

GBFS-MicroGraph

Optimasi Region Bacilli Color Score Menggunakan Best First Search untuk Pseudo-Anotasi Image-to-Graph pada Citra Hasil Patch Sputum

Mirza Tsabita Wafa'Ana - 13524114

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jalan Ganesha 10 Bandung

E-mail: mirzatsabita72@gmail.com , 13524114@std.stei.itb.ac.id

Abstract— Citra patch sputum dahak memiliki objek bakteri yang berukuran kecil, berbentuk tipis, serta memiliki variasi warna dan kontras yang dapat menyulitkan proses segmentasi. Penelitian ini mengusulkan GBFS-MicroGraph, yaitu metode pseudo-anotasi image-to-graph yang menggabungkan Bacilli Color Score dan Greedy Best-First Search untuk membentuk mask biner serta representasi graf objek bakteri. Bacilli Color Score digunakan untuk menghitung kemungkinan suatu piksel sebagai bagian dari bakteri berdasarkan informasi warna RGB, HSV, dan Lab. Selanjutnya, Greedy Best-First Search digunakan untuk menumbuhkan region dari seed dengan skor tertinggi menuju piksel tetangga berdasarkan prioritas skor warna dan kemiripan warna. Hasil region kemudian difilter untuk menghapus noise kecil dan dikonversi menjadi graf, dengan piksel foreground sebagai node dan hubungan ketetanggaan sebagai edge. Berdasarkan hasil pengujian pada citra patch sputum, GBFS-MicroGraph memperoleh mIoU sebesar 0,889 dan CCG sebesar 0,16, lebih baik dibandingkan Greedy Search, Brute Force Search, MicroGraph baseline, BFS-MicroGraph, dan SAM. Hasil ini menunjukkan bahwa optimasi region berbasis Greedy Best-First Search mampu menghasilkan pseudo-anotasi yang lebih mendekati ground truth.

Keywords— *GBFS-MicroGraph, Greedy Best-First Search, Bacilli Color Score, pseudo-anotasi, image-to-graph, citra patch sputum, segmentasi bakteri.*

I. INTRODUCTION (HEADING 1)

Citra patch sputum merupakan citra mikroskopis berukuran kecil yang digunakan untuk mengamati kandidat objek bakteri pada preparat dahak, terutama pada pemeriksaan sputum smear untuk mendeteksi *Mycobacterium tuberculosis* [1], [2]. Pada citra tersebut, objek bakteri umumnya memiliki ukuran kecil, bentuk memanjang, serta karakteristik warna yang dipengaruhi oleh proses pewarnaan mikroskopis, sehingga analisis berbasis kanal warna seperti RGB, HSV, dan CIELAB banyak digunakan dalam pendekatan segmentasi maupun deteksi bacilli [1], [3]. Akan tetapi, proses segmentasi objek bakteri pada citra patch sputum tidak selalu mudah. Hal ini disebabkan oleh variasi pencahayaan, perubahan warna pewarnaan, kontras objek yang rendah, ketebalan apusan, serta keberadaan debris atau artefak pada latar belakang [1], [3]. Kondisi tersebut membuat proses pembentukan mask biner menjadi sulit apabila hanya menggunakan metode segmentasi umum tanpa

penyesuaian terhadap karakteristik warna dan bentuk objek bakteri.

Dalam beberapa tahun terakhir, pendekatan untuk segmentasi dan deteksi objek mikroskopis berkembang ke arah deep learning, foundation model, dan model segmentasi interaktif. Penelitian berbasis YOLOv8 telah digunakan untuk mendeteksi bakteri tuberkulosis secara real-time pada citra mikroskopis sputum [2]. Pendekatan multimodal juga dikembangkan dengan menggabungkan kanal RGB, HSV, dan CIELAB untuk segmentasi dan klasifikasi *Mycobacterium tuberculosis* menggunakan YOLOv8 [1]. Selain itu, model berbasis Attention-Residual U-Net dan ensemble classification digunakan untuk meningkatkan segmentasi serta klasifikasi bacilli pada citra sputum smear [3]. Pada domain segmentasi mikroskopis yang lebih umum, CellSAM dikembangkan sebagai foundation model untuk segmentasi sel dan dapat digunakan pada citra sel, yeast, serta bakteri [4]. Sementara itu, SAM-Med3D, SegVol, dan VISTA3D menunjukkan perkembangan foundation model untuk segmentasi citra medis volumetrik [5]–[8]. Namun, sebagian besar pendekatan tersebut masih bergantung pada model besar, data latih, prompt, atau proses komputasi yang lebih kompleks. Selain itu, metode tersebut belum secara khusus dirancang untuk pseudo-anotasi image-to-graph pada citra patch sputum dengan memanfaatkan skor warna bacilli dan strategi pencarian berbasis prioritas. Tabel state-of-the-art (SOTA) sebagai pembandingan penelitian ini diperlihatkan pada Tabel 1.

Berdasarkan Tabel 1, dapat dilihat bahwa penelitian terbaru banyak mengarah pada penggunaan deep learning dan foundation model. Pendekatan seperti YOLOv8 [1][2], Attention-Residual U-Net [3], CellSAM [4], SAM-Med3D [5][8][9], SegVol [6], dan VISTA3D [7] memiliki kelebihan dalam kemampuan segmentasi atau deteksi visual. Akan tetapi, sebagian besar pendekatan tersebut membutuhkan data latih, model besar, prompt, atau komputasi yang lebih kompleks. Selain itu, metode-metode tersebut umumnya berfokus pada deteksi atau segmentasi mask, belum secara khusus membentuk pseudo-anotasi image-to-graph pada citra patch sputum. Oleh karena itu, penelitian ini mengambil arah yang berbeda, yaitu menggunakan strategi algoritma Greedy Best-First Search untuk mengoptimasi region berdasarkan Bacilli

