

BAB 2

KAJIAN PUSTAKA

Bab ini membahas teori-teori penunjang yang berkaitan dengan penelitian berjudul *Segmentasi, Pengukuran Luasan, dan Colorimetry pada Scar Keloid Menggunakan Multi-Task Learning Berbasis CNN dan LSTM*, dilanjutkan dengan *systematic literature review* (SLR) yang menelaah penelitian-penelitian terdahulu. Kajian ini juga memaparkan penelitian terkait yang relevan dengan topik penelitian.

1.1 TEORI PENUNJANG

1.1.1 Keloid dan Tantangan Penilaiannya

Keloid merupakan bentuk pertumbuhan jaringan parut abnormal yang terjadi akibat penyembuhan luka yang tidak sempurna. Secara histopatologi, keloid ditandai oleh proliferasi fibroblas dan sintesis kolagen yang berlebihan, bahkan meluas melampaui batas luka asal (Ruccia et al., 2021). Tidak hanya berdampak secara fisik seperti rasa nyeri, gatal, dan keterbatasan gerak, keloid juga memberi pengaruh signifikan terhadap kualitas hidup penderitanya secara psikososial dan estetika.

Penilaian terhadap kondisi keloid saat ini masih didominasi oleh metode subjektif seperti *Vancouver Scar Scale* (VSS) dan *Patient and Observer Scar Assessment Scale* (POSAS). Kedua skala ini dinilai praktis, namun bergantung pada persepsi penilai sehingga kurang konsisten dan rentan terhadap bias antar pengamat (Abdolahnejad et al., 2024). Selain itu, meskipun terdapat perangkat objektif seperti Cutometer dan Mexameter, alat-alat tersebut umumnya mahal dan tidak tersedia luas, sehingga keterbatasan ini menjadi salah satu pendorong dalam pengembangan sistem evaluasi digital berbasis citra.

1.1.2 Segmentasi Citra Digital dalam Kesehatan

Segmentasi citra merupakan salah satu tahap fundamental dalam pengolahan citra digital. Secara umum, segmentasi didefinisikan sebagai proses membagi suatu citra

menjadi beberapa region atau area homogen yang memiliki karakteristik serupa, sehingga objek penting dapat dipisahkan dari latar belakang (Gonzalez & Woods, 2018). Tujuan utama segmentasi adalah untuk memudahkan analisis lebih lanjut, seperti pengukuran ukuran, bentuk, tekstur, dan warna dari objek yang diamati. Secara teori, terdapat beberapa pendekatan dasar segmentasi citra, antara lain:

1. Berbasis Ambang (*Thresholding*): memisahkan objek dan latar berdasarkan intensitas piksel atau nilai ambang tertentu.
2. Berbasis Deteksi Tepi (*Edge-based*): mendeteksi batas objek menggunakan operator gradien, seperti Sobel, Canny, atau Laplacian.
3. Berbasis Region (*Region-based*): mengelompokkan piksel yang homogen berdasarkan kriteria kesamaan tertentu, misalnya *region growing* atau *region splitting and merging*.
4. Berbasis *Clustering*: menggunakan metode unsupervised seperti *K-Means* atau *Fuzzy C-Means* untuk membagi piksel menjadi beberapa cluster sesuai karakteristik warna atau intensitas.

Dalam konteks citra medis, segmentasi menjadi langkah krusial untuk mengidentifikasi area patologis, seperti tumor, luka, atau jaringan parut keloid. Akurasi segmentasi akan sangat memengaruhi tahap ekstraksi fitur dan analisis selanjutnya, misalnya pengukuran luasan atau analisis warna.


Seiring berkembangnya teknologi, algoritma *Convolutional Neural Network* (CNN) telah menjadi pendekatan populer dalam segmentasi medis karena kemampuannya menangkap pola spasial dan tekstur. Arsitektur seperti U-Net (Ronneberger et al., 2015), ResUNet, dan Attention U-Net terbukti unggul dalam memisahkan objek medis dari latar belakang dengan tingkat akurasi tinggi. U-Net, misalnya, dirancang khusus untuk segmentasi citra medis dengan memanfaatkan mekanisme *encoder-decoder* serta *skip connection* untuk mempertahankan detail spasial. Berbagai penelitian kemudian memodifikasi U-Net dengan *residual block*, *pretrained backbone* (ResNet, EfficientNet, DenseNet), dan mekanisme perhatian (*attention mechanism*) untuk meningkatkan performa segmentasi (Chen et al., 2020).

1.1.3 Analisis Warna (Colorimetry) pada Luka

Colorimetry adalah proses pengukuran dan analisis warna dalam citra digital yang digunakan untuk menilai karakteristik jaringan seperti kadar melanin, hemoglobin, dan inflamasi pada luka atau scar. Dalam evaluasi keloid, warna memiliki arti klinis penting karena perubahan warna dapat mengindikasikan tingkat peradangan dan proses penyembuhan. Warna citra biasanya direpresentasikan dalam beberapa ruang warna, di antaranya:

- RGB (*Red, Green, Blue*): representasi warna berdasarkan kombinasi tiga komponen dasar cahaya.
- HSV (*Hue, Saturation, Value*): lebih mendekati persepsi manusia, dengan *hue* mewakili jenis warna, *saturation* tingkat kejenuhan, dan *value* tingkat kecerahan.
- CIELAB: ruang warna yang dirancang menyerupai persepsi visual manusia, terdiri dari komponen *L* (kecerahan), *a* (hijau-merah), dan *b* (biru-kuning).

Untuk mengekstraksi warna dominan dari citra luka, metode seperti *K-Means Clustering* atau *Mean Shift Clustering* dapat digunakan untuk mengelompokkan piksel ke dalam sejumlah segmen warna yang signifikan. Dalam studi Ruccia et al. (2021), analisis melanin dan erythema dari citra keloid menunjukkan potensi sebagai indikator respons terhadap terapi steroid intralesi. Untuk memperjelas konsep representasi ruang warna yang digunakan dalam analisis citra. Menurut Berasarte et al. (2025), ruang warna seperti RGB, HSV, dan CIELAB merupakan representasi matematis dari warna yang banyak digunakan dalam *digital image colorimetry*. Model RGB mendeskripsikan warna berdasarkan intensitas merah, hijau, dan biru, sedangkan HSV lebih sesuai untuk mengekspresikan persepsi manusia terhadap warna melalui dimensi *hue*, *saturation*, dan *value*. Sementara itu, CIELAB dianggap lebih unggul dalam analisis warna kuantitatif karena sifatnya yang lebih linear terhadap persepsi visual manusia. Gambar 2.2 menyajikan ilustrasi ruang warna (RGB, HSV, dan CIELAB) beserta penerapannya pada citra keloid.



Gambar 2.1. Representasi ruang warna (RGB, HSV, CIELAB) pada citra keloid
(Sumber Berasarte et al., 2025).

1.1.4 Multi-Task Learning (MTL)

Multi-Task Learning (MTL) merupakan pendekatan pembelajaran mesin di mana sebuah model dilatih untuk menyelesaikan beberapa tugas secara bersamaan, dengan tujuan memanfaatkan keterkaitan antar tugas untuk meningkatkan performa keseluruhan (Caruana, 1997). Ide dasarnya adalah *inductive transfer*, yaitu pengetahuan yang diperoleh dari satu tugas dapat membantu tugas lain melalui representasi bersama (*shared representation*).

1. Kategori Utama dalam MTL

Menurut Zhang dan Yang (2018), *Multi-Task Learning* (MTL) dapat dibedakan menjadi dua kategori utama berdasarkan cara berbagi parameter antartugas, yaitu *Hard Parameter Sharing* dan *Soft Parameter Sharing*.

Kedua pendekatan ini memiliki tujuan yang sama, yaitu memungkinkan beberapa tugas (tasks) saling berbagi pengetahuan untuk meningkatkan generalisasi model, namun mekanismenya berbeda secara struktural.

a. *Hard Parameter Sharing*

Pada *hard parameter sharing*, beberapa *task* berbagi lapisan dasar (*shared layers*) yang sama, sementara hanya lapisan akhir (*task-specific layers*) yang berbeda. Artinya, bobot pada bagian awal jaringan digunakan secara bersama oleh semua tugas, sehingga model dapat mengekstraksi fitur umum (*shared representation*) yang bermanfaat bagi seluruh tugas.

