

BAB II


TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Menurut Zhu dkk. (2021), pengembangan kerangka kerja berbasis *deep learning* untuk diagnosis multi-penyakit kulit di lingkungan klinis dilakukan menggunakan algoritma *CNN*. Penelitian ini memfokuskan pada deteksi berbagai kondisi kulit secara bersamaan dengan akurasi tinggi. Pendekatan ini memanfaatkan kemampuan *deep learning* untuk menganalisis data citra kulit secara otomatis, meskipun penelitian ini tidak spesifik untuk mendeteksi *keloid scars*.

Menurut Sengkey dkk. (2024), pengembangan aplikasi berbasis *android* untuk mengidentifikasi lesi kulit menggunakan *CNN* melibatkan akuisisi citra melalui perangkat *mobile*. Penelitian ini menyoroti implementasi model *deep learning* pada aplikasi *mobile* untuk mendeteksi berbagai jenis lesi kulit dengan hasil yang menjanjikan. Akan tetapi, cakupan penelitian ini mencakup banyak jenis lesi tanpa fokus spesifik pada *keloid scars*.

Menurut Li dkk. (2022), deteksi *keloid scars* dilakukan melalui integrasi *speckle contrast imaging* dengan model *deep learning*. Alur kerja ini melibatkan akuisisi citra berbasis *laser*, yang memberikan hasil akurasi yang tinggi. Namun, pendekatan ini memerlukan perangkat keras khusus, sehingga membatasi skalabilitas untuk aplikasi *mobile* yang sederhana. Penerapan teknologi tersebut bisa dilihat pada Gambar 2.1 di bawah ini.



Gambar 2.1 Deteksi *Keloid* dengan analisis LSCI(Li dkk.,2022)

Pada hasil segmentasi dan pemotongan modul yang diusulkan yang terdapat pada Gambar 2.1, terdapat tiga contoh yang menunjukkan perbedaan tahap *keloid scars*. Setiap gambar terdiri dari lima kolom yang menggambarkan proses analisis. Kolom pertama menunjukkan gambar dengan intensitas asli, kolom kedua berisi anotasi manual, kolom ketiga menampilkan hasil segmentasi otomatis, kolom keempat memperlihatkan gambar perfusi darah asli, dan kolom terakhir menunjukkan gambar perfusi darah setelah dipotong. Baris pertama menggambarkan *keloid scars* dalam tahap progresif, baris tengah menunjukkan *keloid scars* dalam tahap stabil, dan baris terakhir menunjukkan *keloid scars* dalam tahap regresif. Hasil segmentasi ini dapat digunakan untuk memantau perubahan *keloid scars* dalam berbagai tahap perkembangannya.

Menurut Righetti dkk. (2024), deteksi jaringan parut pada gambar MRI jantung dilakukan dengan menggunakan pendekatan pembelajaran yang mendalam, khususnya CNN. Penelitian ini menggabungkan citra parametrik yang dihitung dari gambar *cine* MRI jantung untuk meningkatkan akurasi deteksi jaringan parut. Model CNN yang digunakan dalam penelitian ini adalah arsitektur 3D CNN yang mampu memproses informasi spasial dari citra 3D dan memberikan hasil yang lebih akurat dibandingkan dengan pendekatan 2D. Akurasi model yang dihasilkan mencapai tingkat yang sangat tinggi dalam mendeteksi keberadaan jaringan parut miokard, menunjukkan efektivitas penggunaan CNN dalam analisis gambar medis yang kompleks.

Menurut Junayed dkk. (2022), deteksi jaringan parut pada gambar kulit dilakukan menggunakan model *CNN* untuk mendeteksi keberadaan bekas luka jerawat yang seringkali muncul sebagai hasil dari peradangan jerawat. Model *CNN* yang digunakan adalah arsitektur *ScarNet*, sebuah model *deep learning* novel 19-lapis yang sangat efektif dalam mengekstraksi peta fitur mendalam pada gambar kulit dengan meminimalkan biaya komputasi. Akurasi model yang dicapai dalam penelitian ini adalah 92,53%, menunjukkan kinerja yang sangat baik dalam mengklasifikasikan jenis bekas luka jerawat pada gambar kulit.

Menurut Cheng dkk. (2021) deteksi berbagai lesi pada gambar fundus mata dilakukan menggunakan model klasifikasi multi-label berbasis *graph convolutional network* (*GCN*). Model ini, yang mengintegrasikan ekstraksi fitur dari *ResNet-101*, dirancang untuk mendeteksi 8 jenis lesi fundus secara bersamaan, termasuk *scar laser*, *drusen*, dan perdarahan. Akurasi per kelas (*Acc*) untuk deteksi *scar laser* mencapai 0.986, menunjukkan kinerja yang sangat baik dalam mengidentifikasi lesi pada gambar fundus mata.

