.2).

$$Precision = TP \frac{TP}{TP + FP} \quad (2.2)$$

Keterangan:

$TP = \text{True Positive}$

$FP = \text{False Positive}$

c. *Recall*

Mengukur kemampuan model dalam mendeteksi seluruh data positif yang sebenarnya, sehingga berhubungan dengan tingkat *false negative* (Diptho & Basak, 2025). Rumus *recall* dapat dilihat dengan Persamaan (2.3).

$$\text{Recall} = TP \frac{TP}{(TP + FN)} \quad (2.3)$$

Keterangan:

$TP = \text{True Positive};$

$FN = \text{False Negative}$

F1-Score

F1-Score merupakan rata-rata harmonis antara *precision* dan *recall*, yang memberikan evaluasi yang lebih seimbang terutama pada kondisi ketidakseimbangan kelas (*class imbalance*) (Diptho & Basak, 2025). Rumus *F1-Score* dapat dilihat dengan Persamaan (2.4).

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4)$$

2.11 Penelitian Terkait

Penelitian-penelitian terdahulu disajikan dalam bentuk tabel *State of The Art* (SOTA) untuk memberikan gambaran komparatif terhadap studi yang telah dilakukan sebelumnya. Penyajian ini bertujuan untuk menunjukkan posisi penelitian yang dilakukan saat ini serta mengidentifikasi celah penelitian berdasarkan aspek permasalahan, kontribusi, hasil yang diperoleh, dan keterbatasan

masing-masing studi. Tabel 2.1 memuat ringkasan penelitian terkait yang menjadi landasan dan acuan dalam pelaksanaan penelitian ini.

Tabel 2.1 *State of The Art* (SOTA)

No.	Konten	Penjelasan
1.	Judul	<i>AI-Driven Integrated System for Burn Depth Prediction With Electronic Medical Records: Algorithm Development and Validation</i> (M. M. Rahman dkk., 2025)
	Permasalahan	Ketidakakuratan dalam penilaian kedalaman luka bakar menggunakan inspeksi visual oleh ahli, terutama dalam membedakan antara luka bakar derajat kedua yang dalam dan derajat ketiga, dengan akurasi hanya sekitar 76% untuk ahli dan turun menjadi 50% untuk non-ahli. Kesalahan ini dapat menyebabkan perawatan yang tidak tepat, seperti penundaan pengobatan kritis atau prosedur yang berlebihan pada luka ringan
	Kontribusi/ Keterbaharuan	Menggunakan sistem AI multimodal BURN-AID yang mengintegrasikan foto digital dan <i>ultrasound</i> TDI dalam rekam medis elektronik (EMR), serta memberikan dukungan keputusan klinis real-time melalui penjelasan berbasis bahasa alami
	Hasil Utama	pengembangan sistem AI <i>multimodal</i> bernama BURN-AID yang mampu mengklasifikasikan kedalaman luka bakar (derajat pertama, kedua, dan ketiga) dengan akurasi keseluruhan sebesar 84%. Sistem ini mengintegrasikan foto digital dan <i>ultrasound</i> TDI dalam kerangka rekam medis elektronik (EMR) untuk mendukung pengambilan keputusan klinis secara real-time
	Kekurangan	Ukuran sampel yang relatif kecil membatasi generalisasi hasil penelitian. Variasi warna kulit juga menjadi tantangan karena dapat mempengaruhi akurasi klasifikasi berbasis gambar, meskipun upaya mitigasi telah dilakukan dengan memotong gambar hanya pada area luka
2.	Judul	<i>A Framework for Automatic Burn Image Segmentation and Burn Depth Diagnosis Using Deep Learning</i> (Liu dkk., 2021)
	Permasalahan	Kesulitan dalam penilaian kedalaman dan area luka bakar

