

## ***Systematic Literature Review: Fungsi Loss pada Segmentasi Pembuluh Darah Retina Berbasis Deep Learning***

Putu Agoes Hendra Sugiarta<sup>1a)</sup>, Dandy Pramana Hostiadi<sup>1b)</sup>, Roy Rudolf Huizen<sup>1c)</sup>

<sup>1)</sup>Program Studi Magister Sistem Informasi, Institut Teknologi dan Bisnis STIKOM Bali, Bali, Indonesia  
e-mail: <sup>a)</sup>[242012003@stikom-bali.ac.id](mailto:242012003@stikom-bali.ac.id), <sup>b)</sup>[dandy@stikom-bali.ac.id](mailto:dandy@stikom-bali.ac.id), <sup>c)</sup>[roy@stikom-bali.ac.id](mailto:roy@stikom-bali.ac.id)

### ***Abstrak***

*Segmentasi pembuluh darah retina pada citra fundus merupakan komponen penting dalam sistem diagnosis berbantuan komputer untuk mendukung deteksi dan pemantauan berbagai penyakit oftalmologis. Perkembangan metode deep learning telah menghasilkan peningkatan kinerja yang signifikan dibandingkan pendekatan konvensional. Namun, sebagian besar penelitian di bidang ini masih berfokus pada pengembangan arsitektur jaringan, sementara peran fungsi loss sebagai komponen utama dalam proses optimasi model belum banyak dikaji secara sistematis. Artikel ini menyajikan Systematic Literature Review (SLR) yang bertujuan untuk mengidentifikasi dan menganalisis fungsi loss yang digunakan dalam segmentasi khususnya pembuluh darah retina berbasis deep learning. Kajian dilakukan terhadap tiga belas artikel terpilih yang membahas segmentasi pembuluh darah retina berbasis citra fundus menggunakan pendekatan deep learning dan secara eksplisit mengevaluasi fungsi loss. Hasil SLR menunjukkan bahwa fungsi loss konvensional berbasis piksel dan area, seperti Binary Cross-entropy dan Dice Loss, masih banyak digunakan, namun memiliki keterbatasan dalam kondisi ketidakseimbangan kelas dan preservasi struktur vaskular. Oleh karena itu, berbagai penelitian mengusulkan fungsi loss imbalance-aware dan topology-aware untuk meningkatkan sensitivitas terhadap pembuluh darah kecil serta menjaga kontinuitas dan konektivitas struktur vaskular. Temuan ini memberikan landasan ilmiah yang kuat bagi penelitian komparatif fungsi loss pada segmentasi pembuluh darah retina.*

***Kata kunci:*** Systematic Literature Review, Fungsi Loss, Segmentasi Pembuluh Darah Retina, Deep Learning, Citra Fundus.

### **1. Pendahuluan**

Segmentasi pembuluh darah retina pada citra *fundus* merupakan komponen penting dalam analisis citra oftalmologi karena struktur vaskular retina berperan krusial dalam diagnosis dan pemantauan berbagai penyakit sistemik, seperti retinopati diabetik dan hipertensi [1]. Citra *fundus* banyak digunakan dalam praktik klinis karena bersifat non-invasif, mudah diperoleh, dan mendukung aplikasi skrining berskala luas [2]. Seiring berkembangnya *deep learning*, pendekatan segmentasi berbasis arsitektur *encoder-decoder* menunjukkan peningkatan kinerja yang signifikan dibandingkan metode konvensional, khususnya dalam menangani variasi kontras dan kompleksitas struktur vaskular [3], [4].

Meskipun demikian, sebagian besar penelitian masih berfokus pada pengembangan arsitektur jaringan, sementara fungsi *loss* sebagai komponen kunci dalam proses optimasi sering digunakan secara *default* tanpa analisis komparatif yang mendalam [5], [6]. Berbagai studi menunjukkan bahwa fungsi *loss* konvensional seperti *Binary Cross-entropy* dan *Dice Loss* memiliki keterbatasan dalam mendeteksi pembuluh darah halus serta menjaga kontinuitas dan konektivitas vaskular [7], [8], sehingga mendorong pengembangan *loss imbalance-aware* dan *topology-aware* untuk memperbaiki preservasi struktur vaskular [5], [7], [9], [10]. Namun, kajian literatur yang secara sistematis memetakan dan menganalisis pengaruh berbagai fungsi *loss* pada segmentasi pembuluh darah retina masih terbatas, serta belum terdapat fungsi *loss* yang konsisten optimal pada seluruh skenario segmentasi [11]. Oleh karena itu, penelitian ini menyajikan *Systematic Literature Review* (SLR) untuk mengkaji secara sistematis peran dan pengaruh fungsi *loss* khususnya pada segmentasi pembuluh darah retina berbasis citra *fundus* dan *deep learning*.