Menurut penelitian yang dilakukan oleh Hermosilla dkk. (2024) penggunaan model *CNN* untuk mendeteksi dan mengklasifikasikan kanker kulit dari citra *dermoskopi* dievaluasi berdasarkan kemampuan berbagai arsitektur, seperti *ResNet*, *DenseNet*, dan *Inception*, dalam mengidentifikasi lesi kulit dengan tingkat kompleksitas yang bervariasi. Walaupun begitu, tantangan utama yang diidentifikasi dalam penelitian ini meliputi akurasi yang dipengaruhi oleh kualitas gambar, keberagaman *dataset*, dan latar belakang yang kompleks dalam citra. Akurasi model yang digunakan bervariasi antara 60% hingga 90%, tergantung pada kompleksitas data dan teknik *preprocessing* yang diterapkan. Penelitian ini menekankan pentingnya augmentasi data, penyaringan fitur yang optimal, dan validasi menyeluruh untuk meningkatkan kinerja model dalam kondisi dunia nyata.


Dermoskopi merupakan salah satu metode non-invasif yang digunakan dalam diagnosis *keloid scars* dan *hypertrophic scars*, dengan kemampuan untuk menganalisis struktur vaskular dan karakteristik jaringan parut secara rinci. Melalui *dermoskopi*, pola vaskularisasi, warna, dan tekstur permukaan jaringan dapat diidentifikasi, sehingga membantu membedakan *keloid scars* dari *hypertrophic scars* maupun

kondisi kulit lainnya. Penelitian oleh Yoo dan Kim (2014) menunjukkan bahwa *dermoskopi* dapat mengungkap pola vaskular yang khas pada *keloid scars*, seperti distribusi pembuluh darah yang berkelompok dan warna merah cerah akibat hipervaskularisasi, yang membedakannya dari *hypertrophic scars* dengan pola vaskular yang lebih teratur dan kurang intens. Dengan alat ini, dokter kulit dapat melakukan evaluasi yang lebih mendalam tanpa memerlukan biopsi, sehingga menjadi alat bantu yang penting dalam diagnosis klinis *keloid scars* dan *hypertrophic scars*, terutama di klinik dermatologi.



Gambar 2.2 Deteksi *Keloid* dengan dermoskopi(Yoo dan Kim., 2014)

Pada Gambar 2.2 memperlihatkan temuan klinis dan *dermoskopi* pasien dengan *keloid scars*, terdapat variasi dalam morfologi dan struktur pembuluh darah yang dapat diamati. Pada gambar (A), terlihat nodul keras eritematosa besar di dada, di mana pembuluh darah berbentuk koma terlihat dengan jelas. Pada gambar (B), ditemukan beberapa nodul keras eritematosa di dada, dengan pembuluh darah bercabang yang terlihat. Sementara itu, pada gambar (C), beberapa nodul keras eritematosa juga terlihat di dada, namun pembuluh darah yang teramati menunjukkan pola linear yang tidak teratur. Temuan ini menggambarkan perbedaan dalam pola pembuluh darah yang dapat menjadi petunjuk penting dalam diagnosis *keloid*.




Gambar 2.3 Deteksi *Hypertrophic* dengan dermoskopi(Yoo dan Kim., 2014)

Pada Gambar 2.3 memperlihatkan temuan klinis dan *dermoskopi* pasien dengan bekas luka hipertrofik, terdapat ciri khas yang dapat diamati pada lesi yang terbentuk. Pada gambar (A), terlihat nodul keras berbentuk kubah di dagu tanpa adanya struktur vaskular yang tampak. Pada gambar (B), ditemukan nodul keras eritematosa berbentuk kubah di punggung, yang juga tidak menunjukkan adanya struktur vaskular. Begitu pula pada gambar (C), nodul ^{keras} eritematosa berbentuk kubah terlihat di dada, tanpa adanya struktur vaskular yang terlihat. Temuan ini menunjukkan bahwa pada bekas luka *hypertrophic*, tidak ditemukan pembuluh darah yang tampak pada pemeriksaan *dermoskopi*, yang membedakannya dari kondisi seperti *keloid*.

Pada Teknologi lain seperti *ultrasound* beresolusi tinggi merupakan salah satu teknik pencitraan non-invasif yang digunakan untuk diagnosis dan evaluasi jaringan *keloid scars* serta *hypertrophic scars*. Dalam penelitian Huang dkk. (2020), *ultrasound* dikombinasikan dengan *shear wave elastography (SWE)* untuk menilai karakteristik jaringan secara kuantitatif, seperti kedalaman, ketebalan, dan kekakuan jaringan parut.