No.	Konten	Penjelasan
		secara akurat dan otomatis, karena metode manual bersifat subjektif dan memerlukan keahlian khusus. Selain itu, keterbatasan dataset yang lengkap dan tantangan dalam membedakan tingkat kedalaman luka bakar secara visual juga menjadi masalah utama yang ingin diatasi dengan pendekatan deep learning untuk meningkatkan akurasi dan efisiensi diagnosis luka bakar.
	Kontribusi/ Keterbaharuan	Kontribusi penelitian ini adalah pengembangan <i>framework deep learning end-to-end</i> yang mampu melakukan <i>segmentasi</i> otomatis area luka bakar serta diagnosis kedalaman luka bakar secara akurat dari citra klinis. <i>Framework</i> ini juga dapat menghitung persentase luas luka bakar terhadap total luas permukaan tubuh (TBSA) dan mengatasi keterbatasan anotasi data dengan pendekatan <i>semi-supervised</i> , sehingga meningkatkan efisiensi dan akurasi diagnosis luka bakar secara otomatis
	Hasil Utama	Terciptanya <i>framework deep learning end-to-end</i> yang mampu melakukan segmentasi area luka bakar dengan akurasi tinggi (IOU mencapai 0.8467) serta diagnosis kedalaman luka bakar secara otomatis.
	Kekurangan	Performa prediksi yang kurang baik pada area dengan kedalaman luka bakar yang mirip, seperti antara <i>deep partial-thickness</i> dan <i>full-thickness</i> , serta ketidakseimbangan jumlah piksel pada berbagai kedalaman luka yang menyebabkan banyak kesalahan prediksi pada area background dan luka yang belum dibersihkan.
3.	Judul	<i>Application of multiple deep learning models for automatic burn wound assessment</i> (Chang dkk., 2023)
	Permasalahan	Ketidakakuratan dalam estimasi persentase luas permukaan tubuh yang terbakar (TBSA) oleh tenaga medis, termasuk ahli bedah luka bakar berpengalaman, yang dapat berdampak pada manajemen pasien luka bakar, terutama dalam resusitasi cairan yang tepat waktu dan akurat. Selain itu, metode manual yang digunakan saat ini sering kali tidak konsisten dan memerlukan waktu yang lama.
	Kontribusi/ Keterbaharuan	Penelitian ini berkontribusi dalam eksplorasi model yaitu dengan dua pendekatan yaitu menggunakan model klasik dan CNN

No.	Konten	Penjelasan
	Hasil Utama	Pengembangan sistem otomatis berbasis <i>deep learning</i> yang menggabungkan beberapa model untuk melakukan segmentasi luka bakar dan estimasi persentase luas permukaan tubuh yang terbakar (%TBSA) secara akurat. Penelitian ini juga memperkenalkan metode <i>preprocessing</i> dengan <i>superpixel segmentation</i> untuk segmentasi area luka bakar dalam (<i>deep burn</i>), serta menguji berbagai arsitektur model <i>deep learning</i> untuk meningkatkan performa penilaian luka bakar dalam kondisi klinis yang beragam
	Kekurangan	<i>Segmentasi</i> kedalaman luka bakar hanya menampilkan bagian yang paling <i>homogen</i> tanpa mencakup seluruh informasi kedalaman luka, model <i>machine learning</i> cenderung <i>overfit</i> pada data pelatihan sehingga hasilnya kurang baik pada gambar baru; serta kurangnya metode pelabelan standar untuk pelatihan model <i>deep learning</i> .
4.	Judul	<i>A deep convolutional neural network-based approach for detecting burn severity from skin burn images</i> (Suha & Sanam, 2022)
	Permasalahan	Kesulitan dalam melakukan penilaian kedalaman luka bakar secara akurat dan cepat menggunakan metode tradisional yang memerlukan pengawasan ahli medis, sementara luka bakar dapat berkembang dengan cepat dan memerlukan penanganan segera. Selain itu, teknik medis modern seperti laser <i>Doppler</i> imaging membutuhkan peralatan khusus dan tenaga ahli yang tidak selalu tersedia saat kejadian luka bakar terjadi.
	Kontribusi/ Keterbaharuan	Pengembangan metode klasifikasi otomatis luka bakar menggunakan model <i>Convolutional Neural Network</i> (CNN) dengan teknik <i>transfer learning</i> yang mampu meningkatkan akurasi dan efisiensi dalam menentukan tingkat kedalaman luka bakar secara cepat dan akurat tanpa memerlukan pengawasan ahli secara langsung
	Hasil Utama	Model Deep Convolutional Neural Network (DCNN) dengan <i>transfer learning</i> dan <i>fine tuning</i> mampu mengklasifikasikan tingkat keparahan luka bakar dengan akurasi yang jauh lebih tinggi dibandingkan metode tradisional. Model dengan <i>pretrained</i> VGG16 mencapai akurasi tertinggi sebesar 95,63%, sedangkan model CNN