Formula umum fungsi loss total dituliskan sebagai:

$$\mathcal{L}_{total} = \sum_{i=1}^T \lambda_i \mathcal{L}_i \quad \dots (1)$$

dengan:

- $\mathcal{L}_i$: fungsi loss dari tugas ke-i,
- λ_i : bobot relatif dari masing-masing tugas,
- T: jumlah total tugas dalam model MTL.

Sebagai contoh, untuk dua tugas seperti segmentasi ($\mathcal{L}_{seg}$) dengan $\mathcal{L}_i$ dan klasifikasi $\mathcal{L}_{cls}$, maka:

$$\mathcal{L}_{total} = \lambda_{seg} \mathcal{L}_{seg} + \lambda_{cls} \mathcal{L}_{cls} \quad \dots (2)$$

Jika $\lambda_{seg} = 0.6$ dan $\lambda_{cls} = 0.4$, maka model lebih menekankan kualitas segmentasi dibanding klasifikasi.

Keunggulan *hard parameter sharing*:

- Mengurangi risiko *overfitting* karena parameter bersama mengurangi kompleksitas total model.
- Efisien secara komputasi dan memori karena sebagian besar parameter dibagi bersama.

Kelemahannya:

- Kurang fleksibel jika antar-tugas memiliki karakteristik yang sangat berbeda.
- Satu tugas bisa mendominasi pembelajaran dan mengganggu performa tugas lainnya (*negative transfer*).

b. Soft Parameter Sharing

Sebaliknya, pada *soft parameter sharing*, setiap tugas memiliki arsitektur model terpisah, namun hubungan antar model diatur melalui regularisasi jarak antar parameter. Dengan kata lain, bobot model yang berbeda dipaksa untuk tidak terlalu jauh satu sama lain agar tetap belajar representasi yang mirip.

Rumus umum regularisasi *soft parameter sharing* adalah:

$$\mathcal{L}_{total} = \sum_{i=1}^T \mathcal{L}_i + \mu \sum_{i \neq j} \|\theta_i - \theta_j\|^2 \quad \dots (3)$$

Keterangan:

- $\mathcal{L}_i$: fungsi loss dari tugas ke- i
- θ_i : parameter (bobot) model untuk tugas ke- i
- μ : koefisien regularisasi untuk mengontrol jarak antar-parameter
- T : jumlah total tugas dalam MTL $\|\theta_i - \theta_j\|^2$
- $\|\theta_i - \theta_j\|^2$: penalti jarak parameter antar model tugas ke- i dan ke- j , agar tetap belajar representasi yang mirip

Contoh Implementasi dari jurnal breast ultrasound, 2023. yang menggabungkan tugas segmentasi (Dice Loss) dan klasifikasi (Cross-Entropy Loss) dalam satu framework MTL. Formula loss gabungan yang dipakai:

$$\mathcal{L}_{total} = \alpha \times \mathcal{L}_{Dice} + \beta \times \mathcal{L}_{CE} \quad \dots (4)$$

Keterangan:

- $\mathcal{L}_{Dice}$: fungsi *Dice Loss* untuk tugas segmentasi
- $\mathcal{L}_{CE}$: *Cross-Entropy Loss* untuk tugas klasifikasi
- α, β : bobot relatif yang menyeimbangkan kontribusi masing-masing tugas

Sebagai ilustrasi, jika hasil training menunjukkan Dice Loss = 0.25 dan Cross Entropy Loss = 0.35, dengan bobot $\alpha = 0.7$ dan $\beta = 0.3$:

$$\mathcal{L}_{total} = 0.7(0.25) + 0.3(0.35) = 0.175 + 0.105 = 0.280$$

Pendekatan ini lebih fleksibel, namun memerlukan sumber daya komputasi yang lebih besar karena setiap tugas memiliki model tersendiri.

c. Relevansi untuk penelitian ini

Formula Dalam penelitian ini, digunakan pendekatan Hard Parameter Sharing, di mana lapisan CNN digunakan bersama untuk mengekstraksi fitur spasial dari citra keloid, sedangkan lapisan LSTM dan output head bersifat spesifik untuk setiap tugas, yaitu:

- Segmentasi luka (Loss: Dice Score)
- Pengukuran luasan area (Loss: MAE/RMSE)
- Analisis warna (*Colorimetry*, Loss: MSE pada rasio RGB)

Formulasi *multi-task loss function* yang digunakan adalah:

$$\mathcal{L}_{total} = \lambda_1 \times \mathcal{L}_{Dice} + \lambda_2 \times \mathcal{L}_{Reg} + \lambda_3 \times \mathcal{L}_{Color} \quad \dots (5)$$

dengan:

- $\mathcal{L}_{Dice}$: *Dice Loss* untuk segmentasi area keloid,
- $\mathcal{L}_{Reg}$: *Mean Absolute Error (MAE)* untuk regresi luasan luka,

- $\mathcal{L}_{Color}$: *Mean Squared Error (MSE)* untuk analisis warna RGB,
- $\lambda_1, \lambda_2, \lambda_3$: bobot relatif tiap tugas.

Pembobotan loss digunakan untuk menjaga keseimbangan antar-tugas agar tidak terjadi *task domination*. Dalam penelitian ini, pembobotan diatur secara dinamis dengan metode *uncertainty weighting* (Kendall et al., 2018), sehingga setiap tugas berkontribusi optimal terhadap pembelajaran keseluruhan.

Sebagai contoh, jika $\mathcal{L}_{Dice} = 0.2$, $\mathcal{L}_{Regresi} = 15$, $\mathcal{L}_{Color} = 0.05$, dengan $\lambda_1 = 0.5$, $\lambda_2 = 0.3$, $\lambda_3 = 0.2$:

$$\mathcal{L}_{total} = 0.5(0.2) + 0.3(15) + 0.2(0.05) = 0.1 + 4.5 + 0.01 = 4.61$$

Pendekatan *hard sharing* ini dipilih karena:

- Ketiga tugas (*segmentasi, regresi, colorimetry*) berasal dari domain visual yang sama (citra RGB keloid).
- Diperlukan efisiensi komputasi agar model dapat berjalan *end-to-end* dalam satu arsitektur CNN–LSTM tanpa memerlukan pelatihan terpisah.
- Feature sharing antar-tugas diharapkan meningkatkan konsistensi spasial-temporal hasil analisis.

2. Arsitektur Umum Multi-Task Learning (MTL) pada Citra Medis

Dalam ranah *medical image analysis*, pendekatan *Multi-Task Learning* (MTL) umumnya dibangun dengan arsitektur *end-to-end* yang terdiri dari tiga komponen utama:

a. Backbone / Feature Extractor

- Umumnya berupa *Convolutional Neural Network* (CNN) (misalnya ResNet, U-Net encoder) atau *Transformer* (misalnya Swin Transformer, Vision Transformer) yang berfungsi mengekstraksi representasi spasial dari citra medis (Ruder, 2017; Zhang & Yang, 2018).
- Backbone ini berperan sebagai *shared representation layer* yang digunakan bersama oleh seluruh tugas (*hard parameter sharing*).

b. Task-Specific Heads

Setelah representasi bersama diperoleh, jaringan bercabang menjadi beberapa *task heads* sesuai kebutuhan:

- *Segmentation Head*: menghasilkan peta piksel (*segmentation mask*) untuk memisahkan area lesi vs non-lesi (Ronneberger et al., 2015; Zhang et al., 2023).
- *Regression Head*: memprediksi parameter kuantitatif, misalnya luas lesi, volume jaringan, atau metrik klinis tertentu. Biasanya terdiri dari lapisan *fully-connected* (FC) yang memproses vektor fitur (Cai et al., 2020).
- *Classification / Colorimetry Head*: mengestimasi label klinis (jinak vs ganas) atau kuantifikasi warna (misalnya rasio RGB/CIELAB) yang relevan dengan diagnosis (Liu et al., 2019; Berasarte et al., 2025).

c. Loss Function Gabungan

- Fungsi kerugian dari tiap head digabungkan dalam bentuk *weighted sum*:

$$\mathcal{L}_{total} = \lambda_{seg} \times \mathcal{L}_{seg} + \lambda_{reg} \times \mathcal{L}_{reg} + \lambda_{cls} \times \mathcal{L}_{cls} \dots (6)$$

- Bobot ditentukan untuk menyeimbangkan kepentingan tiap tugas (Kendall et al., 2018).
- Misalnya, *Dice Loss* digunakan untuk segmentasi, MAE/RMSE untuk regresi, dan *Cross-Entropy* / MSE untuk klasifikasi atau *Colorimetry*.