Teknologi ini memberikan gambaran yang jelas mengenai distribusi dan kepadatan jaringan kolagen pada *keloid scars*, yang biasanya lebih padat dibandingkan dengan *hypertrophic scars*. Selain itu, *SWE* mampu mengukur elastisitas jaringan, yang dapat menjadi indikator aktivitas biologis *keloid scars*, seperti tingkat proliferasi dan inflamasi. Dengan pendekatan ini, *ultrasound* tidak hanya membantu membedakan *keloid scars* dari *hypertrophic scars* secara lebih akurat tetapi juga memungkinkan pemantauan respons terhadap terapi secara objektif. Keunggulan *ultrasound* adalah sifatnya yang non-invasif, *real-time*, dan mudah diakses, sehingga menjadi alat yang sangat efektif dalam diagnosis dan penilaian jaringan *keloid scars* dalam praktik klinis.



Gambar 2.4 Deteksi *Keloid Scars* dengan Ultrasonografi(Huang dkk., 2020)

Pada Gambar 2.4 menggunakan *elastography* untuk menggambarkan perbedaan kekakuan jaringan pada kulit normal dan *keloid scars* dalam kondisi yang berbeda. Gambar *elastography* menunjukkan tiga kondisi seperti kulit normal (A), *keloid scars* tanpa pengobatan (B), dan *keloid scars* yang diobati dengan suntikan steroid (C), yang diambil dari pasien yang sama. Hasil menunjukkan penurunan kekakuan jaringan setelah terapi, yang tercermin dalam penurunan *modulus young* dan kecepatan gelombang geser.

Pada citra *elastography* pada Gambar 2.4, warna yang berbeda menunjukkan tingkat kekakuan jaringan, dengan warna gelap menunjukkan kekakuan tinggi dan warna terang menunjukkan kekakuan rendah. Kotak-kotak pengukuran, atau *region of interest (ROI)*, digunakan untuk menghitung nilai-nilai seperti *mean stiffness*, *minimum stiffness*, dan *maximum stiffness*. *Elastography* menggunakan skala pengukuran dalam *kPa* atau *m/s* untuk *modulus elastisitas* dan kecepatan

gelombang geser. Penggunaan *high frequency ultrasound* memungkinkan visualisasi jaringan dengan resolusi tinggi, menghasilkan data yang akurat mengenai perubahan kekakuan.

Pengolahan citra digital telah digunakan secara luas dalam diagnosis jaringan parut, termasuk *keloid scars* dan *hypertrophic scars*, untuk memberikan analisis yang lebih objektif dan kuantitatif. Teknik ini melibatkan proses pengolahan gambar medis, seperti gambar *ultrasonografi*, *dermoskopi*, atau kamera biasa, dengan algoritma berbasis pengolahan citra untuk mengekstraksi fitur struktural dan tekstural dari jaringan parut. Dalam penelitian Maknuna dkk. (2022), pengolahan citra digital digunakan untuk analisis struktural dan karakterisasi jaringan parut secara kuantitatif. Dengan bantuan algoritma pengolahan citra, fitur seperti ketebalan jaringan, distribusi kolagen, dan pola vaskular dapat diidentifikasi secara otomatis. Teknologi ini memungkinkan mengidentifikasi perbedaan karakteristik antara *keloid scars* dan *hypertrophic scars*, sehingga mendukung diagnosis yang lebih akurat. Keunggulan utama dari pendekatan ini adalah sifatnya yang non-invasif, serta kemampuannya untuk menghasilkan data kuantitatif yang dapat digunakan dalam evaluasi klinis maupun penelitian. Pengolahan citra digital juga membuka peluang untuk mengotomasi proses diagnosis, sehingga mengurangi subjektivitas dan ketergantungan pada pengalaman klinis individu. Hal ini menjadikan pengolahan citra digital sebagai langkah penting dalam meningkatkan efisiensi dan akurasi diagnosis jaringan parut.