### **2. Metode Penelitian**

Penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) untuk mengkaji secara sistematis penelitian yang membahas fungsi *loss* pada segmentasi pembuluh darah retina berbasis *deep learning*. Pendekatan ini dipilih karena memungkinkan pemetaan literatur yang terstruktur, transparan, dan replikabel untuk mengidentifikasi jenis fungsi *loss*, pengaruhnya terhadap kinerja segmentasi, serta

keterbatasan penelitian yang telah dilaporkan [12]. Kajian ini diarahkan oleh tiga *research questions*, yaitu: (RQ1) jenis fungsi *loss* yang digunakan, (RQ2) pengaruh fungsi *loss* terhadap kinerja segmentasi, dan (RQ3) keterbatasan penelitian fungsi *loss*, dengan perumusan RQ mengikuti prinsip SLR guna menjaga konsistensi proses pencarian, seleksi, dan analisis literatur [12], [13].

Pencarian literatur dilakukan pada IEEE Xplore, SpringerLink, dan arXiv menggunakan kombinasi kata kunci *retinal vessel segmentation*, *loss function*, *cIDice*, *centerline cross entropy loss*, dan *deep learning*. Proses seleksi studi mengikuti alur PRISMA, meliputi penyaringan judul dan abstrak, evaluasi teks lengkap, serta seleksi akhir berdasarkan kriteria inklusi dan eksklusi [14]. Studi yang disertakan (inklusi) membahas segmentasi pembuluh darah retina berbasis citra *fundus* dan mengevaluasi fungsi *loss* secara eksplisit, sedangkan studi dengan modalitas selain citra *fundus* atau tanpa penjelasan fungsi *loss* dikecualikan (eksklusi). Data diekstraksi secara sistematis meliputi penulis, tahun publikasi, dataset, fungsi *loss*, arsitektur, metrik evaluasi, serta temuan utama, yang selanjutnya dianalisis secara kualitatif dan komparatif sesuai pedoman SLR [12], [13].

### 3. Hasil dan Pembahasan

#### 3.1 Hasil Strategi Pencarian dan Seleksi Studi


Proses seleksi artikel dalam penelitian ini mengikuti pedoman PRISMA untuk memastikan transparansi dan keterulangan (*reproducibility*). Ringkasan kuantitatif dari setiap tahapan seleksi ditampilkan pada Tabel 1, sedangkan alur visual proses seleksi disajikan pada Gambar 1.

Berdasarkan Tabel 1, pencarian awal menghasilkan 153 artikel, yang terdiri dari 70 artikel dari IEEE Xplore, 65 artikel dari SpringerLink, dan 18 artikel dari arXiv. Setelah tahap penghapusan duplikasi, seluruh artikel (153 artikel) dilanjutkan ke tahap *screening* karena tidak ditemukan duplikasi antar basis data.

Tabel 1. Ringkasan Seleksi Artikel Berdasarkan PRISMA

| Database     | Jumlah Artikel | Screening (Judul & Abstrak) | Eligible (Teks Lengkap) | Eksklusi  | Inklusi SLR |
|--------------|----------------|-----------------------------|-------------------------|-----------|-------------|
| IEEE Xplore  | 70             | 16                          | 14                      | 13        | 1           |
| SpringerLink | 65             | 4                           | 4                       | 2         | 2           |
| arXiv        | 18             | 11                          | 11                      | 1         | 10          |
| <b>Total</b> | <b>153</b>     | <b>31</b>                   | <b>29</b>               | <b>16</b> | <b>13</b>   |

Pada tahap *screening* judul dan abstrak, jumlah artikel berkurang secara signifikan menjadi 31 artikel, yang menunjukkan bahwa sebagian besar publikasi awal tidak secara spesifik membahas fungsi *loss* dalam segmentasi pembuluh darah retina. Selanjutnya, 29 artikel dianalisis pada tahap *full-text assessment*, dan 16 artikel dikeluarkan karena tidak memenuhi kriteria inklusi, terutama karena pembahasan lebih berfokus pada desain arsitektur jaringan tanpa analisis atau perbandingan sistematis terhadap fungsi *loss*. Akhirnya sebanyak 13 artikel dinyatakan memenuhi seluruh kriteria dan diikutkan dalam SLR ini. Distribusi artikel terpilih berdasarkan basis data juga ditampilkan pada Tabel 1, yang menunjukkan dominasi artikel dari arXiv (10 artikel), diikuti SpringerLink (2 artikel), dan IEEE Xplore (1 artikel).