Arsitektur ini memungkinkan satu input citra medis menghasilkan keluaran multi-dimensi (mask segmentasi, nilai kuantitatif, serta label/rasio warna), sehingga lebih efisien dibandingkan pendekatan terpisah. Selain itu, MTL terbukti meningkatkan *generalization performance* karena representasi bersama mendorong model untuk belajar fitur yang lebih kaya (Cai et al., 2020; Zhang et al., 2023).

3. Keunggulan dan Tantangan Multi-Task Learning dalam Citra Medis

Pendekatan Multi-Task Learning (MTL) memiliki sejumlah keunggulan yang membuatnya semakin populer dalam analisis citra medis. Salah satu keuntungan utama adalah efisiensi parameter. Dengan menggunakan satu model yang dapat menyelesaikan beberapa tugas sekaligus, MTL mampu menggantikan pipeline terpisah yang biasanya membutuhkan model berbeda untuk segmentasi, klasifikasi, maupun regresi. Hal ini tidak hanya mengurangi kompleksitas komputasi, tetapi juga menghemat sumber daya pelatihan. Selain itu, MTL memberikan peningkatan kemampuan generalisasi. Representasi fitur yang dibagi di antara beberapa tugas cenderung lebih kaya dan bermakna dibandingkan model tugas tunggal, sehingga dapat mengurangi bias serta meningkatkan robustness saat diuji pada data baru. Keunggulan lain yang sering disorot adalah reduksi propagasi error. Pada pendekatan tradisional yang terpisah, kesalahan pada tahap awal, seperti segmentasi, akan terbawa ke modul berikutnya. Sebaliknya, dalam MTL semua komponen dilatih secara *end-to-end*, sehingga kesalahan pada satu tugas dapat diminimalkan melalui pembelajaran bersama.

Meskipun demikian, MTL juga menghadapi sejumlah tantangan metodologis. Salah satu permasalahan umum adalah *task imbalance*, di mana beberapa tugas cenderung lebih dominan dalam proses pelatihan sehingga menurunkan kinerja tugas lain. Tantangan lain adalah penentuan bobot relatif antar fungsi *loss*. Sampai saat ini, tidak ada formula universal yang optimal, dan pemilihan bobot relatif (λ) untuk tiap tugas masih menjadi topik penelitian aktif. Selain itu, terdapat risiko *negative transfer*, yaitu kondisi ketika dua tugas yang dilatih bersama tidak saling mendukung, bahkan justru menurunkan performa keseluruhan sistem. Oleh karena itu, perancangan arsitektur MTL dalam citra medis harus mempertimbangkan keterkaitan antar tugas secara hati-hati.

Dalam penelitian ini, beberapa strategi diterapkan untuk mengantisipasi permasalahan tersebut, antara lain:

1. *Uncertainty Weighting* (Kendall et al., 2018): digunakan untuk menyesuaikan bobot loss tiap tugas secara dinamis berdasarkan tingkat ketidakpastian (*task*


uncertainty) selama pelatihan. Pendekatan ini efektif mengurangi *task imbalance* karena bobot disesuaikan otomatis sesuai kesulitan masing-masing tugas.

2. *Feature Sharing* Terbatas (*Hard Parameter Sharing*): hanya lapisan encoder (CNN-LSTM) yang dibagikan antar-tugas, sementara setiap cabang output memiliki *task-specific layer* sendiri. Hal ini mencegah terjadinya *negative transfer* akibat interferensi antar-representasi.
3. Monitoring Loss Curves Per Tugas: selama pelatihan, setiap fungsi loss dimonitor secara terpisah untuk mendeteksi dominasi satu tugas terhadap yang lain. Penyesuaian bobot atau *learning rate scheduling* dilakukan jika perbedaan konvergensi terlalu besar.
4. Cross-Task Consistency Loss (adaptasi dari He et al., 2021): diterapkan untuk memastikan hasil regresi luas luka konsisten dengan area segmentasi yang dihasilkan, sehingga antar-tugas saling memperkuat.

Dengan kombinasi strategi tersebut, model diharapkan mampu mempertahankan keseimbangan antar-tugas dan menghindari efek *negative transfer*, sekaligus meningkatkan stabilitas pembelajaran *multi-task* secara keseluruhan.

Setelah berbagai tantangan metodologis tersebut diantisipasi. MTL telah banyak diterapkan secara luas dalam domain medis dengan hasil yang menjanjikan. Sebagai contoh, penelitian Ronneberger et al. (2015) dan Chen et al. (2020) menunjukkan bahwa MTL mampu meningkatkan akurasi segmentasi sekaligus prediksi *outcome* klinis. Dalam dermatologi, Abdollahnejad et al. (2024) melaporkan bahwa integrasi segmentasi, klasifikasi, dan analisis warna menghasilkan sistem pemantauan keloid yang lebih efisien dibanding pendekatan terpisah.

Pendekatan umum MTL pada citra medis ditunjukkan pada Gambar 2.3, dengan satu *shared encoder* dan beberapa *task-specific heads* untuk segmentasi, regresi, dan analisis warna.



Gambar 2.2. Arsitektur umum MTL pada citra medis
(Sumber Liu et al., 2019; Zhang & Yang, 2018).

Gambar 2.3 memperlihatkan bagaimana citra masukan (*input image*) diproses melalui *shared encoder* berbasis CNN untuk menghasilkan representasi fitur yang digunakan secara bersama. Fitur ini kemudian diteruskan ke tiga cabang tugas spesifik (*heads*), yaitu:

1. *Segmentation Head* untuk mendeteksi area luka,
2. *Regression Head* untuk menghitung luas luka, dan
3. *Colorimetry Head* untuk menganalisis warna jaringan.

Struktur ini menggambarkan prinsip *hard parameter sharing* yang digunakan juga dalam penelitian ini, di mana satu encoder digunakan untuk mendukung beberapa tugas sekaligus secara efisien dan konsisten.

4. Konsep Multi-Task Learning pada Analisis Citra Medis

Pendekatan *Multi-Task Learning* (MTL) dalam analisis citra medis telah menunjukkan efektivitas tinggi dalam meningkatkan akurasi model dengan memanfaatkan *feature sharing* antar-tugas yang saling berkaitan. Dalam konteks penelitian ini, tiga studi utama dijadikan dasar pengembangan model CNN-LSTM-MTL yang mencakup tugas segmentasi, regresi luasan luka, dan analisis warna (*colorimetry*):

1. MTL untuk Segmentasi berdasarkan *Diagnosis of Esophageal Lesions by Multi-Classification and Segmentation Using an Improved Multi-Task Deep Learning Mode*.

Penelitian oleh Tang et al. (2022) mengusulkan model *Improved Multi-Task Deep Learning (MTDL)* yang menggabungkan segmentasi dan klasifikasi lesi esofagus dalam satu arsitektur terpadu. Model ini menggunakan ResNet50 sebagai *shared encoder* untuk mengekstraksi fitur spasial dari citra endoskopi, yang kemudian dibagi menjadi dua cabang output: segmentasi area lesi dan klasifikasi jenis kelainan jaringan. Pendekatan Tang et al. menunjukkan bahwa pembelajaran lintas-tugas (*cross-task learning*) antara segmentasi dan klasifikasi dapat meningkatkan ketepatan deteksi tepi (*boundary accuracy*) serta konsistensi hasil segmentasi. Hal ini dicapai melalui tiga mekanisme utama:

- *Shared Feature Representation*: fitur hasil ekstraksi ResNet50 digunakan bersama oleh kedua cabang tugas, memungkinkan model menangkap korelasi spasial dan semantik antar-lesi.
- *Improved U-Net Decoder*: cabang segmentasi menggunakan struktur *U-Net enhanced* dengan *skip connections* yang dioptimalkan untuk mempertahankan detail spasial pada area kecil.
- *Joint Optimization Strategy*: fungsi *loss* gabungan digunakan untuk menyeimbangkan pembelajaran kedua tugas, di mana hasil klasifikasi memberikan umpan balik terhadap segmentasi (*feedback refinement*) melalui pembobotan dinamis.