No.	Konten	Penjelasan
		tanpa <i>transfer learning</i> hanya mencapai akurasi 72,01%.
	Kekurangan	Ketergantungan pada kualitas gambar yang tinggi, sehingga performa model dapat menurun jika gambar yang digunakan kurang jelas atau memiliki <i>noise</i> . Selain itu, penelitian ini masih terbatas pada penggunaan sejumlah <i>pretrained</i> model tertentu, sehingga belum mengeksplorasi potensi model lain yang mungkin dapat meningkatkan akurasi lebih lanjut.
5.	Judul	<i>Multi-Feature Extraction and Selection Method to Diagnose Burn Depth from Burn Images</i> (Zhang dkk., 2024)
	Permasalahan	Kesulitan dalam penilaian klinis awal kedalaman luka bakar yang akurat, karena diagnosis visual dan taktil oleh dokter memiliki tingkat akurasi yang bervariasi antara 50% hingga 80%, dengan perbedaan hingga 30% antar ahli. Selain itu, metode tradisional seperti Laser <i>Doppler Imaging</i> (LDI) memiliki keterbatasan akurasi di bawah 80% dalam 24–48 jam setelah cedera, serta biaya tinggi dan kalibrasi yang sulit.
	Kontribusi/ Keterbaharuan	Mengembangkan metode yang mampu mengekstraksi berbagai jenis fitur dari citra luka bakar, termasuk fitur warna, tekstur, dan fitur mendalam menggunakan jaringan Burn-ResNet51 yang dimodifikasi. Metode ini menggunakan seleksi fitur berbasis random forest untuk memilih fitur yang paling relevan, sehingga meningkatkan akurasi klasifikasi kedalaman luka bakar hingga 91,76% untuk klasifikasi dua kelas dan 80,74% untuk klasifikasi tiga kelas.
	Hasil Utama	Metode yang diusulkan mampu mengklasifikasikan kedalaman luka bakar dengan akurasi 91,76% untuk klasifikasi dua kelas dan 80,74% untuk klasifikasi tiga kelas. Metode ini menggabungkan fitur warna, tekstur, dan fitur mendalam yang diekstraksi menggunakan jaringan Burn-ResNet51 serta menggunakan seleksi fitur berbasis <i>random forest</i> untuk meningkatkan performa klasifikasi.
	Kekurangan	Kekurangan dalam penelitian ini keterbatasan jumlah data yang digunakan, kompleksitas komputasi akibat penggabungan berbagai fitur, ketergantungan pada tuning

No.	Konten	Penjelasan
		parameter, serta kesulitan dalam mengatasi variasi pencahayaan dan kondisi citra yang mempengaruhi akurasi klasifikasi
6.	Judul	<i>Deep Learning-Assisted Burn Wound Diagnosis Diagnostic Model Development Study</i> (Chang dkk., 2021)
	Permasalahan	Ketidakakuratan dalam perhitungan luas luka bakar (%TBSA) yang sering terjadi, dengan adanya perbedaan signifikan dalam estimasi antara dokter yang berbeda. Kesalahan ini dapat menyebabkan <i>overestimasi</i> atau <i>underestimasi</i> yang berdampak pada penanganan pasien
	Kontribusi/ Keterbaharuan	Menggunakan metode Mask R-CNN dengan backbone ResNet101 untuk <i>segmentasi</i> luka bakar dan estimasi persentase luas permukaan tubuh yang terbakar (%TBSA). Model ini mencapai akurasi segmentasi dengan <i>Dice Coefficient</i> (DC) sebesar 94%, yang menunjukkan performa yang sangat baik dalam mendeteksi dan mengukur area luka bakar secara otomatis. Akurasi ini lebih tinggi dibandingkan beberapa metode sebelumnya seperti Fuzzy-ARTMAP dan SVM yang memiliki akurasi di kisaran 82-90% untuk klasifikasi kedalaman luka bakar
	Hasil Utama	Metode Mask R-CNN dengan backbone ResNet101 yang mampu melakukan segmentasi luka bakar dengan akurasi tinggi, ditunjukkan oleh <i>Dice coefficient</i> (DC) sebesar 0.9496. Selain itu, metode ini berhasil menghitung persentase luas permukaan tubuh yang terbakar (%TBSA) dengan <i>deviasi</i> rata-rata hanya 0.115% dari <i>ground truth</i> , yang lebih kecil dibandingkan estimasi oleh ahli bedah.
	Kekurangan	Adanya keterbatasan ukuran dataset yang hanya berasal dari satu pusat medis sehingga kurang mewakili variasi luka bakar secara luas, kesulitan dalam konsistensi pelabelan kedalaman luka bakar yang menyebabkan <i>inkonsistensi</i> data, serta tantangan dalam mendeteksi luka bakar <i>superfisial</i> dan luka kecil yang tersebar. Selain itu, variabilitas kondisi pengambilan gambar dan perbedaan warna kulit juga mempengaruhi performa model.
7.	Judul	<i>Multiclass Burn Wound Image Classification Using Deep Convolutional Neural Networks</i> (Rostami dkk., 2021).
	Permasalahan	Permasalahan penelitian ini terbatasnya jumlah studi