Gambar 1. Diagram Alir PRISMA Proses Seleksi Studi

Gambar 1 menyajikan alur seleksi studi secara visual, yang menggambarkan proses penyaringan artikel dari tahap identifikasi hingga studi yang diikutkan dalam SLR.

#### 3.2. Ikhtisar dan Cakupan Studi yang Dianalisis

Karakteristik utama dari 13 artikel yang diikutkan dalam SLR dirangkum secara sistematis pada Tabel 2 (Tabel *Data Extraction*). Tabel ini memuat informasi kunci meliputi dataset yang digunakan, jenis fungsi *loss*, arsitektur model, metrik evaluasi, serta temuan utama yang difokuskan pada aspek hasil metrik

evaluasi pada dataset *fundus* retina. Seperti ditunjukkan pada Tabel 2, sebagian besar penelitian menggunakan dataset standar segmentasi pembuluh darah retina, yaitu DRIVE, STARE, CHASEDB1, HRF, dan FIVES. Konsistensi penggunaan dataset ini memungkinkan dilakukan analisis komparatif secara kualitatif terhadap pengaruh fungsi *loss*, meskipun arsitektur model yang digunakan bervariasi.

Tabel 2. *Data Extraction* Artikel yang Diikutkan dalam SLR

| Judul   | Dataset   | Fungsi Loss  | Arsitektur                                     | Metrik Evaluasi  | Temuan Utama (Hasil Fokus Dataset Fundus Retina)   |
|---|---|--|--|--|--|
| <i>An Elastic Interaction-Based Loss function for Medical Image Segmentation – Lan et al., 2020 [15]</i>        | DRIVE, STARE, CHASEDB1                                      | Elastic Interaction-Based Loss, CE, Dice, Active Contour Loss, Surface | U-Net  | Sensitivity, Specificity, F1, AUC  | DRIVE: Sens = 0.9664, Spec = 0.8067, F1 = 0.8093, AUC = 0.8866; STARE: Sens = 0.9576, Spec = 0.7449, F1 = 0.7304, AUC = 0.8513; CHASEDB1: Sens = 0.9526, Spec = 0.8428, F1 = 0.8248, AUC = 0.8977;   |
| <i>Topological Similarity Index and Loss function for Blood Vessel segmentation – Arairoy et al., 2021 [16]</i> | DRIVE, STARE, CHASEDB1, Coronary Angiogram                  | Topological Loss   | U-Net  | AUC, Accuracy, cDice, TSI ( $\bar{m}H$ & $\bar{m}F$ )                                      | DRIVE: AUC = 96.0, acc = 93.5.0, cDice = 85.2, $\bar{m}H$ = 94.8, $\bar{m}F$ = 21.0; STARE: AUC = 98.7, acc = 95.8, cDice = 88.4, $\bar{m}H$ = 95.6, $\bar{m}F$ = 35.6; CHASEDB1: AUC = 97.8, acc = 95.8, cDice = 80.8, $\bar{m}H$ = 90.1, $\bar{m}F$ = 17.0;  |
| <i>Penalizing Small Errors Using an Adaptive Logarithmic Loss – Kaul et al., 2021 [17]</i>                      | DRIVE, ISIC 2018, Data Science Bowl 2018 (Nuclei)           | Adaptive Logarithmic Loss (ALL)  | U-Net, FocusNet                                | F1, Recall, Jaccard/IoU  | DRIVE: U-Net: F1 = 81.41, Recall = 75.83, Jaccard/IoU = 69.23; FocusNet: F1 = 82.17, Recall = 76.13, Jaccard/IoU = 70.96   |
| <i>Graph Cuts Loss to Boost Model Accuracy and Generalizability – Zheng et al., 2021 [18]</i>                   | SDC (gabungan STARE, DRIVE, CHASEDB1), IOSTAR, AV-WIDE, HRF | Graph Cuts Loss (GC Loss)  | U-Net, FCN                                     | Dice, HD95, cDice, Specificity, Sensitivity, Accuracy, AUC                                 | SDC: (U-Net, GC ( $\lambda=5$ )): Dice = 80.68, HD95 = 3.25, cDice = 80.79, Spec = 98.33, Sens = 79.12, Acc = 96.55, AUC = 97.80; (FCN, GC ( $\lambda=9$ )): Dice = 80.78, HD95: 3.19, cDice: 80.51, Spec: 98.33, Sens: 79.16, Acc = 96.57, AUC: 98.21   |