TABLE I. RINGKASAN SOTA IMAGE-TO-GRAPH DAN GAP TERHADAP MICROGRAPH

Penelitian / Metode	Fokus Utama	Kelebihan	Keterbatasan terhadap Kasus Patch Sputum	Relevansi terhadap Penelitian Ini
Otsu Thresholding [1]	Pemilihan threshold otomatis dari histogram intensitas	Sederhana, cepat, dan tidak memerlukan data latih	Kurang adaptif terhadap variasi warna, pencahayaan, dan noise pada citra mikroskopis	Menjadi dasar pembandingan untuk pendekatan berbasis threshold
U-Net [2]	Segmentasi citra biomedis berbasis encoder-decoder CNN	Mampu menghasilkan segmentasi detail pada data biomedis	Membutuhkan data latih dan anotasi mask yang cukup banyak	Menunjukkan kekuatan deep learning, tetapi kurang sesuai jika dataset patch terbatas
DeepBacs [3]	Analisis citra bakteri menggunakan jaringan saraf dalam	Relevan untuk citra bakteri dan dapat digunakan untuk beberapa tugas analisis mikroskopis	Membutuhkan proses pelatihan, kurasi data, dan konfigurasi model	Menunjukkan bahwa analisis bakteri berbasis citra penting, tetapi pendekatannya berbeda dari strategi algoritma ringan
Segment Anything Model / SAM [4]	Foundation model untuk segmentasi berbasis prompt	Dapat melakukan segmentasi zero-shot pada berbagai citra umum	Pada citra medis, performa dapat tidak stabil bergantung pada prompt, ukuran objek, dan kontras	Digunakan sebagai pembandingan eksternal karena SAM merupakan model segmentasi umum yang kuat
Evaluasi SAM pada Medical Image [5]	Pengujian SAM pada berbagai dataset citra medis	Menunjukkan potensi SAM sebagai baseline segmentasi medis	Performa SAM bervariasi dan tidak selalu mengungguli metode khusus domain medis	Mendukung alasan bahwa citra medis/mikroskopis masih membutuhkan pendekatan khusus domain
μ SAM / Segment Anything for Microscopy [6]	Adaptasi SAM untuk segmentasi dan tracking data mikroskopis	Lebih sesuai untuk data mikroskopi dibanding SAM umum	Tetap bergantung pada model besar dan tidak secara khusus membangun pseudo-anotasi image-to-graph berbasis skor warna bakteri	Menjadi pembandingan konseptual untuk segmentasi mikroskopis
Graph-Based Image Segmentation [7]	Segmentasi citra menggunakan representasi graf	Memodelkan hubungan antar region atau piksel secara eksplisit	Tidak secara spesifik dirancang untuk pseudo-anotasi bakteri pada patch sputum	Menjadi landasan bahwa citra dapat dipandang sebagai graf
Connected Component Labeling / Sequential Digital Picture Processing [8]	Pelabelan komponen terhubung pada citra digital	Cocok untuk menelusuri objek pada citra biner dan membentuk komponen	Tidak mengatur pembentukan mask awal berbasis karakteristik warna bakteri	Menjadi dasar penggunaan BFS untuk menelusuri komponen foreground pada BFS-MicroGraph
Otsu Thresholding [1]	Pemilihan threshold otomatis dari histogram intensitas	Sederhana, cepat, dan tidak memerlukan data latih	Kurang adaptif terhadap variasi warna, pencahayaan, dan noise pada citra mikroskopis	Menjadi dasar pembandingan untuk pendekatan berbasis threshold

Color Score, sehingga proses segmentasi tetap ringan, terarah, dan sesuai dengan karakteristik warna objek bakteri.

Berdasarkan studi terkait, terdapat beberapa gap utama yang menjadi dasar penelitian ini. Pertama, pendekatan deep learning dan foundation model terbaru memang memiliki performa yang kuat, tetapi umumnya membutuhkan data latih, model besar, atau prompt sehingga kurang sederhana untuk eksperimen patch sputum berukuran kecil. Kedua, penelitian yang secara langsung membahas citra sputum masih banyak berfokus pada deteksi, klasifikasi, atau segmentasi berbasis model deep learning, belum pada pseudo-anotasi image-to-graph. Ketiga, belum banyak pendekatan yang menggabungkan skor warna domain-spesifik bacilli dengan strategi pencarian berbasis prioritas. Keempat, metode segmentasi umum belum tentu stabil pada citra patch sputum karena objek bakteri berukuran kecil, memiliki kontras rendah, dan dapat bercampur dengan debris atau artefak latar belakang. Berdasarkan gap tersebut, BFS-MicroGraph diusulkan sebagai pendekatan yang lebih sederhana, terarah, dan sesuai dengan konteks Strategi Algoritma. BFS-MicroGraph merupakan metode pseudo-anotasi citra patch sputum berbasis Breadth-First Search yang bertujuan membentuk mask biner sekaligus representasi graf dari objek bakteri. Metode ini memanfaatkan Bacilli Color Score untuk menentukan kandidat piksel bakteri, kemudian BFS digunakan untuk menelusuri komponen foreground yang

saling terhubung agar bentuk objek dapat dipertahankan secara utuh. Metode ini tidak bergantung pada pelatihan model besar, tetapi menggunakan Breadth-First Search untuk menelusuri komponen foreground secara sistematis. BFS dipilih karena mampu menjelajahi seluruh piksel yang saling terhubung dari suatu objek, sehingga bentuk bakteri dapat dipertahankan lebih utuh. Hal ini berbeda dengan Brute Force Search dan Greedy Search yang pada eksperimen ini cenderung memilih area dengan skor paling dominan saja, sehingga hasilnya lebih menyerupai lokalisasi titik pusat kandidat objek daripada segmentasi penuh. Sehingga kontribusi utama dari artikel ini adalah sebagai berikut :

Berdasarkan gap tersebut, penelitian ini mengusulkan GBFS-MicroGraph, yaitu metode pseudo-anotasi image-to-graph yang menggabungkan Bacilli Color Score dan Greedy Best-First Search. Bacilli Color Score digunakan untuk memberikan skor kemungkinan piksel sebagai bakteri berdasarkan karakteristik warna, sedangkan Greedy Best-First Search digunakan untuk menumbuhkan region dari seed terbaik ke piksel tetangga berdasarkan prioritas skor dan kemiripan warna. Dengan pendekatan ini, proses segmentasi tidak hanya memilih piksel dengan skor tertinggi, tetapi juga memperluas region secara terarah sehingga hasil mask dapat lebih mendekati bentuk objek bakteri. Kontribusi penelitian ini adalah sebagai berikut.




Fig. 1. Roadmap Riset Sputum Bakteri

1. Penelitian ini mengusulkan GBFS-MicroGraph, yaitu metode pseudo-anotasi image-to-graph pada citra patch sputum dengan menggunakan Greedy Best-First Search untuk mengoptimasi region berdasarkan Bacilli Color Score dan kemiripan warna piksel terhadap seed.
2. Penelitian ini mengevaluasi pengaruh beberapa strategi algoritma terhadap kualitas pseudo-anotasi, meliputi Greedy Search, Brute Force Search, MicroGraph baseline, BFS-MicroGraph, dan GBFS-MicroGraph, serta membandingkannya dengan metode segmentasi umum berbasis foundation model.