Eksperimen mereka menunjukkan peningkatan akurasi segmentasi sebesar 2–4% dibandingkan model *single-task U-Net*, serta perbaikan signifikan dalam konsistensi prediksi antar-citra. Dalam konteks penelitian ini, prinsip dari Tang et al. diadaptasi untuk merancang cabang segmentasi pada model CNN-LSTM-MTL, dengan beberapa modifikasi penting:

- Backbone ResNet50 pretrained tetap digunakan sebagai encoder utama untuk memanfaatkan kekuatan representasi spasial yang telah terbukti.
- Cabang segmentasi dikembangkan menggunakan decoder berbasis U-Net untuk menghasilkan *binary mask* area keloid dengan delineasi yang lebih presisi.

- Hasil segmentasi ini menjadi dasar bagi dua tugas lain dalam arsitektur *multi-task*, yaitu regresi luasan luka dan analisis warna (colorimetry), sehingga ketiga tugas saling mendukung dalam satu model *end-to-end*. Pendekatan ini memastikan bahwa model tidak hanya mampu mengenali batas luka secara akurat, tetapi juga mampu memberikan estimasi kuantitatif (luasan) dan karakterisasi warna jaringan yang relevan secara klinis.

2. MTL untuk Regresi Luas dan Boundary Awareness berdasarkan *HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images*

He et al. (2021) mengusulkan HF-UNet, sebuah arsitektur Multi-Task U-Net yang memperkenalkan mekanisme *Hierarchical Feature Sharing* dan *Task Consistency Learning (TCL)* untuk meningkatkan akurasi segmentasi prostat pada citra CT. Dalam pendekatan ini, dua tugas utama segmentasi dan delineasi batas organ dipelajari secara bersamaan melalui blok atensi (*attention block*) di setiap level hierarki *encoder-decoder*.

Metodologi utama HF-UNet mencakup:

- *Hierarchical Inter-Task Relevance*: fitur dari setiap tugas dipertukarkan antar-layer melalui *task-interaction modules* untuk meningkatkan konsistensi prediksi.
- *Task Consistency Learning (TCL)*: *loss* tambahan digunakan untuk memastikan kesesuaian antara hasil segmentasi dan prediksi batas objek.
- *Joint Optimization*: seluruh *loss* digabungkan secara *end-to-end*, memungkinkan model mempelajari hubungan spasial antar-tugas secara simultan.

Pendekatan ini menunjukkan peningkatan akurasi sebesar 2–3% dibanding U-Net konvensional dan menghasilkan kontur batas yang lebih presisi. Dalam konteks penelitian ini, konsep *inter-task relevance* diadopsi untuk menghubungkan cabang segmentasi dengan regresi luasan luka, sehingga nilai area yang diprediksi lebih akurat dan selaras dengan morfologi keloid yang sebenarnya.

3. MTL untuk Analisis Warna (Colorimetry) berdasarkan *Accuracy and Precision of Smartphone Colorimetry: A Comparative Analysis in RGB, HSV, and CIELAB Color Spaces*

Sirisathitkul et al. (2025) mengembangkan metode analisis warna berbasis *digital colorimetry* menggunakan citra yang diambil melalui kamera smartphone. Studi ini membandingkan tiga ruang warna RGB, HSV, dan CIELAB untuk menilai akurasi serta presisi pengukuran warna dibandingkan standar referensi Pantone.

Metode yang digunakan mencakup:

- Pengambilan Citra dan Kalibrasi: setiap gambar dikalibrasi menggunakan kartu warna standar untuk mengoreksi perbedaan pencahayaan.
- Ekstraksi Warna Dominan: nilai warna diekstraksi dengan metode *k-means clustering*, menghasilkan tiga warna dominan yang mewakili karakteristik utama permukaan objek.
- Evaluasi Presisi: dilakukan uji komparatif antara nilai warna hasil pengukuran dengan standar Pantone menggunakan metrik ΔE (CIELAB) dan MSE (RGB).

Dalam penelitian ini, analisis warna dilakukan pada ruang warna RGB, karena penelitian Sirisathitkul et al. (2025) menunjukkan bahwa RGB memiliki korelasi tinggi dengan persepsi warna alami kulit. Setiap area luka hasil segmentasi diekstraksi menggunakan metode K-Means clustering ($k=3$) untuk mendapatkan tiga warna dominan. Nilai rata-rata RGB dari tiap cluster kemudian digunakan sebagai representasi warna jaringan, yang selanjutnya dibandingkan dengan nilai referensi klinis untuk menilai kondisi keloid (inflamasi, maturasi, atau hiperpigmentasi).

Hasil penelitian menunjukkan bahwa ruang warna RGB dan CIELAB memiliki korelasi tinggi dengan nilai referensi standar, menjadikannya ideal untuk analisis kuantitatif berbasis citra. Prinsip ini diadaptasi dalam penelitian ini untuk cabang analisis warna (colorimetry), yang memanfaatkan rasio RGB dari

area luka hasil segmentasi guna menilai perubahan fisiologis keloid seperti tingkat inflamasi, maturasi, dan hiperpigmentasi.

1.1.5 Long Short-Term Memory (LSTM) dan Analisis Citra Time-Series

Long Short-Term Memory (LSTM) merupakan arsitektur turunan dari *Recurrent Neural Network* (RNN) yang dikembangkan oleh Hochreiter & Schmidhuber (1997) untuk mengatasi permasalahan *vanishing gradient* dan *long-term dependency*. LSTM memiliki struktur khusus berupa *cell state* dan tiga gate (*input*, *forget*, dan *output*) yang berfungsi untuk mengatur aliran informasi dalam urutan data.

1. Mekanisme LSTM

Secara umum, alur data dalam LSTM dapat dijelaskan sebagai berikut:

- *Forget Gate* menentukan informasi mana dari state sebelumnya yang akan dibuang.
- *Input Gate* menentukan informasi baru apa yang akan disimpan ke dalam cell state.
- *Output Gate* menentukan bagian dari cell state yang akan digunakan sebagai output pada langkah waktu berikutnya.

2. Formula Matematis LSTM

Persamaan berikut menjelaskan mekanisme kerja *Long Short-Term Memory* (LSTM) dalam memproses urutan data secara temporal. Setiap simbol memiliki fungsi spesifik untuk mengatur bagaimana informasi lama disimpan, diperbarui, atau dibuang pada setiap langkah waktu t :

1. Forget Gate (f_t)

Mengontrol seberapa banyak informasi dari *cell state* sebelumnya (C_{t-1}) akan dipertahankan atau dilupakan. Nilai keluaran f_t berada di antara 0–1 (melalui fungsi sigmoid), di mana 1 berarti informasi dipertahankan sepenuhnya dan 0 berarti dihapus sepenuhnya.

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad \dots (7)$$

2. Input Gate (i_t)

Menentukan seberapa besar informasi baru (C_t) akan ditambahkan ke *cell state*.

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad \dots (8)$$

3. Candidate Cell State ($\tilde{C}_t$)

Merupakan kandidat informasi baru yang akan dimasukkan ke *cell state*, dihitung dengan fungsi aktivasi *tanh* agar nilainya berada dalam rentang $[-1,1]$.

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad \dots (9)$$

4. Update Cell State (C_t)

Cell state diperbarui dengan menggabungkan informasi lama yang dipertahankan ($f_t \times C_{t-1}$) dan informasi baru yang masuk ($i_t \times \tilde{C}_t$):

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad \dots (10)$$

5. Output Gate (o_t)

Menentukan bagian mana dari cell state yang akan dikeluarkan sebagai hidden state baru.

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad \dots (11)$$

6. Hidden State Baru (h_t)

Merupakan keluaran akhir dari LSTM pada langkah waktu t , hasil kombinasi antara *cell state* terkini dan *output gate*:

$$h_t = o_t \times \tanh(C_t) \quad \dots (12)$$

Dengan mekanisme ini, LSTM mampu mengingat informasi penting dari langkah waktu sebelumnya dan mengabaikan informasi yang tidak relevan, sehingga sangat efektif untuk data berurutan seperti *time-series image* pada penelitian ini.