Berikut adalah tabel 2.1 yang berisi perbandingan penelitian terdahulu terkait klasifikasi *scars*:

Tabel 2.1 Penelitian Terdahulu

Peneliti	Tujuan	Model	Hasil	GAP
(Zhu dkk., 2021)	Mengembangkan <i>framework deep learning</i> untuk diagnosis berbagai penyakit kulit di lingkungan klinis.	EfficientNet-b4 (15 class)	94.80%	Efektivitas berkurang pada dataset dengan variasi tinggi, seperti latar belakang kompleks atau pencahayaan buruk.
(Li dkk., 2022)	Mengembangkan alur kerja untuk evaluasi <i>keloid</i> berbasis citra <i>laser speckle</i> dan <i>deep learning</i> .	Vision Transformer (VIT). (3 class)	92.7%	Model ini diuji pada data lama, sehingga mungkin kurang akurat untuk keloid pascaoperasi baru.
(Righetti dkk., 2024)	mengembangkan dan mengevaluasi pendekatan pembelajaran mendalam, khususnya menggunakan CNN, dalam mendeteksi	3D U Net	79%	Hanya fokus pada cine MRI jantung, sedangkan banyak jenis citra medis lainnya (misalnya CT scan atau ultrasound) yang mungkin tidak dapat dideteksi dengan model

	keberadaan jaringan parut miokard pada citra MRI jantung cine.			yang sama tanpa adaptasi lebih lanjut.
(Ma dkk., 2021)	mengembangkan model klasifikasi multi-label berbasis GCN untuk mendeteksi delapan jenis lesi fundus secara simultan. Model ini bertujuan untuk membantu dokter dalam diagnosis dan memungkinkan skrining lesi fundus skala besar yang cepat dan efisien.	Graph Convolutional Network & Resnet-101 <i>8(class)</i>	94.4%	Model menunjukkan kemampuan deteksi yang kurang baik untuk mikroaneurisma, eksudat lunak, dan eksudat keras. Hal ini disebabkan oleh kesulitan membedakan mikroaneurisma dari latar belakang dan tantangan dalam mengekstraksi fitur lesi ketika eksudat lunak dan keras seringkali disertai lesi lain..
(Junayed dkk., 2022)	untuk mengembangkan sistem klasifikasi bekas luka jerawat otomatis	ScarNet <i>(5 Class)</i>	92.53%	Penelitian ini berencana untuk memperluas dataset bekas luka jerawat dengan lebih banyak gambar dan

	menggunakan model Deep Convolutional Neural Network (CNN) yang baru, bernama ScarNet. Sistem ini bertujuan untuk mengatasi keterbatasan metode manual yang memakan waktu dan rentan terhadap variabilitas.			kelas, serta mengembangkan sistem otomatis untuk mendeteksi kedalaman dan melakukan segmentasi serta anotasi bekas luka yang berdekatan.
(Hermosilla dkk., 2024)	Tinjauan sistematis tentang metode CNN untuk deteksi kanker kulit.	Hybrid (Deep Features Fusion) with Multiclass (Best Model), CNN(Binary) (2 Class)	95%	Akurasi sangat bergantung pada kualitas gambar dan dataset, dengan hasil bervariasi tergantung kompleksitas data.

Pada penelitian ini, pendekatan yang digunakan adalah CNN dengan arsitektur MobileNetV2 untuk deteksi *keloid scars*, dibandingkan dengan beberapa penelitian sebelumnya yang juga memanfaatkan teknologi *deep learning* atau pengolahan citra digital. Meskipun beberapa penelitian, seperti yang dilakukan oleh Zhu dkk. (2021), Sengkey dkk. (2024), dan Li dkk. (2022), juga mengaplikasikan *deep learning* menggunakan CNN untuk mendeteksi berbagai jenis lesi kulit, penelitian ini memilih untuk fokus pada penggunaan MobileNetV2 karena arsitektur ini lebih efisien dan ringan, memungkinkan implementasi pada perangkat mobile yang lebih terbatas dalam hal daya dan komputasi. Penggunaan MobileNetV2 memungkinkan deteksi *keloid scars* secara *real-time* melalui aplikasi *mobile*, sehingga memberikan solusi yang lebih praktis dan mudah diakses di lingkungan klinis.

Berbeda dengan penelitian sebelumnya yang mengandalkan metode berbasis pengolahan citra digital, seperti dermoskopi (Yoo dan Kim, 2014), *ultrasound* (Huang dkk., 2020), atau *Laser speckle Contrast Imaging* (Li dkk., 2022), yang memerlukan alat khusus dan teknik pencitraan yang kompleks, pendekatan ini memanfaatkan kemampuan CNN dalam menganalisis citra kulit secara otomatis melalui perangkat mobile seperti *smartphone*. Hal ini memberikan keuntungan dari segi kemudahan penggunaan dan portabilitas, tanpa memerlukan alat tambahan yang mahal atau sulit diakses. Dengan menggunakan MobileNetV2, penelitian ini menawarkan solusi yang lebih efisien dalam deteksi dan klasifikasi *keloid scars* dan *non-keloid scars* yang dapat digunakan oleh masyarakat umum dan tenaga medis dalam berbagai situasi klinis dengan mengandalkan perangkat mobile yang sudah ada.