Penelitian ini telah dikembangkan sebelumnya dimana roadmap dari riset diperlihatkan pada Gambar 1. Gambar 1 menunjukkan roadmap pengembangan penelitian dari pendekatan awal berbasis operasi logika warna hingga metode proposed GBFS-MicroGraph. Tahap pertama menggunakan operasi logika pada kanal warna (R-G-B) untuk membentuk mask biner dan graf, tetapi masih menghasilkan artefak latar belakang serta objek yang terlihat patah-patah dengan mIoU 0,753. Tahap berikutnya mengembangkan MicroGraph dengan konversi warna RGB ke HSV dan Lab, Color Score, threshold adaptif, filtering, dan 8-koneksi sehingga artefak berkurang dan mIoU meningkat menjadi 0,844. Selanjutnya, BFS-MicroGraph menambahkan Breadth-First Search untuk menelusuri komponen foreground yang saling terhubung,

sehingga objek menjadi lebih utuh dengan mIoU 0,863. Tahap terakhir adalah GBFS-MicroGraph yang menggunakan Greedy Best-First Search untuk mengoptimasi pertumbuhan region berdasarkan Bacilli Color Score. Metode ini menghasilkan performa terbaik dengan mIoU 0,889 karena region bakteri dapat diperluas secara lebih terarah, artefak semakin berkurang, dan bentuk objek semakin menyerupai ground truth.

Sistematika penulisan artikel ini disusun menjadi empat bab. Bab 1 menyajikan pendahuluan yang mencakup latar belakang, permasalahan anotasi pada citra patch sputum dahak, posisi penelitian terhadap studi image-to-graph terdahulu, alasan pemilihan GBFS-MicroGraph, dan kontribusi utama penelitian. Bab 2 membahas arsitektur GBFS-MicroGraph, meliputi tahapan preprocessing, pembentukan mask, pemetaan pixel objek menjadi node, pembentukan edge berdasarkan hubungan ketetanggaan, serta representasi hasil dalam bentuk adjacency matrix. Bab 3 memaparkan tentang metode yang digunakan mulai dari dataset yang dipakai, alur eksperimen hingga pengujian. Bab 4 memaparkan hasil dan diskusi, termasuk evaluasi ablasi terhadap metode GBFS-Micrograph dan search yang lain, perbandingan GBFS-MicroGraph dengan SAM, analisis mean IoU, serta pembahasan kualitas hasil segmentasi dan anotasi graf. Bab 5 berisi penutup yang merangkum kesimpulan penelitian dan memberikan saran untuk pengembangan metode pada penelitian selanjutnya.




Fig. 2. Arsitektur GBFS-Micrograph

II. ARSITEKTUR GBFS-MICROGRAPH

GBFS-MicroGraph merupakan metode pseudo-anotasi image-to-graph pada citra patch sputum yang menggabungkan Bacilli Color Score dan Greedy Best-First Search. Metode ini menggunakan skor warna bakteri untuk menentukan kandidat piksel awal, kemudian menumbuhkan region dari seed terbaik menuju piksel tetangga berdasarkan prioritas skor warna dan kemiripan warna. Hasil region yang terbentuk selanjutnya difilter menjadi mask biner dan dikonversi ke dalam representasi graf, dengan piksel foreground sebagai node dan hubungan ketetanggaan sebagai edge. Perbedaan utama GBFS-MicroGraph terletak pada tahap pembentukan region sebelum mask biner akhir. Pada BFS-MicroGraph, BFS digunakan untuk menelusuri piksel foreground yang telah terbentuk dari threshold. Sebaliknya, pada GBFS-MicroGraph, Greedy Best-First Search digunakan untuk menumbuhkan region dari seed dengan Bacilli Color Score tertinggi. Piksel kandidat diproses berdasarkan prioritas skor warna dan kemiripan warna terhadap seed, sehingga pertumbuhan region menjadi lebih terarah sebelum dikonversi menjadi mask biner dan graf. Arsitektur GBFS-Micrograph ditunjukkan pada Gambar 2.

Satu patch citra sputum dahak ukurannya 40×40 . Karena citra berwarna RGB, maka citra ditulis seperti pada persamaan 1.

$$I \in \mathbb{R}^{40 \times 40 \times 3} \quad (1)$$

Setiap pixel punya 3 nilai warna, seperti ditunjukkan pada persamaan 2.

$$I(x, y) = [R(x, y), G(x, y), B(x, y)] \quad (2)$$

Dengan $0 \leq R(x, y), G(x, y), B(x, y) \leq 255$, Agar lebih mudah diproses, nilai RGB dinormalisasi diperlihatkan pada persamaan 3.

$$\begin{aligned} \tilde{R}(x, y) &= \frac{R(x, y)}{255} \\ \tilde{R}(x, y) &= \frac{R(x, y)}{255} \\ \tilde{R}(x, y) &= \frac{R(x, y)}{255} \end{aligned} \quad (3)$$

Berikutnya adalah proses baseline lama: Aljabar Boolean RGB. Dari setiap kanal warna dibuat mask biner, seperti ditunjukkan pada persamaan 4.

$$M_R(x, y) = \begin{cases} 1, & R(x, y) \geq T_R \\ 0, & R(x, y) < T_R \end{cases}$$

$$M_R(x, y) = \begin{cases} 1, & R(x, y) \geq T_R \\ 0, & R(x, y) < T_R \end{cases}$$

$$M_R(x, y) = \begin{cases} 1, & R(x, y) \geq T_R \\ 0, & R(x, y) < T_R \end{cases} \quad (4)$$

Lalu dibuat kombinasi Boolean:

$$M_{OR} = M_R \vee M_G \vee M_B$$

$$M_{OR} = M_R \vee M_G \vee M_B$$

$$M_{OR} = M_R \vee M_G \vee M_B$$

$$M_{OR} = M_R \vee M_G \vee M_B \quad (5)$$

Bagian ini bukan novelty utama, karena ini masih pengembangan dari metode sebelumnya. Ini dipakai sebagai baseline pembandingan. Metode usulan: Bacilli Color Score ditunjukkan pada persamaan 6. Karena bakteri biasanya tampak merah, ungu, tipis, dan agak gelap, maka dibuat skor kandidat bakteri. Pertama, hitung komponen warna merah:

$$E_R(x, y) = \max \left(0, \tilde{R}(x, y) - \frac{\tilde{G}(x, y) + \tilde{B}(x, y)}{2} \right) \quad (6)$$