3. Fungsi aktivasi

Fungsi aktivasi utama yang digunakan dalam LSTM adalah:

- σ : fungsi sigmoid, membatasi nilai antara 0 - 1, digunakan untuk mengontrol seberapa banyak informasi diteruskan.
- $\tanh$: fungsi hiperbolik, menjaga keseimbangan nilai positif dan negatif agar *cell state* tetap stabil selama pelatihan.

4. Penerapan dalam Penelitian

Dalam penelitian ini, LSTM digunakan setelah fitur spasial diekstraksi oleh CNN. Dengan demikian, CNN bertindak sebagai *feature extractor*, sedangkan LSTM menangkap *dynamics temporal* dari perubahan keloid dalam beberapa interval waktu. Pendekatan CNN+LSTM ini memungkinkan model memahami evolusi morfologi dan warna keloid secara longitudinal. Penelitian terkini menunjukkan bahwa integrasi spasial-temporal ini meningkatkan akurasi prediksi perkembangan lesi dan memperbaiki interpretasi klinis pada evaluasi luka kronis, tumor, maupun terapi keloid (Wang et al., 2023).



Gambar 2.3 Skema arsitektur LSTM (Sumber Hochreiter & Schmidhuber, 1997; Goodfellow et al., 2016).

Arsitektur *Long Short-Term Memory* (LSTM) digunakan untuk memproses data sekuensial dengan mempertahankan informasi jangka panjang melalui *forget*, *input*, dan *output gate* (Hochreiter & Schmidhuber, 1997). Pada penelitian ini, LSTM relevan karena citra keloid dikumpulkan secara *longitudinal* (time-series) dari bulan pertama hingga ketiga. Dengan ditempatkan setelah backbone CNN, LSTM mampu menangkap pola temporal perubahan bentuk, ukuran, dan warna keloid, sehingga hasil segmentasi, pengukuran luas, dan analisis warna menjadi lebih stabil dan akurat dibandingkan pendekatan citra tunggal.

1.1.6 Segment Anything Model (SAM) dan Vision Transformer (ViT)

Segmentation merupakan salah satu tugas penting dalam *computer vision*, di mana model diharapkan mampu membagi citra menjadi area-area yang bermakna berdasarkan objek atau struktur yang ingin dianalisis. Segment Anything Model (SAM) adalah sebuah *foundation model* untuk segmentasi citra yang dirancang agar mampu memprediksi *mask* segmentasi dari berbagai macam objek hanya dengan sedikit isyarat (*prompt*) dari pengguna, seperti titik atau kotak. SAM dilatih menggunakan dataset berskala besar yang mencakup lebih dari satu miliar *mask* pada 11 juta citra, sehingga menunjukkan kemampuan generalisasi yang kuat terhadap berbagai domain segmentasi gambar tanpa memerlukan pelatihan ulang (*zero-shot transfer*). Dalam arsitekturnya, SAM menggunakan *Image Encoder* berbasis Vision Transformer (ViT) untuk menghasilkan representasi fitur citra, *Prompt Encoder* untuk mengodekan informasi prompt, serta *Mask Decoder* untuk menghasilkan prediksi segmentasi akhir dari gabungan representasi tersebut (Kirillov et al., 2023).

Vision Transformer (ViT) merupakan arsitektur model berbasis *transformer* yang awalnya diperkenalkan untuk tugas klasifikasi citra, namun kemudian banyak diadopsi pada berbagai tugas visi komputer lanjutan, termasuk segmentasi citra. ViT memproses citra dengan membaginya menjadi *patch* berukuran tetap yang diproyeksikan ke dalam ruang embedding dan diproses oleh *transformer encoder* menggunakan mekanisme *self-attention*. Pendekatan ini memungkinkan model untuk menangkap hubungan global antar *patch* citra, berbeda dengan Convolutional Neural Network (CNN) yang lebih menekankan pada ekstraksi fitur lokal. ViT telah terbukti memiliki performa yang

kompetitif dan bahkan unggul dibandingkan model berbasis CNN ketika dilatih pada dataset berskala besar (Dosovitskiy et al., 2021).

Dalam konteks penelitian ini, Segment Anything Model (SAM) digunakan pada tahap pra-pemrosesan data untuk menghasilkan *mask* luka keloid yang selanjutnya digunakan sebagai referensi dalam pengembangan dataset. Pendekatan ini bertujuan untuk meningkatkan konsistensi dan efisiensi proses anotasi *mask* tanpa perlu melatih model segmentasi khusus dari awal untuk setiap citra luka. Integrasi SAM dengan pipeline penelitian dilakukan secara terpisah dari proses pelatihan model CNN–LSTM–Multi-Task Learning yang dikembangkan untuk tugas segmentasi, estimasi luasan, dan analisis warna luka secara temporal. Dengan demikian, SAM berfungsi sebagai alat bantu generatif, sedangkan model CNN–LSTM difokuskan pada pembelajaran terarah terhadap tugas-tugas klinis yang menjadi fokus utama penelitian ini (Kirillov et al., 2023; Dosovitskiy et al., 2021).

1.2 Systematic Literature Review (SLR)

2.2.1 Metode SLR

Kajian literatur sistematis ini disusun mengikuti pedoman PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) untuk memastikan transparansi dan reproduibilitas. Pertanyaan penelitian dirumuskan dengan kerangka PICO (*Population, Intervention, Comparison, Outcome*) sebagai berikut:

- Population: penelitian yang mengimplementasikan *Multi-Task Learning (MTL)* berbasis *deep learning* pada citra medis dua dimensi (CT, MRI, X-ray, dermoscopy, ultrasound), serta studi yang menggunakan analisis citra digital berbasis RGB/HDR untuk *colorimetry* atau evaluasi visual jaringan medis dalam periode 2020-2025.
- Intervention: penerapan arsitektur *deep learning* seperti CNN, U-Net, ResNet, EfficientNet, dan CNN-Transformer hybrid yang menggabungkan lebih dari satu tugas pembelajaran, seperti segmentasi klasifikasi, segmentasi pengukuran, atau segmentasi analisis warna.
- Comparison: perbandingan performa model MTL terhadap *single-task learning* tradisional, serta perbandingan efektivitas metode analisis citra berbasis *deep*

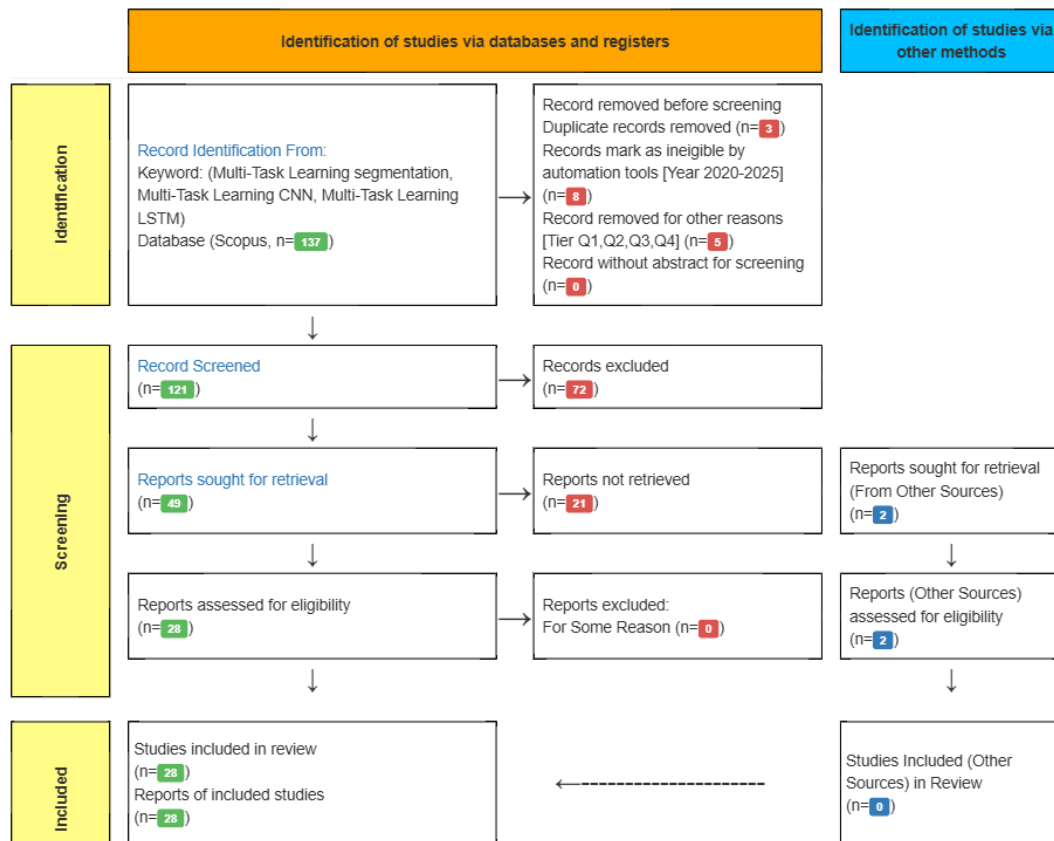
learning dengan pendekatan kemometri konvensional (PCA, PLS) atau representasi ruang warna (RGB vs HDR).