2.2 Landasan Teori

2.2.1 *Keloid Scars*



Gambar 2.5 *Keloid Scars*(Sulistioyono, 2025)

Keloid Scar didefinisikan sebagai jaringan parut patologis yang berkembang secara berlebihan di luar tepi luka awal dan tidak mengalami regresi atau penyembuhan spontan. Berbeda dengan jaringan parut normal yang biasanya akan menyusut dan membaik seiring waktu, *keloid scars* cenderung terus tumbuh dan dapat mengganggu penampilan fisik seperti pada gambar 2.5. Kondisi ini sering disertai dengan gejala seperti rasa gatal, nyeri, dan pembengkakan, yang dapat menurunkan kualitas hidup penderitanya.

Selain itu, *keloid scar* seringkali memerlukan intervensi medis untuk mengurangi gejala-gejalanya dan memperbaiki penampilannya, baik melalui pengobatan topikal, terapi laser, suntikan *kortikosteroid*, atau bahkan prosedur bedah. Penanganan *keloid scars* tetap menjadi tantangan karena kemampuannya untuk tumbuh kembali setelah perawatan, yang memerlukan pendekatan pengelolaan yang berkelanjutan (Ogawa, 2017).

2.2.2 Hypertrophic Scars



Gambar 2.6 Hypertrophic Scars(Islam ,2023)

Hypertrophic Scar adalah bentuk jaringan parut abnormal yang muncul akibat peningkatan aktivitas fibroblas, yang berkontribusi pada produksi kolagen secara berlebihan di area luka. Kondisi ini biasanya terjadi selama proses penyembuhan luka, terutama pada luka yang terpapar tekanan mekanik tinggi, seperti di area persendian, atau yang mengalami infeksi. Jaringan parut *hypertrophic* ditandai dengan penebalan jaringan yang menonjol namun tetap terbatas pada batas luka awal. Faktor-faktor yang mempengaruhi keparahan *hypertrophic* meliputi tingkat inflamasi lokal, tekanan mekanik, dan predisposisi genetik individu.

Dalam upaya untuk mengelola dan mengurangi keparahan jaringan parut *Hypertrophic*, beberapa pendekatan terapi telah dikembangkan. Teknik yang sering digunakan termasuk terapi kompresi, yang berfungsi untuk mengurangi pembentukan jaringan parut dengan memberikan tekanan konstan pada area luka injeksi *kortikosteroid*, yang bertujuan untuk mengurangi inflamasi dan aktivitas fibroblas serta pembedahan untuk menghilangkan jaringan parut berlebih jika terapi konservatif tidak memberikan hasil yang memadai. Penelitian ini menekankan pentingnya pendekatan multidisiplin untuk menangani jaringan parut *Hypertrophic*, dengan tujuan mengurangi dampak fisik dan psikologis yang mungkin timbul pada pasien (Ogawa, 2017).

2.2.3 Burn Scars



Gambar 2.7 *Burn Scars*(Nabil, 2025)

bekas luka bakar (*burn scars*), khususnya bekas luka hipertrofik, adalah jaringan parut patologis yang timbul dari luka bakar serius, ditandai dengan kemerahan, penonjolan, dan kekakuan yang dapat membatasi fungsi tubuh serta menyebabkan nyeri dan gatal, dengan dampak jangka panjang akibat gangguan pada proses penyembuhan luka yang melibatkan inflamasi, proliferasi, dan remodeling kolagen yang tidak teratur.

Terapi laser merupakan pendekatan konservatif yang efektif dan minimal invasif untuk penanganan bekas luka ini, dengan jenis laser seperti Pulse Dye Laser (PDL) menunjukkan efektivitas tinggi dalam mengurangi skor VSS/POSAS, sementara efikasi keseluruhan dipengaruhi oleh waktu inisiasi terapi (baik dini maupun laten), jenis laser yang digunakan, dan interval perawatan yang lebih pendek cenderung memberikan hasil yang lebih baik, meskipun masih diperlukan penelitian lebih lanjut untuk mengatasi heterogenitas studi dan mengkonfirmasi parameter optimal serta efek jangka panjang terapi ini (Ma dkk., 2023).

2.2.4 Machine Learning

Machine Learning didefinisikan sebagai sebuah cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma dan model statistik yang memungkinkan komputer untuk "belajar" dari data

dan pengalaman, tanpa diprogram secara eksplisit untuk melakukan tugas tertentu. Proses ini melibatkan pembuatan model secara matematis yang dapat memprediksi atau mengambil keputusan berdasarkan pola yang ditemukan dalam data.