Lalu hitung komponen ungu (Persamaan 7) :

$$E_P(x, y) = \max \left(0, \frac{\tilde{R}(x, y) + \tilde{B}(x, y)}{2} - \tilde{G}(x, y) \right) \quad (7)$$

Dari HSV diambil nilai saturasi (Persamaan 8):

$$S_{HSV}(x, y) \quad (8)$$

Dari Lab diambil kanal a^* , karena kanal ini menunjukkan kecenderungan warna merah. Dari Lab diambil kanal a^* , karena kanal ini menunjukkan kecenderungan warna merah (Persamaan 9) :

$$A_r(x, y) = \max \left(0, \frac{a^*(x, y) - 128}{127} \right) \quad (9)$$

Lalu kegelapan pixel dihitung dari nilai V pada HSV (Persamaan 10)

$$D(x, y) = 1 - V(x, y) \quad (10)$$

Kemudian skor kandidat bakteri dihitung (Pers. 11) :

$$S(x, y) = N(0.35A_r(x, y) + 0.20S_{HSV}(x, y) + 0.20E_R(x, y) + 0.15E_P(x, y) + 0.05D(x, y)) \quad (11)$$

dengan $N()$ adalah fungsi normalisasi ke rentang 0 sampai 1. Nilai $S(x,y)$ menunjukkan kemungkinan suatu piksel termasuk bagian dari objek bakteri. Semakin tinggi nilai $S(x,y)$, semakin besar peluang piksel tersebut merupakan kandidat bakteri. Pada metode lama, skor $S(x,y)$ langsung diubah menjadi mask biner menggunakan threshold adaptif. Namun, pada GBFS-MicroGraph, tahap threshold adaptif tersebut diganti dengan pemilihan seed dan proses region growing menggunakan Greedy Best-First Search. Pertama, seed dipilih dari piksel dengan Bacilli Color Score tinggi. Ambang seed ditentukan menggunakan persentil skor (Pers 12) :

$$s = P_p(s) \quad (12)$$

dengan $P_p(s)$ menyatakan persentil ke-(p) dari seluruh nilai Bacilli Color Score. Himpunan kandidat seed dinyatakan sebagai (Pers.13):

$$V_s = (x, y).S(x, y)_s \quad (13)$$

Dari himpunan kandidat seed tersebut, piksel dengan skor tertinggi dipilih sebagai seed awal (Pers 14) :

$$v_s = (x, y) V_s S(x, y) \quad (14)$$

Setelah seed diperoleh, dilakukan proses Greedy Best-First Search untuk menumbuhkan region dari seed tersebut. Berbeda dari BFS biasa yang menelusuri piksel berdasarkan urutan antrian, Greedy Best-First Search memilih piksel berdasarkan nilai prioritas. Prioritas piksel dihitung dari Bacilli Color Score dan kemiripan warna terhadap seed. Jarak warna antara piksel kandidat ($v=(x,y)$) dan seed ($v_s=(x_s, y_s)$) pada ruang warna Lab dihitung dan mempunyai kemiripan warna antara piksel kandidat dan seed didefinisikan sebagai (Pers.15):

$$D_{Lab}(v, v_s) = C_{sim}(v, v_s) = 1 - (0.1) \quad (15)$$

dengan D_{max} adalah batas maksimum jarak warna yang masih dianggap mirip. Fungsi prioritas pada Greedy Best-First Search didefinisikan sebagai (Pers 16) :

$$F(v) = S(v) + (1 -)C_{sim}(v, v_s) \quad (16)$$

dengan C_{sim} adalah bobot Bacilli Color Score terhadap kemiripan warna. Piksel dengan nilai $F(v)$ tertinggi akan diproses terlebih dahulu. Pada setiap iterasi, piksel dengan prioritas tertinggi diambil dari priority queue :

$$v^* = v_Q F(v) \quad (17)$$

dengan (Q) adalah priority queue yang berisi kandidat piksel untuk diekspansi. Piksel v^* diterima sebagai bagian dari region apabila memenuhi dua syarat. Syarat pertama adalah Bacilli Color Score piksel tersebut cukup tinggi $S(v^*)_a$. Syarat kedua adalah warna piksel tersebut masih cukup mirip dengan warna seed (Pers 18):

$$D_{Lab}(v^*, v_s) D_{max} \quad (18)$$

Jika kedua syarat tersebut terpenuhi, maka piksel v^* dimasukkan ke dalam region. Setelah itu, tetangga 8-arah dari piksel tersebut dimasukkan ke priority queue sebagai kandidat berikutnya. Himpunan tetangga 8-arah didefinisikan sebagai :

$$N_{8(x,y)} = (x + i, y + j)i, j(-1,0,1), (i,j)(0,0) \quad (19)$$

Region hasil pertumbuhan dari seed (v_s) didefinisikan sebagai $R_s = \{v, v_s\}$. Jika terdapat beberapa seed, maka semua region hasil pertumbuhan digabungkan menjadi mask kandidat $B_{0(x,y)}$. Dengan demikian, pada GBFS-MicroGraph, mask awal (B_0) tidak dibentuk langsung dari threshold global atau threshold adaptif, tetapi dari hasil pertumbuhan region berbasis prioritas Greedy Best-First Search. Setelah mask kandidat (B_0) terbentuk, dilakukan connected component filtering untuk menghapus komponen kecil yang dianggap noise. Misalkan komponen terhubung pada (B_0) Adalah Pers. 20:

$$C = \{C_1, C_2, C_3, \dots, C_k\} \quad (20)$$

Setiap komponen (C_i) memiliki himpunan piksel atau node (V_i). Komponen kecil dihapus apabila jumlah node-nya lebih kecil dari ambang minimum C_i' . Mask akhir setelah filtering didefinisikan sebagai $B_f(x,y)$. Dengan demikian, mask akhir merupakan matriks biner $B_f \{0,1\}^{40}$. Tahap endpoint bridging pada metode sebelumnya tidak digunakan sebagai tahap utama pada GBFS-MicroGraph. Hal ini karena proses Greedy Best-First Search sudah melakukan pertumbuhan region dari seed menuju piksel tetangga yang memiliki prioritas tinggi. Dengan demikian, bagian objek yang sebelumnya berpotensi terputus dapat diperluas melalui mekanisme region growing berbasis Bacilli Color Score dan kemiripan warna. Setelah mask akhir diperoleh, mask dikonversi menjadi graf. Piksel objek pada mask akhir dijadikan node (Pers.21) :

$$V = (x, y) B_f(x, y) = 1 \quad (21)$$

Hubungan antar piksel dijadikan edge berdasarkan aturan ketetanggaan 8-arah:

$$E = \{((x, y), (p, q)), (p, q) V, (|x - p|, |y - q|) = 1\} \quad (22)$$

Maka graf anotasi yang dihasilkan adalah: $G = (V, E)$. Jika node diberi nomor $V = \{v_1, v_2, v_3, \dots, v_n\}$. maka matriks ketetanggaan graf ditulis sebagai $A\{0,1\}^{nm}$. Dengan A_{ij} . Karena graf yang digunakan tidak berarah, maka berlaku $A_{ij} = A_{ji}$ Rumus akhir anotasi graf dapat ditulis sebagai (Pers 23):

$$(I) = \{G, A, C\} \quad (23)$$

Dengan $G = (V, E)$ dan $C = \{C_1, C_2, \dots, C_k\}$, Dimana Keterangan: (I) adalah citra patch sputum dahak, (G) adalah graf hasil anotasi, (V) adalah node atau piksel objek bakteri, (E) adalah edge atau hubungan ketetanggaan antar piksel objek, (A) adalah adjacency matrix, dan (C) adalah kumpulan komponen graf yang merepresentasikan kandidat bakteri. Dengan demikian, alur formula GBFS-MicroGraph Adalah (Pers:24)

$$I(x, y) S(x, y) V_s R_s B_0 B_f G = (V, E) A(I) \quad (24)$$

III. METODE

A. Dataset

Dataset yang digunakan pada penelitian ini adalah DDS1 (Dataset of Patch Images Derived from Sputum Smear Microscopy Images for the Development of Bacillus Detection Methods). Dataset ini merupakan dataset publik yang tersedia melalui Figshare dan berisi citra patch hasil pemotongan dari citra mikroskop sputum dahak. Dataset ini dipilih karena objek yang diteliti sesuai dengan fokus penelitian, yaitu bacillus pada citra sputum dahak yang berukuran kecil, tipis, dan memiliki warna khas merah atau ungu setelah proses pewarnaan Ziehl–Neelsen [10]. Secara keseluruhan, DDS1 terdiri dari 31.484 citra patch warna, yang terbagi menjadi 2.636 patch positif dan 28.848 patch negatif. Patch positif adalah patch yang mengandung bacillus, sedangkan patch negatif adalah patch yang tidak mengandung bacillus. Selain citra patch warna, dataset ini juga menyediakan 2.636 mask biner untuk patch positif. Mask biner tersebut digunakan sebagai ground truth, dengan pixel putih menunjukkan area bacillus dan pixel hitam menunjukkan latar belakang. Pada penelitian ini, data yang digunakan difokuskan pada patch positif karena tujuan utama MicroGraph adalah membentuk pseudo-anotasi graf dari objek bacillus. Citra warna digunakan sebagai input, sedangkan mask biner digunakan sebagai acuan evaluasi. Dengan demikian, pasangan data utama yang digunakan dalam pengujian adalah citra patch positif dan mask binernya. Patch negatif dapat digunakan sebagai data latar belakang, tetapi tidak menjadi fokus utama dalam evaluasi segmentasi karena tidak memiliki objek bacillus.

Ukuran asli patch pada DDS1 adalah 40×40 pixel. Namun, pada penelitian ini patch diproses menjadi ukuran 40×40 pixel agar sesuai dengan rancangan MicroGraph dan agar representasi graf yang dihasilkan tidak terlalu besar. Pemilihan ukuran kecil ini juga bertujuan untuk menjaga efisiensi pembentukan node, edge, dan adjacency matrix. Setelah citra diproses menjadi mask, setiap pixel objek pada mask direpresentasikan sebagai node, sedangkan hubungan ketetanggaan antar pixel direpresentasikan sebagai edge. Untuk kebutuhan visualisasi dan studi awal, penelitian ini menggunakan subset citra patch positif dari DDS1. Subset tersebut digunakan untuk menampilkan perbandingan antara citra warna, mask ground truth, hasil metode Boolean, hasil MicroGraph, dan hasil pembandingan berbasis SAM. Sementara itu, evaluasi kuantitatif dilakukan dengan membandingkan mask hasil prediksi terhadap mask biner ground truth menggunakan metrik segmentasi dan metrik berbasis graf. Ringkasan dataset yang digunakan ditunjukkan pada Tabel 2.

TABLE II. RINGKASAN SOTA IMAGE-TO-GRAPH DAN GAP TERHADAP MICROGRAPH

Keterangan	Jumlah	Penjelasan
Total citra patch warna	31.484	Seluruh citra patch RGB pada DDS1.
Patch positif	2.636	Patch warna yang mengandung bacillus.

Dengan struktur dataset tersebut, DDS1 sesuai digunakan untuk penelitian MicroGraph karena menyediakan dua

informasi penting sekaligus, yaitu citra warna sebagai input dan mask biner sebagai acuan evaluasi. Citra warna digunakan untuk membentuk mask kandidat melalui bacilli score, sedangkan mask biner digunakan untuk menghitung kualitas hasil segmentasi dan kesesuaian struktur graf.

B. Alur Eksperimen

Pengujian dilakukan dalam dua skenario. Skenario pertama adalah studi ablasi untuk melihat pengaruh strategi algoritma terhadap hasil pseudo-anotasi. Skenario kedua adalah perbandingan dengan SAM sebagai metode segmentasi umum berbasis foundation model. Pada studi ablasi, metode yang dibandingkan adalah Greedy Search, Brute Force Search, MicroGraph baseline, BFS-MicroGraph, dan GBFS-MicroGraph sebagai proposed method. Greedy Search memilih kandidat piksel berdasarkan skor tinggi secara bertahap. Brute Force Search mencoba beberapa kemungkinan threshold secara iteratif. MicroGraph baseline menggunakan logical color score dan threshold adaptif. BFS-MicroGraph menggunakan Breadth-First Search untuk menelusuri komponen foreground. GBFS-MicroGraph menggunakan Greedy Best-First Search untuk menumbuhkan region dari seed terbaik berdasarkan Bacilli Color Score dan kemiripan warna. Perbandingan eksternal dilakukan terhadap SAM (melalui demo di <https://segment-anything.metademolab.com/demo#>). SAM digunakan untuk melihat apakah model segmentasi umum mampu menangani objek bakteri kecil pada citra patch sputum.

C. Pengujian

Pengujian pada penelitian ini dilakukan dalam dua arah, yaitu pengujian berbasis segmentasi dan pengujian berbasis graf. Pengujian berbasis segmentasi digunakan untuk menilai seberapa dekat mask hasil prediksi dengan mask ground truth. Sementara itu, pengujian berbasis graf digunakan untuk menilai apakah struktur graf yang dihasilkan sudah sesuai dengan bentuk objek bakteri. Metrik pengujian yang digunakan pada penelitian ini dapat diringkas pada Tabel 3.