- Outcome: evaluasi performa model menggunakan metrik kuantitatif seperti Dice Score, IoU, akurasi, sensitivitas, spesifisitas, F1-score, MAE, RMSE, serta parameter *colorimetry* seperti rasio RGB, nilai CIELAB, dan Limit of Detection (LOD).

Proses pencarian literatur dilakukan secara sistematis pada lima basis data ilmiah utama, yaitu Scopus, PubMed, IEEE Xplore, ScienceDirect, dan SpringerLink. Proses pencarian dibagi menjadi dua kelompok utama berdasarkan fokus penelitian, yaitu:

1. Pencarian Literatur Topik Multi-Task Learning (MTL)

Difokuskan pada studi yang menerapkan Multi-Task Learning (MTL) berbasis *deep learning* untuk analisis citra medis dua dimensi. Dari hasil pencarian literatur di database *Scopus* (n=137) dan sumber lain (n=2), dilakukan penyaringan berdasarkan duplikasi, rentang tahun (2020–2025), serta kualitas jurnal. Sebanyak 121 artikel diseleksi berdasarkan judul dan abstrak, menghasilkan 49 artikel potensial, dan 28 studi akhir memenuhi kriteria inklusi untuk ditinjau. Proses seleksi ditunjukkan pada Gambar 2.4 dalam *Diagram PRISMA 2020*.



Gambar 2.4 Diagram alur seleksi literatur SLR pada topik multi-task learning.

2. Pencarian Literatur Topik Keloid Scars, Area Measurement, dan Colorimetry

Difokuskan pada studi yang membahas analisis citra digital, pengukuran area jaringan, dan evaluasi warna (*colorimetry*) pada objek medis, khususnya keloid dan jaringan kulit. Pencarian dibatasi pada periode publikasi 2020–2025, bahasa Inggris, dan artikel ilmiah terindeks Scopus (Q1–Q4) atau jurnal bereputasi internasional lainnya. Proses identifikasi awal menemukan 607 rekam literatur dari basis data Scopus. Setelah eliminasi berdasarkan tahun publikasi dan kelengkapan abstrak, 289 artikel dikeluarkan, menyisakan 318 studi untuk tahap *screening*. Dari hasil penyaringan, 168 artikel dievaluasi lebih lanjut pada tahap *full-text review*, dan setelah eksklusi berdasarkan relevansi konten, 79 studi akhir dinyatakan memenuhi kriteria inklusi dan dimasukkan dalam analisis. Alur proses seleksi ini divisualisasikan dalam Gambar 2.5 dalam bentuk Diagram PRISMA 2020.



Gambar 2.5 Diagram alur seleksi literatur SLR pada topik Keloid Scars treatment, Area Measurement, and Colorimetry

2.2.2 Hasil SLR

Kajian literatur sistematis yang dilakukan dalam penelitian ini mengungkapkan dua tren utama dalam pengembangan analisis citra medis berbasis pembelajaran mesin, yaitu penerapan Multi-Task Learning (MTL) pada citra medis dua dimensi, serta analisis warna berbasis citra digital (colorimetry).

Pada topik Multi-Task Learning (MTL) pada citra medis 2D, sebagian besar penelitian memanfaatkan kerangka MTL untuk mengintegrasikan segmentasi dan klasifikasi dalam satu model *end-to-end*. Pendekatan ini terbukti meningkatkan efisiensi serta akurasi diagnosis karena memungkinkan *feature sharing* antar-tugas, sehingga model dapat belajar konteks spasial dan semantik secara bersamaan. Sebagai contoh, Al-Masni et al. (2024) mengembangkan model *unified MTL* dengan mekanisme *joint reverse*

optimization untuk tugas simultan segmentasi dan diagnosis lesi kulit. Model ini menggabungkan fitur dari jalur *encoder-decoder* berbasis U-Net dengan *fully connected layers* untuk klasifikasi, serta memperkenalkan *reverse learning connection* antara submodul klasifikasi dan segmentasi. Pendekatan ini mampu menyeimbangkan dominasi antar-tugas dan meningkatkan hasil kedua tugas secara signifikan mencapai Dice Similarity Coefficient (DSC) sebesar 89,48% untuk segmentasi dan F1-score sebesar 82,07% untuk klasifikasi pada dataset ISIC 2016 dan PH2. Performa model terbukti meningkat signifikan ketika U-Net dikombinasikan dengan mekanisme tambahan seperti attention mechanism, residual blocks, maupun backbone pretrained seperti ResNet50 dan EfficientNet (Chen et al., 2020). Tren penelitian terkini menunjukkan munculnya arsitektur hybrid CNN + Transformer, yang menawarkan kemampuan lebih baik dalam menangkap konteks global sekaligus detail spasial. Selain itu, MTL meningkatkan efisiensi pelatihan melalui *parameter sharing*, yang memungkinkan pemanfaatan fitur bersama dan mempercepat konvergensi. Pendekatan ini juga terbukti mengurangi overfitting pada dataset medis berukuran kecil, karena pembelajaran multi-tugas membantu menyeimbangkan gradien dan memperkuat generalisasi model (Alenezi et al., 2023).

Sementara itu, pada ranah analisis warna berbasis citra digital (colorimetry), literatur menunjukkan bahwa representasi warna dalam ruang RGB, HSV, dan CIELAB mampu merefleksikan kondisi biologis penting seperti kandungan melanin, hemoglobin, serta tingkat inflamasi pada jaringan (Berasarte et al., 2025). Pendekatan paling banyak digunakan adalah RGB image analysis berbasis kamera digital atau smartphone karena sifatnya yang murah, portabel, dan mudah diterapkan di lapangan. Untuk ekstraksi warna dominan, metode K-Means Clustering dan Mean Shift Clustering merupakan pilihan populer. Aplikasi medisnya meliputi evaluasi luka kronis, pemantauan perkembangan terapi keloid, hingga digital histopathology. Lebih jauh lagi, tren terbaru mengarah pada integrasi colorimetry dengan deep learning, terutama CNN, U-Net, dan attention-based models, yang mampu meningkatkan akurasi analisis secara signifikan dibandingkan metode tradisional berbasis kemometri seperti PCA atau PLS (Abdolahnejad et al., 2024).

Kedua pendekatan ini memiliki potensi sinergis: MTL menyediakan kerangka otomatisasi multi-fungsi, sedangkan colorimetry memberikan indikator fisiologis

kuantitatif. Kombinasi keduanya memungkinkan sistem analisis citra medis yang lebih *holistic* tidak hanya memetakan bentuk dan ukuran, tetapi juga kondisi biologis jaringan secara visual. Tren penelitian terbaru (2020-2025) menunjukkan meningkatnya minat pada integrasi pembelajaran multimodal dan temporal seperti CNN-LSTM dan *Vision Transformer* (ViT), namun masih terbatas pada citra CT dan MRI, belum pada citra RGB klinis.

Secara keseluruhan, hasil SLR ini menegaskan bahwa baik MTL maupun colorimetry digital telah menjadi pendekatan penting dalam medical image analysis. Namun, belum ada penelitian yang mengintegrasikan keduanya dalam satu kerangka kerja *end-to-end* yang juga mempertimbangkan aspek temporal. Oleh karena itu, penelitian ini mengusulkan pengembangan model CNN-LSTM berbasis *Multi-Task Learning* yang mampu melakukan segmentasi, pengukuran luasan, dan analisis warna (*colorimetry*) secara bersamaan pada citra RGB *time-series* jaringan keloid.