| <i>Unified Focal Loss – Yeung et al., 2021 [5]</i>  | CVC-ClinicDB, DRIVE, BUS2017, BraTS20, KiTS19               | Unified Focal Loss   | U-Net (2D & 3D)                                | DSC/Dice, IoU, Precision, Recall   | DRIVE: DSC = 0.803, IoU = 0.671, Precision = 0.793, Recall = 0.818   |
| <i>cDice: A Novel Topology-Preserving Loss – Shit et al., 2021 [7]</i>  | DRIVE, Roads, CREMI, Vessap                                 | cDice  | U-Net, FCN                                     | Dice, Acc., cDice, Betti Number Err. ( $\beta_0$ & $\beta_1$ )                             | U-Net: Dice = 75.21, Acc = 95.82, cDice = 76.86, $\beta_0$ Err = 1.538, $\beta_1$ Err = 1.389; FCN: Dice = 77.76, Acc = 96.04, cDice = 80.95, $\beta_0$ Err = 1.836, $\beta_1$ Err = 1.408;  |
| <i>SPNet: Shared Decoder and Pyramid-like Loss – Xu et al., 2022 [19]</i>                                       | DRIVE, STARE, CHASEDB1                                      | Pyramid-like Loss + Global Loss  | SPNet (U-Net-based)                            | Accuracy, Sensitivity, Specificity, AUC  | DRIVE: Acc = 0.9664, Sens = 0.8243, Spec = 0.9802, AUC = 0.9828; STARE: Acc = 0.9692, Sens = 0.8504, Spec = 0.9790, AUC = 0.9812; CHASEDB1: Acc = 0.9685, Sens = 0.8619, Spec = 0.9760, AUC = 0.9840;  |
| <i>Impact of Loss function in DL for Retinal Vessel segmentation – Herrera et al., 2022 [8]</i>                 | DRIVE   | Dice, Tversky, BCE, Combo Loss   | U-Net, SA-U-Net, Attention U-Net, Nested U-Net | AUC, MSE, Hausdorff Distance (HD), Dice  | Best loss: Combo Loss<br>U-Net: AUC = 0.9373, MSE = 0.0259, HD = 6.4871, Dice = 0.7668; SA-U-Net: AUC = 0.9335, MSE = 0.0355, HD = 7.9129, Dice = 0.809; Att-U-Net: AUC = 0.9391, MSE = 0.0259, HD = 6.4342, Dice = 0.7731; Nested-U-Net: AUC = 0.9344, MSE = 0.0251, HD = 6.4174, Dice = 0.7659;        |
| <i>Centerline Boundary Dice Loss – Shi et al., 2024 [9]</i>   | DRIVE, Parse 2022, TopCoW 2023                              | cbDice   | nnU-Net  | Dice, cDice, Betti Number Err. ( $\beta^{Err}$ ), Betti Matching Err. ( $\mu^{Err}$ ), NSD | cbDice ( $\alpha = 1, \beta = 0.5$ ): Dice = 82.5, cDice = 82.3, $\beta^{Err} = 358, \mu^{Err} = 590, NSD = 87.2$  |
| <i>Centerline-Cross Entropy Loss – Acebes et al., 2024 [10]</i>   | HRF, DR-HAGIS, TREND, ASOCA, FIVES                          | cICE   | small U-Net (2D) & nnU-Net (3D)                | Dice, cDice  | HRF: Dice = 79.34; cDice = 78.94; DR-HAGIS: Dice = 70.65; cDice = 70.06; TREND: Dice = 64.54; cDice = 67.04; ASOCA: Dice = 84.80; cDice = 84.95; FIVES-N: Dice = 83.40; cDice = 81.28; FIVES-A: Dice = 84.10; cDice = 80.64; FIVES-G: Dice = 71.83; cDice = 67.91; FIVES-D: Dice = 79.04; cDice = 74.65; |
| <i>Benchmarking Retinal Vessel Segmentation Models – Fadugba et al., 2024 [20]</i>                              | FIVES, DRIVE, CHASEDB1                                      | BCE, Dice, DiceBCE, cDice  | U-Net, FR-U-Net, MA-Net, SA-U-Net, W-Net       | DSC/Dice, MCC  | Nilai Dice pada tiap arsitektur untuk seluruh dataset:<br>U-Net: FIVES = 90.15, DRIVE = 77.23, CHASEDB1 = 80.55; FR-U-Net: FIVES = 90.37, DRIVE = 80.62, CHASEDB1 = 81.65; MA-Net: FIVES = 89.97, DRIVE = 77.78, CHASEDB1 = 80.56; SA-U-Net: FIVES = 86.55, DRIVE = 81.65,                               |