TABLE III. JENIS PENGUJIAN

Jenis Pengujian	Metrik	Tujuan
Segmentasi	mean IoU	Mengukur rata-rata kualitas segmentasi secara keseluruhan.
Graf	Connected Component Error	Mengukur kesesuaian jumlah komponen graf terhadap ground truth.

Dengan kombinasi pengujian tersebut, hasil MicroGraph tidak hanya dinilai dari sisi visual, tetapi juga dari sisi segmentasi dan struktur graf. Hal ini penting karena tujuan utama MicroGraph bukan hanya menghasilkan mask, tetapi menghasilkan pseudo-anotasi berbasis graf yang ringan, terstruktur, dan dapat direkonstruksi kembali menjadi mask biner.

C.1 Pengujian Segmentasi

Pada pengujian segmentasi, metrik utama yang digunakan adalah Intersection over Union (IoU) dan mean IoU (mIoU).

IoU digunakan untuk mengukur tingkat tumpang tindih antara mask hasil prediksi dan mask ground truth. Semakin besar nilai IoU, semakin baik hasil segmentasi. Karena objek bakteri berukuran kecil dan jumlah pixel latar belakang jauh lebih besar daripada pixel objek, IoU lebih sesuai digunakan dibandingkan akurasi biasa. Akurasi dapat terlihat tinggi hanya karena banyaknya pixel latar belakang yang benar, padahal objek bakteri belum tentu terdeteksi dengan baik.

$$IoU_{Objek} = \frac{TP}{TP + FP + FN}$$

dengan TP atau true positive adalah jumlah pixel bakteri yang berhasil diprediksi sebagai bakteri, FP atau false positive adalah jumlah pixel latar belakang yang salah diprediksi sebagai bakteri, dan FN atau false negative adalah jumlah pixel bakteri yang tidak berhasil terdeteksi. Sementara itu, IoU untuk kelas latar belakang dihitung menggunakan persamaan 28.

$$IoU_{Latarbelakang} = \frac{TN}{TN + FP + FN} \quad (28)$$

dengan TN atau true negative adalah jumlah pixel latar belakang yang berhasil diprediksi sebagai latar belakang. Setelah nilai IoU untuk kedua kelas diperoleh, nilai mean IoU dihitung dengan mengambil rata-rata dari IoU objek dan IoU latar belakang, seperti pada persamaan 29.

$$mIoU = \frac{IoU_{Objek} + IoU_{Latarbelakang}}{2} \quad (29)$$

Nilai mIoU berada pada rentang 0 hingga 1. Semakin mendekati 1, maka hasil segmentasi semakin mirip dengan mask acuan. Sebaliknya, semakin mendekati 0, maka hasil segmentasi semakin jauh dari mask acuan. Dalam konteks penelitian ini, metode yang memiliki mIoU lebih tinggi dianggap lebih baik karena mampu menghasilkan mask bakteri yang lebih sesuai dengan label acuan. Penggunaan mIoU juga membantu membandingkan metode baseline seperti RGB, OR, AND, XOR, XNOR, SAM, dan Proposed MicroGraph secara lebih adil. Hal ini penting karena jumlah pixel latar belakang pada citra patch lebih banyak dibandingkan pixel bakteri. Dengan demikian, mIoU memberikan penilaian yang lebih fokus terhadap kualitas segmentasi objek kecil.

C.2 Pengujian Graf

Selain IoU, penelitian ini juga menggunakan Connected Component Error (CCE) sebagai pengujian berbasis graf. CCE digunakan untuk membandingkan jumlah komponen terhubung pada graf hasil prediksi dengan graf ground truth. Jika ground truth memiliki satu objek bakteri, maka hasil yang baik seharusnya juga menghasilkan satu komponen graf utama. Jika hasil prediksi memecah satu bakteri menjadi beberapa bagian kecil, maka nilai CCE akan meningkat. Sebaliknya, semakin kecil nilai CCE, semakin baik kemampuan metode dalam mempertahankan struktur objek bakteri. Graf ground truth dinyatakan sebagai Persamaan 30.

$$G_{gt} = (V_{gt}, E_{gt}) \quad (30)$$

dan graf hasil prediksi dinyatakan sebagai (Pers 31)

$$G_{pred} = (V_{pred}, E_{pred}) \quad (31)$$

dengan (V) sebagai himpunan node dan E sebagai himpunan edge. Jumlah komponen terhubung pada suatu graf dinyatakan dengan fungsi sebagai $CC(G)$. Maka nilai Connected Component Gap untuk satu citra dihitung dengan Pers. 32.

$$CCG = |CC(G_{pred}) - CC(G_{gt})| \quad (32)$$

Untuk seluruh dataset yang terdiri dari (N) citra, nilai rata-rata CCG dihitung dengan Pers. 33.

$$\overline{CCG} = \frac{1}{\sum_{i=1}^N |CC(G_{pred}^i) - CC(G_{gt}^i)|} \quad (33)$$

Semakin kecil nilai ($\overline{CCG}$), semakin baik metode dalam mempertahankan struktur objek bakteri. Nilai CCG sebesar 0 menunjukkan bahwa jumlah komponen graf hasil prediksi sama dengan jumlah komponen graf pada ground truth. Sebaliknya, nilai CCG yang besar menunjukkan bahwa objek bakteri terlalu banyak terpecah menjadi beberapa komponen, atau beberapa objek justru tergabung menjadi satu komponen yang tidak sesuai. Oleh karena itu, jumlah node dan edge digunakan sebagai informasi tambahan untuk memahami karakteristik graf yang dihasilkan.

IV. HASIL DAN DISKUSI

Bagian ini menyajikan hasil pengujian GBFS-MicroGraph sebagai metode proposed pada citra hasil patch sputum. Pengujian dilakukan melalui dua skenario, yaitu studi ablasi internal dan perbandingan dengan SAM sebagai metode segmentasi umum berbasis foundation model. Evaluasi menggunakan mIoU untuk mengukur kesesuaian mask terhadap ground truth dan CCG untuk menilai kedekatan struktur graf terhadap anotasi acuan. Semakin tinggi nilai mIoU, semakin baik kesesuaian mask yang dihasilkan. Sebaliknya, semakin rendah nilai CCG, semakin dekat struktur graf terhadap ground truth.