Machine learning dapat dibagi menjadi tiga kategori utama yaitu , *supervised learning* di mana model dilatih menggunakan data yang sudah diberi label, *unsupervised learning* yang digunakan untuk menemukan struktur atau pola dalam data tanpa label dan *reinforcement learning* yang dimana data belajar untuk membuat keputusan dengan cara memperoleh feedback melalui *trial and error*. Buku ini menjelaskan berbagai teknik dalam *machine learning*, termasuk model probabilistik, *artificial neural network*, dan algoritma optimasi yang digunakan untuk memecahkan masalah pengenalan pola dan klasifikasi dalam berbagai bidang (Bishop Christopher M, 2006).


2.2.5 Deep Learning

Pada buku Ohlsson dan Stellan (2011) *deep learning* merupakan pembelajaran yang menekankan pada pengembangan sistem yang hierarkis, yang mampu memproses dan merepresentasikan data dari tingkat yang sederhana hingga tingkat yang lebih kompleks. Konsep ini terinspirasi oleh cara kerja otak manusia dalam memahami informasi kompleks secara bertahap, di mana fitur-fitur sederhana digabungkan untuk membentuk pola-pola yang lebih rumit.

Buku ini berfokus pada bagaimana *deep learning* dapat digunakan untuk mengatasi keterbatasan pengalaman manusia dengan *mengatasi* kebiasaan sebelumnya melalui eksplorasi pola baru dalam data. *Deep learning* dicirikan oleh penggunaan arsitektur *artificial neural network* yang mendalam dengan banyak lapis, yang memungkinkan sistem untuk secara otomatis mengekstraksi fitur dari data mentah, seperti gambar atau teks.

Pendekatan ini tidak hanya meningkatkan kemampuan prediktif tetapi juga memperluas aplikasi dalam bidang-bidang seperti pengenalan suara, *computer vision*, dan pemrosesan bahasa alami. Ohlsson juga menekankan pentingnya struktur hierarkis dan pembelajaran berbasis pengalaman dalam membangun sistem kecerdasan yang lebih adaptif dan fleksibel.

2.2.6 Convolutional Neural Network



Gambar 2.8 *Arsitektur CNN (O'Shea dan Nash, 2015)*

Convolutional Neural Networks (CNN) adalah arsitektur *Artificial Neural Network (ANN)* yang secara khusus dirancang untuk menangani tugas pengenalan pola berbasis gambar dengan memanfaatkan pengetahuan tentang jenis input tersebut. Berbeda dengan ANN tradisional yang cenderung kesulitan dengan kompleksitas komputasi data gambar berdimensi tinggi, CNN menggunakan struktur tiga dimensi (tinggi, lebar, dan kedalaman) serta konektivitas lokal di mana neuron hanya terhubung ke wilayah kecil dari lapisan sebelumnya. Arsitektur ini umumnya terdiri dari tumpukan lapisan konvolusi untuk mengekstraksi fitur melalui *learnable kernels*, lapisan *pooling* untuk pengurangan dimensi dan parameter, serta lapisan *fully-connected* untuk menghasilkan skor klasifikasi akhir. Click or tap here to enter text (O'Shea dan Nash, 2015).

2.2.7 Mobilenet-v2

MobileNetV2 merupakan arsitektur jaringan saraf konvolusional (CNN) yang dikembangkan oleh tim Google untuk aplikasi *computer vision* pada perangkat dengan sumber daya terbatas. Diperkenalkan pada tahun 2018, MobileNetV2 mengusung konsep *inverted residuals* dan *linear bottlenecks* untuk meningkatkan efisiensi komputasi dan akurasi model.

Pendekatan ini memungkinkan model untuk mencapai kinerja tinggi dengan ukuran dan latensi yang rendah, menjadikannya ideal untuk implementasi pada perangkat *mobile* dan sistem tertanam. Konsep-konsep ini memungkinkan *MobileNetV2* untuk mengurangi kompleksitas komputasi sambil mempertahankan akurasi yang tinggi, sehingga sangat efektif untuk aplikasi seperti pengenalan gambar, deteksi objek, dan segmentasi, terutama pada perangkat yang memiliki keterbatasan dalam hal daya dan memori. Arsitektur ini menekankan efisiensi dan fleksibilitas, memungkinkan model untuk berjalan optimal pada perangkat *mobile* serta perangkat dengan kemampuan terbatas lainnya (Sandler dkk., 2018).