CHASEDB1 = 79.30; W-Net: FIVES = 85.65, DRIVE = 77.98, CHASEDB1 = 74.98;

| Judul   | Dataset                            | Fungsi Loss                                       | Arsitektur  | Metrik Evaluasi                                  | Temuan Utama<br>( Hasil Fokus Dataset Fundus Retina )   |
|---|------------------------------------|---|---|--|---|
| <i>SAM2LoRA: Composite Loss-Guided, Parameter-Efficient Finetuning of SAM2 for Retinal Fundus Segmentation – Mandal et al., 2024 [21]</i> | DRIVE, STARE, CHASEDB1, HRF, FIVES | Composite Loss (Binary Cross-entropy + Dice Loss) | SAM2 dengan parameter-efficient fine-tuning berbasis LoRA | Dice, AUC  | DRIVES: Dice = 0.82, AUC = 0.98; STARE: Dice = 0.81, AUC = 0.97; CHASEDB1: Dice = 0.83, AUC = 0.99; HRF: Dice = 0.78, AUC = 0.98; FIVES: Dice = 0.87, AUC = 0.99;   |
| <i>Dual-Scale Morphological Enhancement Network – Ni et al., 2025 [22]</i>  | DRIVE, STARE, CHASEDB1             | BCE + SSIM  | TED-SCNet   | Accuracy, Sensitivity, Specificity, AUC, F1, IoU | DRIVES: Acc = 0.9711, Sen = 0.8678, Spe = 0.9824, AUC = 0.9890, F1 = 0.8430, IoU = 0.7287; CHASEDB1: Acc = 0.9765, Sen = 0.9091, Spe = 0.9803, AUC = 0.9902, F1 = 0.8049, IoU = 0.6735; STARE: Acc = 0.9799, Sen = 0.8604, Spe = 0.9879, AUC = 0.9916, F1 = 0.8445, IoU = 0.7325; |

Selain itu, Tabel 2 juga menunjukkan bahwa mayoritas penelitian masih menggunakan arsitektur berbasis *encoder-decoder* (keluarga U-Net), sehingga perbedaan performa yang dilaporkan dalam artikel-artikel tersebut lebih dapat dikaitkan dengan pemilihan dan perancangan fungsi *loss*, bukan semata-mata perbedaan arsitektur jaringan.

### 3.3. Analisis Fungsi Loss Berdasarkan Tabel Data Extraction

#### 3.3.1 Fungsi Loss Pixel-Wise/Overlap sebagai Baseline

Berdasarkan Tabel 2, fungsi *loss* konvensional (*pixel-wise/overlap*) seperti *Binary Cross-entropy* dan *Dice Loss* masih digunakan secara luas sebagai *baseline* pada sebagian besar artikel yang dianalisis [8],[15],[17],[19],[20],[21]. Namun, beberapa studi menunjukkan bahwa fungsi *loss* ini cenderung mengoptimalkan *overlap* piksel global, sehingga kurang sensitif terhadap kesalahan kecil pada pembuluh darah tipis dan struktur vaskular yang kompleks [7],[8]. Hal ini terlihat jelas pada studi yang membandingkan *Dice Loss* dengan fungsi *loss* alternatif, di mana *Dice Loss* sering menghasilkan nilai metrik *overlap* yang tinggi tetapi gagal menjaga konektivitas struktur vaskular secara utuh, sebagaimana dilaporkan oleh Lan et al. dan Araújo et al. [15],[16].

#### 3.3.2 Fungsi Loss untuk Ketidakseimbangan Kelas (*Imbalance-Aware*)

Sebagaimana dirangkum pada Tabel 2, beberapa penelitian secara eksplisit mengevaluasi fungsi *loss* yang dirancang untuk menangani permasalahan ketidakseimbangan kelas, seperti *Unified Focal Loss*, *Tversky Loss*, dan *Combo Loss* [5],[8],[21]. Studi-studi tersebut melaporkan bahwa fungsi *loss imbalance-aware* mampu meningkatkan sensitivitas terhadap piksel pembuluh darah yang jumlahnya jauh lebih sedikit dibandingkan latar belakang, terutama pada pembuluh darah berdiameter kecil [5],[8]. Analisis komparatif pada Tabel 2 juga menunjukkan bahwa pemilihan fungsi *loss* yang tepat dapat menghasilkan peningkatan performa yang signifikan meskipun arsitektur jaringan yang digunakan sama, sehingga memperkuat peran fungsi *loss* sebagai faktor kunci dalam segmentasi pembuluh darah retina [5].