A. Studi Ablasi

Sebelum evaluasi visual, dilakukan evaluasi kuantitatif untuk membandingkan pengaruh masing-masing strategi algoritma terhadap kualitas pseudo-anotasi. Tabel 4 menampilkan hasil studi ablasi yang melibatkan Greedy Search, Brute Force Search, MicroGraph baseline, BFS-MicroGraph, dan GBFS-MicroGraph sebagai metode proposed.

TABLE IV. HASIL STUDI ABLASI

Metode	↑ mIoU (%)	↓ CCG
Greedy	0.780	0.27
Brute Force	0.780	0.27
MicroGraph	0.844	0.20
BFS-MicroGraph	0.863	0.18
GBFS-MicroGraph (Proposed)	0.889	0.16




Fig. 3. Hasil Mask Biner dari Studi Ablasi

Berdasarkan Tabel 4, GBFS-MicroGraph memperoleh hasil terbaik dengan mIoU 0.889 dan CCG 0.16. Nilai ini lebih baik dibandingkan BFS-MicroGraph yang memperoleh mIoU 0.863 dan CCG 0.18, MicroGraph baseline dengan mIoU 0.844 dan CCG 0.20, serta Greedy dan Brute Force yang sama-sama memperoleh mIoU 0.780 dan CCG 0.27. Kenaikan mIoU menunjukkan bahwa mask yang dihasilkan proposed lebih mendekati ground truth, sedangkan penurunan CCG menunjukkan bahwa struktur graf yang terbentuk semakin dekat dengan struktur anotasi acuan. Hasil tersebut dapat dijelaskan dari karakteristik masing-masing strategi. Brute Force dan Greedy sederhana hanya memilih kandidat berdasarkan skor atau threshold tertentu, sehingga area objek yang diperoleh sering terlalu kecil dan tidak mencakup seluruh bentuk bakteri. MicroGraph baseline sudah lebih baik karena menggunakan logical color score dan threshold adaptif, tetapi masih dapat mengalami fragmentasi objek. BFS-MicroGraph memperbaiki fragmentasi melalui penelusuran komponen foreground. Akan tetapi, BFS tetap bergantung pada kualitas mask awal. GBFS-MicroGraph memberikan hasil lebih baik karena menggunakan mekanisme Greedy Best-First Search: region tidak hanya ditelusuri secara terhubung, tetapi juga diprioritaskan berdasarkan skor bacilli dan kemiripan warna. Kombinasi tersebut membuat proses segmentasi lebih selektif sekaligus tetap mampu mempertahankan area objek.

Setelah melihat hasil kuantitatif, dilakukan pengamatan visual terhadap beberapa metode yang digunakan dalam studi ablasi. Gambar 2 memperlihatkan perbandingan citra warna, ground truth, Brute Force, Greedy, BFS, dan GBFS-MicroGraph sebagai metode proposed. Perbandingan visual ini bertujuan untuk melihat apakah setiap metode mampu mempertahankan bentuk objek bakteri secara utuh atau hanya mendeteksi bagian tertentu dari objek. Berdasarkan Gambar 2, Brute Force dan Greedy cenderung menghasilkan mask yang lebih kecil dibandingkan ground truth. Kedua metode tersebut lebih banyak mengambil area dengan skor warna paling dominan, sehingga keluarannya menyerupai lokalisasi kandidat objek atau centroid-like detection. BFS menghasilkan bentuk yang lebih utuh karena menelusuri piksel foreground yang saling terhubung. GBFS-MicroGraph memperbaiki hasil

tersebut dengan menumbuhkan region dari kandidat bernilai tinggi menggunakan prioritas Greedy Best-First Search, sehingga objek bakteri dapat dipertahankan lebih baik sekaligus mengurangi area yang tidak relevan. Selain menghasilkan mask biner, GBFS-MicroGraph juga dapat divisualisasikan sebagai deteksi kandidat objek pada citra warna. Gambar 3 memperlihatkan hasil deteksi objek bakteri yang ditandai pada area dengan skor bacilli yang tinggi. Visualisasi ini digunakan untuk menunjukkan bahwa metode proposed tidak hanya bekerja pada ruang biner, tetapi juga dapat menunjukkan lokasi kandidat bakteri pada citra asli.




Fig. 4. Hasil GBFS-MicroGraph

Pada Gambar 3, kandidat objek yang terdeteksi berada di sekitar bagian bakteri yang memiliki respons warna paling kuat. Hasil ini terjadi karena GBFS-MicroGraph menggunakan Bacilli Color Score sebagai fungsi prioritas. Seed awal dipilih dari piksel dengan skor tertinggi, kemudian region diperluas ke piksel tetangga berdasarkan skor dan kemiripan warna. Dengan demikian, metode ini lebih terarah dibandingkan BFS biasa yang hanya menelusuri mask awal, serta lebih lengkap dibandingkan Greedy sederhana yang cenderung berhenti pada area pusat objek.

B. Perbandingan Dengan Sota

Selain dibandingkan dengan metode internal, GBFS-MicroGraph juga dibandingkan dengan SAM sebagai metode segmentasi umum berbasis foundation model.

TABLE V. HASIL PERBANDINGAN SOTA

Metode	↑ mIoU (%)	↓ CCG
SAM	0.749	0.30
GBFS-MicroGraph (Proposed)	0.889	0.16

Warna										
GT										
SAM										
Prop										

Fig. 5. Perbandingan Output Hasil mask SAM dengan GBFS-Micrograph

Perbandingan ini dilakukan untuk melihat apakah model segmentasi umum mampu menangani citra patch sputum yang memiliki objek kecil, kontras terbatas, dan variasi warna latar belakang. Ringkasan hasil kuantitatif perbandingan antara SAM dan GBFS-MicroGraph ditunjukkan pada Tabel 5. Tabel ini digunakan untuk memperjelas perbedaan performa antara model segmentasi umum dan metode proposed yang dirancang khusus untuk citra patch sputum.

Berdasarkan Tabel 5, SAM memperoleh mIoU 0.749 dan CCG 0.30, sedangkan GBFS-MicroGraph memperoleh mIoU 0.889 dan CCG 0.16. Selisih mIoU sebesar 0.140 menunjukkan bahwa mask proposed lebih sesuai dengan ground truth. Selain itu, selisih CCG sebesar 0.14 menunjukkan bahwa struktur graf dari proposed lebih dekat dengan struktur anotasi acuan. Perbedaan ini terjadi karena SAM merupakan model segmentasi umum yang tidak secara khusus menggunakan karakteristik warna bacilli pada patch sputum. Sebaliknya, GBFS-MicroGraph menggunakan skor warna domain-spesifik dan pencarian berbasis prioritas, sehingga lebih sesuai untuk objek bakteri kecil yang memiliki pola warna tertentu. Perbandingan Output Hasil mask SAM dengan GBFS-Micrograph diperlihatkan pada Gambar 5.