No.	Konten	Penjelasan
		yang menggunakan metode <i>deep learning end-to-end</i> untuk klasifikasi gambar luka bakar, khususnya untuk klasifikasi <i>multi-kelas</i> . Sebagian besar penelitian sebelumnya hanya fokus pada klasifikasi <i>binary</i> dan sering menggabungkan ekstraksi fitur manual dengan classifier tradisional, sehingga belum optimal dalam hal efisiensi dan akurasi.
	Kontribusi/ Keterbaharuan	Kontribusi pada penelitian ini pengembangan metode klasifikasi gambar luka bakar menggunakan <i>deep convolutional neural networks</i> (DCNN) secara <i>end-to-end</i> untuk klasifikasi <i>multi-kelas</i> , yang mengatasi keterbatasan data dengan <i>transfer learning</i> dan <i>augmentasi</i> data, serta menghilangkan kebutuhan ekstraksi fitur manual sehingga meningkatkan akurasi dan efisiensi klasifikasi luka bakar.
	Hasil Utama	Metode alexNet yang telah di <i>fine-tune</i> berhasil meningkatkan akurasi klasifikasi menjadi sekitar 90% untuk klasifikasi dua kelas (<i>grafted</i> dan <i>non-grafted</i>) serta menunjukkan performa yang memuaskan untuk klasifikasi tiga kelas (<i>deep dermal</i> , <i>full-thickness</i> , dan <i>superficial dermal</i>) dengan peningkatan akurasi lebih dari 8% dibandingkan penelitian sebelumnya menggunakan dataset yang sama.
	Kekurangan	Kurangan pada penelitian ini keterbatasnya jumlah data yang digunakan untuk pelatihan, terutama pada klasifikasi multi-kelas, sehingga dapat menyebabkan penurunan akurasi akibat kurangnya data untuk melatih parameter jaringan yang lebih banyak.
8.	Judul	<i>Burns Depth Assessment Using Deep Learning Features</i> (Abubakar dkk., 2020)
	Permasalahan	Permasalahan pada penelitian ini ketidakakuratan dalam penilaian kedalaman luka bakar oleh klinisi, dengan akurasi yang hanya berkisar antara 60-80% karena kurangnya standar yang baku. Dan metode standar saat ini seperti <i>Laser Doppler Imaging</i> (LDI) meskipun akurat, memiliki keterbatasan seperti biaya tinggi, waktu pemeriksaan yang lama, dan memerlukan keahlian khusus
	Kontribusi/ Keterbaharuan	Kontribusi penelitian ini adalah pengenalan fitur citra ResFeat50 dan VggFeat16 yang diekstraksi dari model

No.	Konten	Penjelasan
		<i>pretrained</i> ResNet50 dan VGG16 untuk memprediksi waktu penyembuhan luka bakar pada kulit manusia, serta penggunaan <i>Support Vector Machines</i> (SVM) sebagai prediktor. Penelitian ini juga memberikan analisis mendalam mengenai fitur dengan pola diskriminatif kuat, perbandingan performa dan waktu komputasi antara ResFeat50 dan VggFeat16, serta pencapaian akurasi prediksi yang signifikan hingga 95,43%,
	Hasil Utama	Metode dalam penelitian menggunakan fitur citra dari model <i>pretrained</i> ResNet50 (ResFeat50) dan VGG16 (VggFeat16) dengan klasifikasi menggunakan <i>Support Vector Machines</i> (SVM) berhasil mencapai akurasi prediksi kedalaman luka bakar hingga 95,43% dengan ResFeat50 dan 85,67% dengan VggFeat16. Metode ini memungkinkan pengambilan keputusan dalam waktu kurang dari satu menit mengenai kebutuhan intervensi bedah seperti cangkok kulit,
	Kekurangan	Kekurangannya meliputi kesalahan klasifikasi yang masih terjadi terutama antara luka bakar derajat kedua (2DB) dan ketiga (3DB) akibat <i>heterogenitas</i> dataset dan campuran tipe luka dalam satu gambar. Selain itu, terdapat kesulitan membedakan antara kulit sehat dan luka bakar derajat ketiga karena kemiripan visual beberapa gambar 3DB yang tampak putih dan keras. Pengaruh pencahayaan buruk pada beberapa gambar juga menyebabkan kesalahan klasifikasi, khususnya pada luka bakar derajat pertama (1DB). Dan yang terakhir penelitian ini belum mengestimasi luas permukaan tubuh yang terkena luka bakar, padahal informasi ini penting untuk penentuan penanganan klinis seperti cangkok kulit
9.	Judul	<i>Development and evaluation of deep learning algorithms for assessment of acute burns and the need for surgery</i> (Boissin dkk., 2023)
	Permasalahan	kesulitan dalam menilai secara akurat luas dan kedalaman luka bakar akut secara visual oleh tenaga medis di garis depan, yang sering kali mengakibatkan kesalahan diagnosis hingga 25–39%. Kesalahan ini berdampak besar pada pasien dan pusat luka bakar, terutama dalam membedakan luka yang memerlukan intervensi bedah