2.2.3 Gap Analysis

Berdasarkan hasil kajian literatur sistematis terhadap penelitian terkini (2020 s.d 2025), diperoleh beberapa kesenjangan penelitian yang menjadi dasar pengembangan tesis ini, antara lain:

1. Ruang lingkup implementasi Multi-Task Learning (MTL) masih terbatas. Sebagian besar penelitian MTL pada citra medis hanya mengintegrasikan tugas segmentasi dan klasifikasi dalam satu arsitektur *end-to-end*. Belum ditemukan model yang secara bersamaan menggabungkan segmentasi, pengukuran luasan, dan analisis warna dalam satu kerangka terpadu.
2. Analisis warna belum terintegrasi dengan model deep learning. Pendekatan digital colorimetry pada bidang medis umumnya masih menggunakan metode statistik atau kemometri konvensional. Padahal, informasi warna dalam ruang RGB dan CIELAB memiliki potensi penting untuk merepresentasikan kondisi biologis jaringan, seperti inflamasi, vaskularisasi, dan hiperpigmentasi.
3. Fokus penelitian segmentasi medis masih dominan pada citra radiologi statis. Sebagian besar model segmentasi dikembangkan untuk citra CT atau MRI yang

bersifat *grayscale* dan tidak mencerminkan variasi warna serta tekstur jaringan kulit. Analisis berbasis citra RGB klinis yang lebih representatif terhadap kondisi permukaan kulit masih sangat terbatas.

4. Minimnya pendekatan pemodelan temporal pada citra medis. Hampir seluruh penelitian yang ada bersifat *single-frame*, sehingga belum mampu menangkap perubahan morfologi dan warna jaringan secara longitudinal. Aspek temporal dalam pemantauan luka atau perkembangan keloid belum banyak dieksplorasi melalui integrasi CNN dan model sekuensial seperti LSTM.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut melalui pengembangan model CNN-LSTM berbasis *Multi-Task Learning* (MTL) yang mampu melakukan segmentasi, pengukuran luasan, dan analisis colorimetry secara simultan pada citra RGB *time-series* keloid. Pendekatan ini diharapkan dapat menghasilkan sistem penilaian keloid yang lebih objektif, efisien, serta dapat diterapkan dalam konteks klinis untuk pemantauan luka secara longitudinal.

2.2.4 Kesimpulan SLR

Secara keseluruhan, hasil kajian literatur menunjukkan bahwa:

1. Pendekatan *Multi-Task Learning* (MTL) berbasis deep learning menunjukkan kinerja unggul dibandingkan pendekatan *single-task*. MTL memungkinkan pembelajaran bersama beberapa tugas seperti segmentasi dan klasifikasi dalam satu arsitektur *end-to-end*, sehingga meningkatkan efisiensi pelatihan dan generalisasi model pada dataset medis yang terbatas. Berbagai penelitian menunjukkan bahwa integrasi tugas-tugas yang saling berkaitan dapat meningkatkan stabilitas pembelajaran serta menekan risiko *overfitting*, dengan capaian performa segmentasi mencapai *Dice Score* di atas 0,85 dan akurasi klasifikasi melebihi 90%.
2. Analisis warna (*digital colorimetry*) memiliki potensi besar sebagai metode penilaian jaringan non-invasif. Representasi warna dalam ruang RGB, HSV, dan CIELAB terbukti mampu merefleksikan perubahan biologis pada jaringan, seperti inflamasi, vaskularisasi, dan pigmentasi. Pendekatan ini bersifat murah, portabel,

serta dapat digunakan untuk pemantauan kondisi luka dan keloid secara kuantitatif. Namun, sebagian besar studi masih menggunakan pendekatan kolorimetri konvensional dan belum mengintegrasikannya ke dalam model deep learning berbasis citra RGB secara otomatis.

3. Penerapan teknologi analisis citra medis secara klinis masih menghadapi sejumlah tantangan. Tantangan utama meliputi keterbatasan dataset publik berskala besar dengan anotasi warna dan area yang terstandar, kebutuhan validasi lintas populasi, serta integrasi sistem analisis citra secara *real-time* di lingkungan klinis. Sebagian besar penelitian masih bersifat eksperimental dan belum diterapkan secara luas untuk evaluasi longitudinal kondisi jaringan.

Berdasarkan temuan tersebut, penelitian ini menempati posisi strategis dalam mengisi kesenjangan dengan mengembangkan model CNN-LSTM berbasis *Multi-Task Learning* yang mampu melakukan segmentasi, pengukuran luasan, dan analisis warna secara simultan pada citra RGB *time-series* keloid. Pendekatan ini diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan sistem penilaian keloid yang lebih objektif, efisien, dan aplikatif dalam praktik klinis.

Selanjutnya, berdasarkan hasil kajian literatur sistematis yang telah dilakukan, dapat disimpulkan bahwa arah penelitian terkini dalam analisis citra medis menunjukkan dua fokus utama, yaitu pengembangan arsitektur *Multi-Task Learning (MTL)* untuk meningkatkan efisiensi dan akurasi model, serta pemanfaatan *digital colorimetry* sebagai pendekatan kuantitatif dalam menilai karakteristik biologis jaringan. Meskipun kedua pendekatan tersebut telah terbukti efektif secara terpisah, integrasi keduanya dalam satu kerangka *end-to-end* yang juga mempertimbangkan aspek temporal masih sangat terbatas.

Oleh karena itu, untuk memperkuat temuan hasil SLR dan mendukung landasan konseptual penelitian ini, bagian berikutnya menyajikan penelitian-penelitian terkait yang secara empiris mewakili tren utama tersebut. Kajian ini berfokus pada studi yang mengimplementasikan *MTL* pada segmentasi dan klasifikasi citra medis dua dimensi, serta penelitian yang menerapkan *colorimetric analysis* pada citra luka dan jaringan kulit. Dengan demikian, bagian *Penelitian Terkait* berfungsi untuk menjembatani hasil sintesis

teoretis dari SLR dengan dasar empiris yang akan menjadi pijakan dalam perancangan model CNN-LSTM berbasis MTL pada penelitian ini.

2.3 PENELITIAN TERKAIT

2.3.1 Segmentasi dan Klasifikasi Citra Medis berbasis *Deep Learning*

Perkembangan teknologi *deep learning* telah menghasilkan kemajuan signifikan dalam segmentasi citra medis, terutama untuk mendeteksi area jaringan abnormal seperti lesi kulit, luka kronis, atau tumor. Pendekatan *Convolutional Neural Network* (CNN) menjadi dasar dari berbagai arsitektur canggih seperti U-Net, EfficientNet, dan ResNet yang terbukti efektif dalam menangkap fitur spasial pada citra medis.

Studi oleh Abdolahnejad et al. (2024) dalam *A Prototype Machine Learning Pipeline for Assessing and Tracking Keloid Scars* mengembangkan sistem berbasis CNN untuk mendeteksi, mengukur, dan menganalisis warna jaringan keloid dari citra RGB 2D. Model ini memanfaatkan *fiducial marker* untuk kalibrasi ukuran dan menerapkan *K-Means clustering* untuk analisis warna. Pipeline tersebut menunjukkan akurasi klasifikasi 98% dengan kemampuan memantau perubahan ukuran dan warna keloid secara longitudinal.

Sementara itu, Al-Masni et al. (2024) dalam *A Unified Multi-Task Learning Model with Joint Reverse Optimization for Simultaneous Skin Lesion Segmentation and Diagnosis* memperkenalkan pendekatan *Multi-Task Learning (MTL)* yang secara simultan melakukan segmentasi dan klasifikasi lesi kulit. Dengan menerapkan strategi *joint reverse learning*, model ini mencapai nilai *Dice Similarity Coefficient* sebesar 89.48% pada dataset ISIC 2016 dan meningkatkan *F1-score* klasifikasi hingga 85.50%. Penelitian ini menunjukkan keunggulan arsitektur MTL dalam meningkatkan akurasi kedua tugas melalui pembelajaran bersama.

Selain itu, He et al. (2021) melalui *HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images* memperkenalkan arsitektur *hierarchically fused U-Net (HF-UNet)* yang menggabungkan dua tugas berbeda, yaitu segmentasi utama dan segmentasi batas (*boundary delineation*) sebagai tugas tambahan. Pendekatan ini terbukti mampu memperbaiki kejelasan batas

organ pada citra dengan kontras rendah dan meningkatkan konsistensi antar-tugas dalam kerangka MTL.