#### 3.3.3 Fungsi Loss Berbasis Topologi dan Konektivitas (*Topology-Aware*)

Salah satu temuan paling menonjol pada Tabel 2 adalah meningkatnya penggunaan fungsi *loss* berbasis topologi, seperti *clDice*, *cbDice*, dan *centerline cross-entropy* (clCE) [7],[9],[10]. Fungsi *loss* ini dirancang untuk mengatasi keterbatasan *loss* berbasis *overlap* dengan secara eksplisit mempertimbangkan konektivitas dan struktur graf pembuluh darah. Seperti ditunjukkan pada kolom Temuan Utama di Tabel 2, artikel-artikel yang menggunakan *topology-aware loss* secara konsisten melaporkan peningkatan kualitas struktur vaskular, meskipun dalam beberapa kasus nilai *Dice* tidak selalu menjadi yang tertinggi [7],[9]. Temuan ini mengindikasikan adanya *trade-off* antara optimasi akurasi piksel dan preservasi struktur topologi yang lebih bermakna secara klinis [9],[10].

#### 3.3.4 Fungsi Loss sebagai Pendukung Arsitektur Baru (*Hybrid Loss*)

Beberapa artikel dalam Tabel 2 mengusulkan arsitektur jaringan baru, namun tetap menyertakan pembahasan eksplisit mengenai fungsi *loss* yang digunakan, seperti kombinasi *Binary Cross-entropy* dengan SSIM, *pyramid-like loss*, atau *composite loss* [19][21],[22]. Berdasarkan hasil yang dirangkum pada Tabel 2, peningkatan performa yang dilaporkan tidak hanya berasal dari modifikasi arsitektur, tetapi juga dari desain fungsi *loss* yang selaras dengan karakteristik pembuluh darah retina, khususnya dalam mempertahankan detail pembuluh darah halus [21], [22]. Temuan ini menunjukkan bahwa fungsi *loss*

berperan sebagai komponen penting yang memperkuat kemampuan arsitektur dalam mengekstraksi dan merekonstruksi struktur vaskular secara lebih akurat.

### 3.4 Analisis Dataset dan Metrik Evaluasi

Dataset DRIVE menjadi *benchmark* utama dalam evaluasi fungsi *loss* untuk segmentasi pembuluh darah retina [8],[15],[16],[22], sementara STARE, CHASEDB1, HRF, dan FIVES digunakan secara terbatas untuk menguji variasi struktur vaskular [10],[21],[22], dengan sebagian besar studi masih membatasi evaluasi pada satu hingga dua dataset retina [5],[7],[8],[9],[10],[17]. Dari sisi evaluasi, *Dice Coefficient* dan *IoU* merupakan metrik yang paling umum digunakan [5],[7]-[10],[17],[18],[20]-[21], namun metrik *overlap* ini belum sepenuhnya merepresentasikan kualitas struktural pembuluh darah, khususnya terkait kontinuitas dan konektivitas [7],[9],[10]. Oleh karena itu, studi yang mengusulkan fungsi *loss* berbasis topologi umumnya melengkapi evaluasi dengan metrik topologi seperti *clDice* dan *Betti Number Error* ( $\beta_0$  &  $\beta_1$ ) [7],[9], sehingga pemilihan dataset dan metrik evaluasi menjadi faktor kunci dalam memperoleh penilaian kinerja fungsi *loss* yang lebih komprehensif [7],[20].

### 4. Gap Analysis dan Arah Penelitian

Berdasarkan hasil *Systematic Literature Review* terhadap 13 artikel terpilih, dapat diidentifikasi bahwa sebagian besar studi membandingkan atau mengevaluasi fungsi *loss* hanya pada satu atau beberapa arsitektur segmentasi tertentu, yang umumnya berbasis U-Net dan turunannya, tanpa melibatkan perbandingan arsitektur dengan tingkat kompleksitas yang berbeda (ringan, *baseline*, berat). Kondisi ini menyebabkan kontribusi dan pengaruh fungsi *loss* sulit digeneralisasikan di luar arsitektur yang digunakan dalam studi tersebut [5],[9],[10],[15],[16],[19],[20]. Keterbatasan serupa juga ditemukan pada studi yang mengusulkan fungsi *loss* berbasis topologi, seperti *clDice* dan turunannya, yang meskipun mampu meningkatkan kualitas struktur vaskular, masih diuji dalam lingkup arsitektur yang sempit [7],[9],[10]. Selain itu, meskipun dataset DRIVE, STARE, CHASEDB1, HRF, dan FIVES digunakan secara luas, sebagian besar penelitian masih mengandalkan evaluasi pada satu hingga dua dataset retina, sehingga kemampuan generalisasi fungsi *loss* terhadap variasi karakteristik data belum dapat disimpulkan secara kuat [5],[7],[8],[9],[10],[17].