No.	Konten	Penjelasan
		dari yang dapat sembuh secara konservatif.
	Kontribusi/ Keterbaharuan	Penelitian ini berkontribusi pada pengembangan dan evaluasi algoritma deep learning berbasis <i>Convolutional Neural Networks</i> (CNN) yang mampu secara otomatis mengidentifikasi area luka bakar dan mengklasifikasikan kebutuhan intervensi bedah berdasarkan kedalaman luka dari citra digital.
	Hasil Utama	Penggunaan dua algoritma <i>deep learning</i> berbasis citra yang mampu mengidentifikasi area luka bakar dengan akurasi rata-rata 87,2% dan mengklasifikasikan kebutuhan intervensi bedah dengan nilai AUC sebesar 0,885. Algoritma identifikasi luka lebih akurat pada tipe kulit gelap, sedangkan algoritma klasifikasi lebih akurat pada tipe kulit terang.
	Kekurangan	kebutuhan akan dataset yang lebih besar dan beragam dengan <i>anotasi</i> yang lebih detail untuk meningkatkan akurasi dan generalisasi algoritma.
10.	Judul	<i>Automated skin burn detection and severity classification using YOLO Convolutional Neural Network Pretrained Model</i> (Ferdinand dkk., 2023)
	Permasalahan	Permasalahan pada penelitian yang diangkat mengenai kesulitan dalam membedakan tingkat keparahan luka bakar, terutama antara luka bakar derajat kedua dan ketiga, yang seringkali memiliki perbedaan minimal sehingga dapat menyebabkan penanganan yang kurang tepat. Kesalahan dalam penilaian ini dapat menyebabkan luka yang seharusnya mendapat perawatan khusus justru terlambat ditangani, sehingga memperburuk kondisi dan efek negatif pada kulit yang terluka maupun jaringan di sekitarnya.
	Kontribusi/ Keterbaharuan	Penelitian ini berkontribusi dalam pengembangan dan <i>fine-tuning</i> model YOLO (terutama YOLOv5 dan YOLOv7) untuk deteksi dan klasifikasi tingkat keparahan luka bakar kulit secara otomatis dengan akurasi yang meningkat. Penelitian ini berhasil menggabungkan dataset dari berbagai sumber, menerapkan hyperparameter tuning menggunakan metode evolusi, serta menunjukkan peningkatan performa model dalam metrik F1-Score dan mAP yang signifikan.

No.	Konten	Penjelasan
	Hasil Utama	Model YOLOv5l yang telah di <i>fine-tune</i> berhasil mencapai peningkatan performa dengan F1-Score sebesar 75.9%, mAP@0.5 sebesar 83.1%, dan mAP@0.5:0.95 sebesar 82.9%. Hal ini menunjukkan bahwa proses <i>fine-tuning hyperparameter</i> dapat meningkatkan akurasi deteksi dan klasifikasi tingkat keparahan luka bakar secara signifikan, sehingga model ini berpotensi untuk diterapkan dalam situasi nyata untuk membantu penanganan medis luka bakar.
	Kekurangan	Kekurangannya masih ada tantangan dalam membedakan secara akurat antara luka bakar derajat kedua dan ketiga karena perbedaan yang minimal, serta keterbatasan jumlah dan variasi dataset yang digunakan untuk pelatihan model. Selain itu, meskipun <i>fine-tuning hyperparameter</i> dapat meningkatkan performa, masih diperlukan pengembangan lebih lanjut seperti penambahan data augmentasi dan peningkatan jumlah data untuk mencapai hasil yang lebih optimal
11.	Judul	<i>Multi-Class Wound Classification via High and Low-Frequency Guidance Network</i> (Guo dkk., 2023)
	Permasalahan	Permasalahan yang terdapat di penelitian ini tantangan dalam melakukan klasifikasi multi-kelas luka berdasarkan dataset gambar luka yang terbatas, serta kebutuhan untuk meningkatkan akurasi dan efisiensi klasifikasi luka guna membantu diagnosis dan perencanaan pengobatan yang lebih tepat.
	Kontribusi/ Keterbaharuan	Penelitian ini memberikan kontribusi untuk pengembangan model klasifikasi luka <i>multi-kelas</i> bernama HLG-Net yang menggunakan arsitektur <i>dual-branch</i> untuk menangkap informasi frekuensi tinggi dan rendah secara bersamaan. Pendekatan ini memungkinkan model untuk menangkap fitur tekstur detail dan struktur global luka secara lebih komprehensif, sehingga meningkatkan performa klasifikasi dibandingkan metode sebelumnya.
	Hasil Utama	Model HLG-Net menunjukkan performa klasifikasi luka yang baik pada berbagai tugas klasifikasi (dua kelas, tiga kelas, dan empat kelas) dengan akurasi, presisi, recall, dan F1-score yang tinggi, terutama saat menggunakan