2.2.8 *Canny Edge Detector*

Canny Edge Detector adalah metodologi tradisional untuk mendeteksi ketidakteraturan dalam sebuah gambar, yang berfokus pada pemisahan antara dua area dengan tingkat intensitas atau tingkat keabuan yang berbeda, yang disebut sebagai "*Edge*" (tepi). Tepi ini sangat penting dalam berbagai aplikasi dan peningkatan citra untuk memperjelas detail gambar.

Operasi turunan digunakan untuk mendeteksi keberadaan tepi dalam gambar, dan umumnya fungsi konvolusi diterapkan pada gambar dengan masker yang sesuai. *Canny* dikenal sebagai detektor tepi yang efisien karena mampu meningkatkan tepi dengan menggunakan ambang batas gradien untuk menemukan tepi yang mungkin, serta menekan tepi-tepi tersebut melalui sistem penekanan *non-maksimal* dan ambang batas histeresis.

Namun, perlu diperhatikan bahwa kebisingan dalam gambar sangat mempengaruhi deteksi tepi, yang dapat menyebabkan tepi yang teridentifikasi terdiri dari piksel diskrit, mungkin tidak memadai atau tidak teratur. Oleh karena itu, sebelum deteksi tepi, gambar harus dihaluskan menggunakan operator gaussian. Pra-pemrosesan gambar ini dapat mencegah deteksi tepi yang keliru dan dapat mengatasi masalah dengan teknik deteksi tepi multi-resolusi dan pelacakan tepi (Ramesh dkk., 2021).

2.2.9 Augmentation



Gambar 2.9 Beberapa proses augmentasi (Elsoin dkk., 2025)

Augmentasi data merupakan strategi esensial dalam pengembangan model *Convolutional Neural Networks* (CNN) yang bertujuan untuk memperkaya variasi dataset pelatihan guna meningkatkan akurasi dan ketahanan (*robustness*) sistem pengenalan wajah. Secara teoretis, teknik ini memanipulasi citra wajah asli melalui transformasi fisik dan pencahayaan, seperti rotasi, pembalikan (*flipping*), serta penyesuaian kecerahan, untuk mensimulasikan berbagai kondisi *real* saat pengambilan gambar.

Dengan menghadirkan variasi posisi dan kondisi lingkungan secara artifisial, model CNN dipaksa untuk mempelajari fitur-fitur wajah yang bersifat invarian, sehingga secara efektif dapat mengatasi keterbatasan jumlah sampel data latih dan meminimalkan risiko *overfitting* yang sering terjadi pada dataset berskala kecil (Elsoin dkk., 2025).

2.2.10 Tensorflow

Menurut Pattanayak (2017), *TensorFlow* adalah sebuah *library* sumber terbuka yang dikembangkan oleh Google Brain Team untuk mendukung komputasi numerik dan pembelajaran mesin pada skala besar. *tensorflow* menggunakan konsep *data flow graphs*, di mana *node*

dalam grafik merepresentasikan operasi matematika, sedangkan tepinya merepresentasikan array data multidimensi (*tensors*) yang mengalir di antara operasi tersebut. Keunggulan utama dari *tensorflow* terletak pada fleksibilitasnya dalam menjalankan berbagai algoritma pembelajaran mesin, terutama pembelajaran mendalam, pada berbagai *platform*, termasuk CPU, GPU, dan TPU.

Buku ini juga menjelaskan bahwa *tensorflow* dirancang untuk mendukung pengembangan model yang dapat diskalakan, baik untuk penelitian maupun produksi, dengan API yang mudah digunakan dan berbagai alat bawaan untuk *debugging* dan visualisasi. Pattanayak menyoroti pentingnya *tensorflow* dalam mempercepat inovasi di bidang pembelajaran mendalam melalui efisiensi dan ekosistemnya yang kaya.

2.2.11 Keras

Menurut Nandy dan Biswas (2017), keras adalah sebuah *open-source library* yang digunakan untuk membuat dan melatih *deep learning*. Keras dirancang untuk memberikan *interface* yang sederhana dan intuitif, yang dapat memungkinkan pengembang untuk dengan mudah membuat model jaringan saraf tanpa harus memahami detail implementasi dengan tingkat yang rendah. *Library* ini berjalan di atas backend seperti *TensorFlow*, *Theano*, atau *Microsoft Cognitive Toolkit* (CNTK), yang menangani operasi matematis tingkat rendah. Keras mendukung pembangunan model sekuensial (*sequential*) atau model yang lebih kompleks menggunakan API fungsional. Dengan fitur seperti kompilasi model, pelatihan, evaluasi, dan prediksi, Keras mempercepat proses pengembangan aplikasi pembelajaran mesin, menjadikannya alat yang ideal untuk peneliti dan praktisi di bidang AI.