Kesenjangan lain yang menonjol adalah ketidaksesuaian antara desain fungsi *loss* dan metrik evaluasi yang digunakan, di mana mayoritas studi masih mengandalkan metrik berbasis *overlap* seperti *Dice* dan *IoU* meskipun metrik tersebut tidak selalu mencerminkan kualitas struktur vaskular secara topologis [5],[7]-[10],[17],[18],[20]-[21]. Meskipun beberapa penelitian telah melengkapi evaluasi dengan metrik topologi seperti *clDice* dan *Betti Number Error* ( $\beta_0$  &  $\beta_1$ ) [7],[9], kerangka evaluasi yang secara konsisten menyelaraskan fungsi *loss*, metrik evaluasi, dan evaluasi lintas dataset masih belum tersedia, serta hanya sedikit studi yang melakukan analisis komparatif fungsi *loss* secara sistematis dalam satu kerangka eksperimen terkontrol [8]. Oleh karena itu, penelitian selanjutnya perlu diarahkan pada evaluasi fungsi *loss* yang komprehensif lintas arsitektur dan dataset, dengan integrasi metrik topologi sebagai bagian dari protokol evaluasi standar.

### 5. Kesimpulan

*Systematic Literature Review* ini mengkaji fungsi *loss* pada segmentasi pembuluh darah retina berbasis *deep learning* dengan memetakan jenis *loss*, dataset, metrik evaluasi, serta keterkaitannya dengan arsitektur dan generalisasi model. Hasil kajian menunjukkan bahwa fungsi *loss* dapat diklasifikasikan menjadi: *pixel-wise/overlap*, *imbalance-aware*, *topology-aware*, dan *hybrid loss*, di mana *Binary Cross-entropy* dan *Dice Loss* masih dominan digunakan meskipun terbatas dalam menjaga kontinuitas dan konektivitas pembuluh darah halus [8],[15],[17],[19],[20],[21]. Oleh karena itu, berbagai studi mengusulkan *loss* berbasis topologi dan *hybrid* untuk meningkatkan preservasi struktur vaskular, meskipun sering kali dengan kompromi pada metrik *overlap* piksel [7],[9],[10]. Dari sisi data, DRIVE, diikuti oleh STARE, CHASEDB1, HRF, dan FIVES, berperan sebagai *benchmark de facto*, namun sebagian besar studi masih terbatas pada evaluasi terhadap satu hingga dua dataset *fundus* retina dan belum menerapkan evaluasi lintas dataset *fundus* retina secara konsisten [5],[7],[8],[9],[10],[17]. Selain itu, meskipun *Dice Coefficient* dan *IoU* merupakan metrik evaluasi yang paling umum [5],[7]-[10],[17],[18],[20]-[22], metrik tersebut tidak selalu mencerminkan kualitas struktural vaskular, sehingga studi *topology-aware loss* umumnya melengkapinya dengan metrik topologi (*clDice* & *Betti Number Error*) [7],[9]. Secara keseluruhan, temuan ini menegaskan perlunya evaluasi sistematis fungsi *loss* yang konsisten lintas tingkat kompleksitas arsitektur segmentasi (ringan, *baseline*, berat), serta lintas dataset, dan lintas metrik evaluasi, untuk memperoleh kesimpulan yang lebih *robust* dan *generalisable*.