No.	Konten	Penjelasan
		gambar luka utuh dibandingkan dengan ROI. Model ini mampu membedakan jenis luka seperti luka bedah dan luka vena dengan akurasi hingga 98%, serta memiliki nilai AUC mendekati 1 untuk beberapa klasifikasi biner.
	Kekurangan	kurangnya keberagaman dataset sampel yang menyebabkan kemampuan generalisasi model menjadi terbatas.
12.	Judul	<i>KLASIFIKASI PENYAKIT KULIT MENGGUNAKAN YOLOv11</i> (Tappi & Dewi, 2025)
	Permasalahan	Permasalahan pada penelitian ini yaitu tingginya risiko penularan dan dampak negatif penyakit kulit yang dapat menular melalui kontak langsung maupun benda, serta pentingnya diagnosis dini untuk meningkatkan peluang kesembuhan, terutama pada penyakit serius seperti kanker kulit. Selain itu, keterbatasan metode sebelumnya dalam akurasi dan efisiensi deteksi penyakit kulit mendorong penggunaan teknologi <i>machine learning</i> , khususnya algoritma YOLOv11, untuk meningkatkan performa deteksi secara real-time dan akurat.
	Kontribusi/ Keterbaharuan	Kontribusi dalam penelitian ini berupa pengembangan model deteksi penyakit kulit menggunakan algoritma YOLOv11 yang mampu mengidentifikasi empat jenis penyakit kulit dengan akurasi mencapai 79%, lebih tinggi dibandingkan metode sebelumnya seperti <i>Image Processing</i> dan ANN. Penelitian ini juga menerapkan teknik augmentasi data untuk meningkatkan ketangguhan model serta menunjukkan bahwa YOLOv11 efektif dalam deteksi real-time dengan presisi dan recall yang stabil, khususnya untuk penyakit <i>Actinic Keratosis</i> dan <i>Basal Cell Carcinoma</i>
	Hasil Utama	Menggunakan algoritma YOLOv11 yang mencapai akurasi sebesar 79%, lebih tinggi dibandingkan metode sebelumnya seperti <i>Image Processing</i> dan ANN yang hanya mencapai 72%. Model ini menunjukkan performa yang baik terutama pada penyakit <i>Actinic Keratosis</i> dengan precision 0,92 dan <i>Basal Cell Carcinoma</i> dengan recall 0,96, meskipun performa untuk Melanoma lebih rendah akibat ketidakseimbangan kelas dalam dataset.
	Kekurangan	Ukuran dataset yang relatif terbatas sehingga

No.	Konten	Penjelasan
		memengaruhi kemampuan generalisasi model, adanya variabilitas kualitas gambar dan pencahayaan, serta ketidakseimbangan kelas yang menyebabkan performa model kurang merata, terutama pada deteksi <i>Melanoma</i> . Selain itu, keberadaan objek lain dalam gambar validasi juga berpotensi mengurangi akurasi deteksi.
13.	Judul	<i>YOLOv7-PSA, an intelligent detection model, is designed for assessing the severity of skin burns (Luo dkk., 2025)</i>
	Permasalahan	Permasalahan yang mendasari penelitian ini adalah kesulitan dalam menentukan tingkat keparahan luka bakar secara akurat dan tepat waktu menggunakan metode tradisional seperti observasi visual dan penilaian fisik yang subjektif. Keterlambatan atau ketidakakuratan diagnosis dapat menyebabkan waktu penyembuhan luka yang lebih lama dan komplikasi serius seperti sindrom <i>disfungsi multiorgan</i> .
	Kontribusi/ Keterbaharuan	Kontribusi pada penelitian ini berupa pengembangan model deteksi tingkat keparahan luka bakar berbasis deep learning dengan menggunakan YOLOv7-PSA yang menggabungkan mekanisme Pyramid Split Attention (PSA). Model ini mampu melakukan deteksi secara real-time dengan akurasi tinggi dan stabil pada berbagai skala luka bakar, sehingga meningkatkan kecepatan dan ketepatan diagnosis dibandingkan metode tradisional
	Hasil Utama	YOLOv7-PSA, yang mampu mencapai akurasi deteksi sebesar 86% untuk luka bakar derajat pertama, 87% untuk derajat kedua, dan 91% untuk derajat ketiga. Model ini menunjukkan performa yang lebih baik dibandingkan model sebelumnya dan memiliki potensi untuk meningkatkan efisiensi dan ketepatan diagnosis luka bakar secara real-time.
	Kekurangan	Terdapat ukuran dan keberagaman dataset yang masih terbatas, terutama dominasi gambar luka bakar pada kulit dengan warna dan tipe tertentu (misalnya kulit Asia) serta fokus pada luka di ekstremitas tubuh, sehingga model kurang generalisasi untuk populasi dan kondisi luka yang lebih luas. Dan Kesulitan dalam mendeteksi luka bakar pada kondisi pencahayaan yang buruk dan objek target yang berukuran kecil.