2.2.12 Tensorflow Lite

TensorFlow Lite merupakan versi ringan dari *tensorflow* yang dirancang khusus untuk perangkat *mobile* dan sistem dengan daya komputasi yang terbatas. *TensorFlow Lite* memungkinkan *developer* untuk menjalankan model *machine learning* secara efisien di perangkat dengan sumber daya yang rendah, seperti ponsel, tablet, atau perangkat *Internet of Things (IoT)*. *Library* ini menggunakan format model yang disederhanakan dan runtime yang dioptimalkan untuk memberikan kinerja yang lebih cepat dan konsumsi daya yang lebih rendah.

TensorFlow lite mendukung berbagai operasi pembelajaran yang mendalam, seperti klasifikasi, deteksi objek, dan pemrosesan teks, dengan fokus pada inferensi model, bukan pelatihannya. Dengan arsitektur yang bersifat modular dan dukungan untuk akselerasi perangkat keras melalui API, *tensorflow lite* memberikan solusi ideal untuk aplikasi pembelajaran mesin di perangkat *edge* (Pattanayak, 2017).

2.2.13 Optimizers

Optimizers merupakan komponen penting dalam pelatihan model CNN yang bertujuan untuk meminimalkan fungsi loss melalui penyesuaian bobot secara iteratif. Dalam studi *Performance Comparison of Gradient-Based Convolutional Neural Network Optimizers for Facial Expression Recognition* oleh Nurdiati dkk (2022), berbagai optimizers berbasis gradien dibandingkan untuk mengidentifikasi kinerjanya dalam tugas pengenalan ekspresi wajah. *Optimizers* seperti Adam, Nadam, dan AdamW terbukti unggul dengan akurasi lebih dari 90%, menunjukkan keefektifan kombinasi teknik adaptif dan momentum dalam mempercepat konvergensi serta menghindari jebakan local minimal. Hasil ini menegaskan bahwa pemilihan optimizer yang tepat dapat secara signifikan memengaruhi performa dan efisiensi pelatihan model CNN, terutama dalam aplikasi yang memerlukan tingkat akurasi tinggi seperti pengenalan pola wajah.

2.2.14 Mobile

Menurut Fitzek dan Reichert (2007), *mobile* merupakan perangkat seluler yang memiliki kemampuan untuk terhubung dan berkomunikasi secara nirkabel melalui berbagai jaringan, termasuk jaringan seluler dan *wifi*. Buku ini membahas bagaimana perangkat *mobile*, seperti ponsel dan perangkat pintar, dapat diprogram untuk memanfaatkan teknologi nirkabel dalam berbagai aplikasi, mulai dari komunikasi hingga pengolahan data. Perangkat *mobile* memiliki keunggulan dalam hal portabilitas, fleksibilitas, dan aksesibilitas yang memungkinkan pengguna untuk tetap terhubung dengan dunia luar kapan saja dan di mana saja.

Dalam konteks pemrograman, pengembangan aplikasi untuk perangkat *mobile* mencakup pemanfaatan perangkat keras dan perangkat lunak yang ada, termasuk sensor, antarmuka pengguna, serta kemampuan

untuk mengakses jaringan dan layanan berbasis *cloud*. Buku ini juga membahas tantangan dan solusi dalam pengembangan aplikasi untuk perangkat *mobile*, terutama dalam hal pengelolaan sumber daya terbatas dan penggunaan teknologi nirkabel secara efisien.

2.2.15 *Functional Testing*

Menurut Patton (2005) dalam bukunya *Software Testing*, functional testing merupakan metode pengujian perangkat lunak yang bertujuan untuk memverifikasi bahwa setiap fungsi dalam sistem perangkat lunak bekerja sesuai dengan spesifikasi yang telah ditentukan. Pengujian ini dilakukan dengan pendekatan *black-box testing*, di mana pengujian dilakukan tanpa memerhatikan struktur internal atau implementasi kode, melainkan lebih berfokus pada keluaran yang dihasilkan berdasarkan masukan tertentu. Functional testing memastikan bahwa setiap fitur yang diuji memberikan hasil yang sesuai dengan kebutuhan pengguna dan tujuan sistem, sehingga menjadi bagian penting untuk menjamin kualitas perangkat lunak. Proses pengujian ini mencakup pengujian pada berbagai skenario, seperti masukan valid, masukan tidak valid, kondisi batas, dan interaksi antar fungsi untuk memastikan kelayakan sistem secara keseluruhan.