Dalam konteks longitudinal, Li et al. (2021) mengembangkan *Segis-Net*, sebuah framework *single-step deep learning* untuk *simultaneous segmentation and registration* pada data MRI serial. Model ini memanfaatkan informasi temporal untuk mempertahankan konsistensi spasio-temporal antar waktu, sehingga sangat relevan untuk studi luka yang diamati secara berkala seperti keloid.

Tinjauan komprehensif oleh Cassidy et al. (2025) dalam *Deep Learning in Chronic Wound Segmentation: A Comprehensive Review and Meta-analysis* juga menyoroti bahwa CNN, terutama U-Net dan turunannya, telah menjadi standar dalam segmentasi luka kronis, meskipun tantangan seperti keterbatasan dataset dan variasi warna jaringan masih menjadi hambatan utama.

Pendekatan-pendekatan ini menunjukkan bahwa model CNN dan MTL berpotensi tinggi untuk diadaptasi pada citra keloid, yang memiliki kompleksitas bentuk dan variasi warna serupa dengan lesi kulit lainnya.

2.3.2 Colorimetric Analysis pada Citra Luka dan Jaringan Kulit

Analisis warna (*colorimetry*) merupakan aspek penting dalam evaluasi jaringan kulit dan luka, karena perubahan warna sering kali berkorelasi dengan proses biologis seperti inflamasi, hiperpigmentasi, dan fase penyembuhan jaringan. Warna menjadi salah satu indikator klinis yang mudah diamati namun sulit diukur secara objektif tanpa bantuan sistem digital.

Penelitian oleh Abdollahnejad et al. (2024) secara eksplisit mengintegrasikan *colorimetry* ke dalam *pipeline* deteksi keloid. Mereka menggunakan metode K-Means clustering pada citra RGB untuk menilai heterogenitas pigmen pada jaringan keloid. Hasil penelitian menunjukkan bahwa variasi nilai RGB berhubungan dengan perubahan warna kulit pasien, yang dapat dipantau secara longitudinal untuk menilai progres terapi.

Sementara itu, Tang et al. (2022) dalam penelitiannya "*Diagnosis of Esophageal Lesions by Multi-Classification and Segmentation Using an Improved Multi-Task Deep*

Learning Model” menggabungkan analisis warna dan tekstur sebagai fitur tambahan untuk meningkatkan akurasi segmentasi dan klasifikasi lesi esofagus. Mereka memanfaatkan ResNet50 sebagai backbone CNN dengan *hard parameter sharing* untuk berbagi representasi spasial yang mencakup informasi intensitas warna dan bentuk jaringan. Walaupun fokus utama penelitian ini bukan pada colorimetry secara eksplisit, penggunaan fitur warna terbukti berkontribusi terhadap peningkatan performa model dalam membedakan jaringan sehat dan patologis. Pendekatan ini relevan bagi penelitian ini, karena menunjukkan bahwa fitur warna dapat memperkuat pembelajaran lintas-tugas (cross-task learning) antara segmentasi dan analisis warna keloid.

Selain itu, Sirisathitkul et al. (2025) dalam “*Accuracy and Precision of Smartphone Colorimetry: A Comparative Analysis in RGB, HSV, and CIELAB Color Spaces*” membandingkan akurasi pengukuran warna menggunakan tiga ruang warna utama (RGB, HSV, dan CIELAB). Studi ini menemukan bahwa ruang warna CIELAB memberikan presisi tinggi terhadap warna alami, sementara HSV lebih menyerupai persepsi visual manusia terhadap intensitas dan saturasi. Temuan ini sangat relevan untuk penelitian keloid, karena pemilihan ruang warna yang tepat dapat meningkatkan reliabilitas analisis warna jaringan secara kuantitatif.

Di sisi lain, Cassidy et al. (2025) dalam tinjauan meta-analisisnya mencatat bahwa fitur warna dalam ruang RGB dan HSV sering dimanfaatkan dalam segmentasi luka untuk membedakan jaringan nekrotik, fibrin, dan granulasi. Warna jaringan menjadi indikator penting kondisi luka, sehingga penggabungan fitur warna dan tekstur terbukti meningkatkan akurasi segmentasi.

Meskipun berbagai studi telah meneliti fitur warna dalam konteks luka dan jaringan kulit, sebagian besar studi analisis warna pada luka masih terpisah dari proses segmentasi dan pengukuran area. Penelitian ini berupaya mengisi kesenjangan tersebut dengan mengembangkan sistem *Multi-Task Learning* berbasis CNN-LSTM yang secara simultan melakukan segmentasi, pengukuran luasan, dan analisis warna pada citra RGB *time-series* keloid untuk mendukung pemantauan penyembuhan luka secara objektif dan berkelanjutan.

2.3.3 Tabel Perbandingan Penelitian Terkait

Tabel 2.3 merangkum perbandingan penelitian terdahulu terkait segmentasi dan colorimetry pada citra luka atau lesi kulit, mencakup algoritma yang digunakan, tujuan penelitian, serta aspek segmentasi, luasan, dan analisis warna. Sebagian besar studi masih berfokus pada tugas tunggal (*single-task*) seperti segmentasi atau analisis warna. Hanya beberapa, seperti He et al. (2021) dan Li et al. (2021), yang menerapkan Multi-Task Learning (MTL) untuk mengintegrasikan segmentasi dan regresi.

Adapun penelitian oleh Lailatul Hayani (2025) berbeda dari studi sebelumnya karena menjadi satu-satunya yang menggabungkan segmentasi, pengukuran luasan, dan analisis warna secara simultan melalui arsitektur CNN-LSTM berbasis MTL end-to-end, sehingga memberikan kontribusi baru dalam analisis citra keloid spatio-temporal.

Tabel 2.1 Tabel Perbandingan Penelitian Terkait

Judul Penelitian	Peneliti	Algoritma	Fokus	Tipe Arsitektur	Segmentasi	Luasan/ Regresi	Colorimetry
Deep Learning in Chronic Wound Segmentation: A Comprehensive Review and Meta-analysis	Cassidy et al. (2025)	U-Net, ResNet, FCN (review)	Tinjauan segmentasi luka kronis dengan deep learning	Single-task	Ya	Tidak	Tidak
A Prototype Machine Learning Pipeline for Assessing and Tracking Keloid Scars	Abdolahnejad et al. (2024)	CNN + K-Means clustering	Deteksi, pengukuran, dan analisis warna keloid RGB	Single-task (pipeline modular)	Ya	Ya	Ya
Diagnosis of Esophageal Lesions by Multi-Classification and	Tang et al. (2022)	Multi-Task CNN (ResNet50 Backbone)	Segmentasi dan klasifikasi lesi esofagus secara simultan	Multi-task (hard parameter sharing)	Ya	Tidak	Tidak

Segmentation Using an Improved Multi-Task Deep Learning Model							
HF-UNet: Learning Hierarchically Inter-Task Relevance in Multi-Task U-Net for Accurate Prostate Segmentation in CT Images	He et al. (2021)	Hierarchical Multi-Task U-Net (HF-UNet)	Segmentasi prostat dan delineasi batas organ	Multi-task	Ya	Ya	Tidak
Longitudinal Diffusion MRI Analysis Using Segis-Net: A Single-Step Deep-Learning Framework for Simultaneous	Li et al. (2021)	Segis-Net (CNN + Registration + Temporal Modeling)	Segmentasi MRI serial dengan konsistensi longitudinal	Multi-task (spatio-temporal)	Ya	Ya	Tidak

Segmentation and Registration							
Accuracy and Precision of Smartphone Colorimetry: A Comparative Analysis in RGB, HSV, and CIELAB Color Spaces	Sirisathitkul et al. (2025)	Colorimetric Comparison (RGB, HSV, CIELAB)	Analisis akurasi warna digital antar ruang warna	Single-task	Tidak	Tidak	Ya
Segmentasi, Pengukuran Luasan, dan Colorimetry pada Scar Keloid	Lailatul Hayani (2025)	CNN + LSTM (MTL end-to-end)	CNN + LSTM (MTL end-to-end)	Multi-task (spatio-temporal)	Ya	Ya	Ya