No.	Konten	Penjelasan
14.	Judul	<i>YOLO11 APPLIED TO THE SEGMENTASI AND CLASSIFICATION OF SKIN BURN</i> (Avena-Caro dkk., 2025)
	Permasalahan	Rendahnya akurasi diagnosis kedalaman luka bakar yang biasanya dilakukan melalui inspeksi visual, terutama oleh tenaga medis yang tidak memiliki spesialisasi dalam penanganan luka bakar. Akurasi diagnosis tersebut kurang dari 50%, yang menjadi kendala serius terutama di daerah dengan sumber daya dan infrastruktur medis terbatas. Hal ini menyebabkan perlunya pengembangan model berbasis kecerdasan buatan untuk membantu identifikasi dan klasifikasi luka bakar secara lebih akurat dan cepat.
	Kontribusi/ Keterbaharuan	Evaluasi model segmentasi luka bakar berbasis YOLOv11 yang mampu melakukan segmentasi dan klasifikasi luka bakar derajat pertama, kedua, dan ketiga secara otomatis pada tingkat piksel (<i>instance segmentation</i>). Model ini memberikan <i>delimitasi</i> area luka yang lebih akurat dibandingkan metode deteksi berbasis <i>bounding box</i> , sehingga memberikan nilai klinis tambahan untuk diagnosis dan perawatan luka bakar.
	Hasil Utama	Model berbasis YOLOv11 berhasil melakukan segmentasi dan klasifikasi luka bakar derajat pertama, kedua, dan ketiga secara otomatis dari gambar. Model ini menunjukkan kinerja terbaik dalam mendeteksi luka bakar derajat ketiga dengan nilai presisi 0.675, recall 0.774, dan mAP50 sebesar 0.67.
	Kekurangan	Model memiliki keterbatasan dalam mendeteksi luka bakar derajat pertama dan kedua, yang tercermin dari rendahnya nilai recall dan banyaknya <i>false negatives</i> . Hal ini menunjukkan sensitivitas model yang masih kurang dalam mengidentifikasi luka bakar dengan karakteristik yang kurang jelas atau lebih superfisial.
15.	Judul	<i>Skin Lesion Classification Using YOLOv11 on the HAM10000 Dataset</i> (Wicaksana dkk., 2025)
	Permasalahan	Terdapat tingginya angka kematian akibat kanker kulit, khususnya melanoma yang memiliki tingkat

No.	Konten	Penjelasan
		kelangsungan hidup yang rendah, serta keterbatasan metode diagnostik tradisional yang sangat bergantung pada pengalaman dokter kulit sehingga rentan terhadap subjektivitas dan kesalahan diagnosis. Oleh karena itu, diperlukan teknologi canggih seperti <i>deep learning</i> untuk meningkatkan akurasi dan konsistensi dalam klasifikasi lesi kulit dari gambar <i>dermatoskopi</i> .
	Kontribusi/ Keterbaharuan	Penelitian ini memberikan arsitektur dan kinerja tiga model <i>deep learning</i> , yaitu YOLOv11, VGG19, dan ResNet50, dalam klasifikasi lesi kulit menggunakan dataset HAM10000. YOLOv11 menggunakan <i>backbone</i> dengan blok C3k2 dan modul SPPF untuk ekstraksi fitur multi-skala yang efisien, serta blok C2PSA untuk fusi fitur berbasis perhatian. Sementara itu, VGG19 dan ResNet50 merupakan model <i>multi-stage</i> dengan pendekatan <i>fine-tuning</i> pada lapisan akhir setelah membekukan lapisan awal. Penelitian ini juga menerapkan teknik augmentasi data seperti rotasi dan <i>flipping</i> untuk mengatasi ketidakseimbangan kelas dan meningkatkan performa model.
	Hasil Utama	Menunjukkan model YOLOv11x-cls yang dilatih dengan dataset yang telah diaugmentasi mencapai akurasi sebesar 84,74%, presisi 83,94%, recall 84,74%, dan F1-score 84,06%. Namun, model VGG19 mencatat akurasi tertinggi sebesar 89,68%, mengungguli YOLOv11. Teknik augmentasi data terbukti efektif dalam meningkatkan performa model dengan mengatasi ketidakseimbangan kelas.
	Kekurangan	Meskipun penggunaan model YOLOv11 menunjukkan kinerja yang kompetitif, performanya masih belum mampu melampaui model <i>multi-stage</i> seperti VGG19 dan ResNet50 yang memiliki kemampuan ekstraksi fitur hierarkis lebih baik. Selain itu, penelitian ini masih terbatas pada teknik <i>augmentasi</i> data dasar dan belum mengeksplorasi metode <i>augmentasi</i> atau model yang lebih canggih untuk mengatasi tantangan ketidakseimbangan kelas dan meningkatkan akurasi lebih lanjut