---

**Daftar Pustaka**

- [1] G. Chondrozoumakis *et al.*, “Retinal Biomarkers in Diabetic Retinopathy: From Early Detection to Personalized Treatment,” Feb. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/jcm14041343.
  - [2] T. Chaikijurajai, J. P. Ehlers, and W. H. W. Tang, “Retinal Microvasculature: A Potential Window Into Heart Failure Prevention,” Nov. 01, 2022, *Elsevier Inc.* doi: 10.1016/j.jchf.2022.07.004.
  - [3] Q. Qin and Y. Chen, “A review of retinal vessel segmentation for fundus image analysis,” *Eng. Appl. Artif. Intell.*, vol. 128, Feb. 2024, doi: 10.1016/J.ENGAPPAI.2023.107454.
  - [4] C. Zhang, X. Deng, and S. H. Ling, “Next-Gen Medical Imaging: U-Net Evolution and the Rise of Transformers,” *Sensors 2024, Vol. 24, Page 4668*, vol. 24, no. 14, p. 4668, Jul. 2024, doi: 10.3390/S24144668.
  - [5] M. Yeung, E. Sala, C.-B. Schönlieb, and L. Rundo, “Unified Focal loss: Generalising Dice and cross entropy-based losses to handle class imbalanced medical image segmentation,” Nov. 2021, [Online]. Available: <http://arxiv.org/abs/2102.04525>
  - [6] M. Brekke, “Optimizing a Deep Learning Model for Retinal Blood Vessel Segmentation,” M.Sc. thesis, Norwegian University of Science and Technology, Trondheim, Norway, 2024.
  - [7] S. Shit *et al.*, “cDice-a Novel Topology-Preserving Loss Function for Tubular Structure Segmentation.”
  - [8] D. Herrera, G. Ochoa-Ruiz, M. Gonzalez-Mendoza, and C. Mata, “Impact of loss function in Deep Learning methods for accurate retinal vessel segmentation,” Jun. 2022, [Online]. Available: <http://arxiv.org/abs/2206.00536>
  - [9] P. Shi, J. Hu, Y. Yang, Z. Gao, W. Liu, and T. Ma, “Centerline Boundary Dice Loss for Vascular Segmentation”, Accessed: Dec. 03, 2025. [Online]. Available: <https://github.com/PengchengShi1220/cbDice>.
  - [10] C. Acebes, A. H. Moustafa, O. Camara, and A. Galdran, “The Centerline-Cross Entropy Loss for Vessel-Like Structure Segmentation: Better Topology Consistency Without Sacrificing Accuracy,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 15008 LNCS, pp. 710–720, 2024, doi: 10.1007/978-3-031-72111-3\_67.
  - [11] J. Ma *et al.*, “Loss odyssey in medical image segmentation,” *Med. Image Anal.*, vol. 71, p. 102035, Jul. 2021, doi: 10.1016/J.MEDIA.2021.102035.
  - [12] B. Kitchenham and S. Charters, “Guidelines for performing Systematic Literature Reviews in Software Engineering,” vol. 2, Jan. 2007.
  - [13] C. Okoli, “A Guide to Conducting a Standalone Systematic Literature Review,” *Communications of the Association for Information Systems*, vol. 37, p. 43, 2015, [Online]. Available: <http://aisel.aisnet.org/cais/vol37/iss1/43>
  - [14] M. J. Page *et al.*, “The PRISMA 2020 statement: An updated guideline for reporting systematic reviews,” Mar. 29, 2021, *BMJ Publishing Group*. doi: 10.1136/bmj.n71.
  - [15] Y. Lan, Y. Xiang, and L. Zhang, “An Elastic Interaction-Based Loss Function for Medical Image Segmentation”, Accessed: Jan. 17, 2026. [Online]. Available: <https://github.com/charrywhite/>
  - [16] R. J. Ará ujo, J. S. Cardoso, S. Member, and elder P. Oliveira, “Topological Similarity Index and Loss Function for Blood Vessel Segmentation,” *IEEE Trans. Med. Imaging*, vol. XX, p. 1, Jul. 2021, Accessed: Jan. 17, 2026. [Online]. Available: <https://arxiv.org/pdf/2107.14531>
  - [17] C. Kaul, “Penalizing small errors using an Adaptive Logarithmic Loss,” 2020.
  - [18] Z. Zheng, M. Oda, and K. Mori, “Graph Cuts Loss to Boost Model Accuracy and Generalizability for Medical Image Segmentation”, Accessed: Jan. 17, 2026. [Online]. Available: <https://github.com/zzh>
  - [19] G.-X. Xu and C.-X. Ren, “SPNet: A novel deep neural network for retinal vessel segmentation based on shared decoder and pyramid-like loss”.
  - [20] J. Fadugba, P. Köhler, L. Koch, P. Manescu, and P. Berens, “Benchmarking Retinal Blood Vessel Segmentation Models for Cross-Dataset and Cross-Disease Generalization,” Jun. 2024, [Online]. Available: <http://arxiv.org/abs/2406.14994>
  - [21] S. Jose, “SAM2LoRA: Composite Loss-Guided, Parameter-Efficient Finetuning of SAM2 for Retinal Fundus Segmentation 1 st Sayan Mandal,” 2025.
  - [22] Y. Ni, P. Wang, W. Chen, and J. Qi, “Retinal vascular segmentation network based on dual-scale morphological enhancement,” *Journal of King Saud University - Computer and Information Sciences*, vol. 37, no. 7, Sep. 2025, doi: 10.1007/s44443-025-00191-3.
-