Banyak penelitian mengenai klasifikasi tingkat keparahan dan kedalaman luka bakar telah dilakukan menggunakan pendekatan *computer vision*. Beberapa penelitian seperti (Abubakar dkk., 2020; Chang dkk., 2021; Ferdinand dkk., 2023; Rostami dkk., 2021; Suha & Sanam, 2022) telah memanfaatkan model *Convolutional Neural Network* (CNN) dan *Transfer Learning* dengan berbagai arsitektur seperti VGG16, ResNet101, AlexNet, hingga varian YOLO (YOLOv5 dan YOLOv7) untuk mengekstraksi fitur visual citra luka bakar. Walaupun penelitian-penelitian tersebut berhasil meningkatkan performa dibandingkan metode observasi klinis tradisional (Liu dkk., 2021; M. M. Rahman dkk., 2025) akurasi yang dihasilkan masih sangat dipengaruhi oleh kualitas input citra. Terdapat permasalahan identik yang sering muncul, yaitu tingginya gangguan dari latar belakang citra (*background noise*) seperti seprai, pakaian, atau alat medis, yang seringkali ikut terekstraksi sebagai fitur sehingga mengaburkan perbedaan visual antara luka bakar derajat dua dan derajat (Abubakar dkk., 2020; Ferdinand dkk., 2023; Liu dkk., 2021) .

Berdasarkan kondisi tersebut, masih terdapat kebutuhan untuk mengkaji apakah pemfokusan area luka melalui pendekatan *Region of Interest* (ROI) dapat meningkatkan kualitas masukan dan kinerja klasifikasi tingkat keparahan luka bakar. Selain itu, penelitian yang secara khusus membandingkan performa klasifikasi antara penggunaan citra utuh dan citra ROI hasil deteksi otomatis menggunakan YOLOv11s masih terbatas. Oleh karena itu, penelitian ini mengintegrasikan deteksi area luka menggunakan YOLOv11s dengan klasifikasi

menggunakan *EfficientNetB0* untuk menganalisis pengaruh penggunaan ROI terhadap kinerja klasifikasi tingkat keparahan luka bakar.

Peneliti	Tujuan				Algoritma	Metode ROI/Deteksi	Arsitektur CNN							
	Klasifikasi	Deteksi	Segmentasi	Prediksi			<i>Dartnet</i>	<i>ResNet</i>	<i>DenseNet</i>	<i>VGG</i>	<i>AlexNet</i>	<i>C3k2 (v11)</i>	<i>EfficientNet</i>	<i>Custom</i>
dkk., 2023)														
(Ferdinand dkk., 2023)	-	✓	-	-	YOLOv5 & v7	Bounding Box	✓	-	-	-	-	-	-	-
(Guo dkk., 2023)	✓	-	-	-	HLG-Net	Citra Utuh	-	✓	-	-	-	-	-	-
(Tappi & Dewi, 2025)	-	✓	-	-	YOLOv11	Bounding Box	-	-	-	-	-	✓	-	
(Luo dkk., 2025)	-	✓	-	-	YOLOv7-PSA	Bounding Box	-	-	-	-	-	-	-	-
(Avena-Caro dkk., 2025)	-	-	✓	-	YOLOv11	Instance Seg.	-	-	-	-	-	✓	-	-
(Wicaksana dkk., 2025)	✓	-	-	-	YOLOv11	-	-	-	-	-	-	-	-	-
(Ours)	✓	-	-	-	YOLOv11 + CNN	Auto-ROI (v11)	-	-	-	-	-	-	✓	-