Berdasarkan Gambar 5, SAM masih dapat menghasilkan mask pada beberapa objek, tetapi hasilnya tidak selalu stabil untuk patch kecil. Pada beberapa kasus, SAM cenderung menghasilkan area yang terlalu besar, terlalu kasar, atau tidak mengikuti bentuk bakteri secara tepat. Sebaliknya, GBFS-MicroGraph menghasilkan mask yang lebih konsisten terhadap bentuk objek karena proses segmentasi dipandu oleh Bacilli Color Score dan region growing berbasis prioritas. Secara umum, hasil eksperimen menunjukkan bahwa strategi algoritma berpengaruh terhadap bentuk mask dan kualitas pseudo-anotasi. Metode yang hanya melakukan seleksi kandidat, seperti Greedy dan Brute Force, cenderung menghasilkan keluaran yang kecil karena hanya mempertahankan area dengan skor paling dominan. Metode tersebut lebih cocok dipandang sebagai lokalisasi kandidat objek daripada segmentasi penuh. BFS menghasilkan mask yang lebih utuh karena menelusuri komponen yang saling terhubung. Namun, karena BFS bekerja setelah mask awal terbentuk, kualitasnya tetap sangat dipengaruhi oleh hasil segmentasi awal.

GBFS-MicroGraph mengatasi sebagian kelemahan tersebut dengan menggabungkan dua ide utama: pemilihan kandidat berbasis skor dan perluasan region berbasis prioritas. Dalam konteks Strategi Algoritma, pendekatan ini sesuai dengan

Greedy Best-First Search karena setiap kandidat piksel diproses berdasarkan nilai prioritas tertinggi. Prioritas tersebut dibentuk dari Bacilli Color Score dan kemiripan warna, sehingga pencarian diarahkan ke area yang paling mungkin merepresentasikan bakteri. Oleh karena itu, GBFS-MicroGraph mampu menghasilkan mask yang lebih utuh dibandingkan Greedy sederhana, tetapi tetap lebih selektif dibandingkan BFS biasa.

C. Implikasi

Hasil penelitian ini menunjukkan bahwa strategi Greedy Best-First Search dapat dimanfaatkan sebagai pendekatan ringan untuk pseudo-anotasi citra patch sputum. Implikasinya, segmentasi objek bakteri tidak harus selalu bergantung pada model deep learning besar atau anotasi manual yang banyak. Dengan memanfaatkan skor warna domain-spesifik dan mekanisme pencarian berbasis prioritas, metode ini dapat menghasilkan mask dan graf yang cukup dekat dengan ground truth. Selain itu, hasil ini juga menunjukkan bahwa representasi image-to-graph berpotensi menjadi jembatan antara segmentasi citra dan analisis struktur objek. Mask yang diperoleh dari GBFS-MicroGraph dapat dikonversi menjadi node dan edge, sehingga dapat digunakan sebagai data awal untuk analisis lanjutan, seperti ekstraksi fitur morfologi, perhitungan konektivitas, atau pengujian menggunakan Graph Neural Network pada penelitian berikutnya.

D. Limitasi

Penelitian ini masih memiliki beberapa keterbatasan, yaitu :

1. Jumlah citra patch yang digunakan masih terbatas, sehingga hasil evaluasi belum sepenuhnya mewakili variasi citra sputum nyata. Pada kondisi nyata, citra mikroskopis dapat memiliki variasi pencahayaan, pewarnaan, ketebalan apusan, debris, dan artefak yang lebih kompleks.
2. Kualitas GBFS-MicroGraph masih bergantung pada Bacilli Color Score. Jika warna bakteri tidak cukup kontras terhadap latar belakang atau jika latar belakang memiliki warna yang mirip dengan bakteri, proses pemilihan seed dan region growing dapat mengalami penurunan kualitas.
3. Evaluasi masih dilakukan pada tingkat patch-level dan belum diuji pada citra bidang pandang penuh.
4. CCG masih digunakan sebagai metrik internal sehingga perlu dirumuskan dan divalidasi lebih kuat agar dapat digunakan secara lebih umum pada evaluasi graph-based annotation.

E. Future Work

Penelitian berikutnya dapat diarahkan pada beberapa pengembangan. Pertama, dataset perlu diperbesar dan dibuat lebih bervariasi agar metode dapat diuji pada kondisi mikroskopis yang lebih realistis. Kedua, Bacilli Color Score dapat dibuat lebih adaptif, misalnya dengan menambahkan normalisasi pencahayaan, koreksi stain, atau pembobotan warna yang disesuaikan berdasarkan distribusi warna lokal. Ketiga, GBFS-MicroGraph perlu diuji pada citra bidang pandang penuh, bukan hanya patch kecil, agar kemampuan metode dalam menangani banyak objek dan artefak dapat dievaluasi lebih menyeluruh. Keempat, metrik CCG perlu diformalkan lebih kuat dan dibandingkan dengan metrik graf lain. Terakhir, graf hasil pseudo-anotasi dapat diuji sebagai input untuk model lanjutan seperti Graph Neural Network guna melihat apakah representasi graf benar-benar bermanfaat untuk tugas klasifikasi atau deteksi otomatis bakteri.

V. PENUTUP

Makalah ini mengusulkan GBFS-MicroGraph sebagai metode pseudo-anotasi image-to-graph pada citra patch sputum. Metode ini menggabungkan Bacilli Color Score untuk membentuk kandidat piksel bakteri dan Greedy Best-First Search untuk menelusuri komponen foreground yang saling terhubung. Berdasarkan seluruh hasil pengujian, GBFS-MicroGraph menjadi metode terbaik dalam eksperimen ini dengan mIoU 0.889 dan CCG 0.16. Peningkatan ini terjadi karena Greedy Best-First Search mampu menyeimbangkan dua kebutuhan penting, yaitu memilih area dengan skor bacilli tinggi dan memperluas region secara terarah agar bentuk objek tetap utuh. Dengan demikian, metode proposed lebih sesuai untuk pseudo-anotasi image-to-graph pada citra hasil patch sputum dibandingkan Greedy, Brute Force, MicroGraph baseline, BFS-MicroGraph, dan SAM. Dengan demikian, GBFS-MicroGraph dapat menjadi alternatif ringan dan deterministik untuk pseudo-anotasi image-to-graph pada citra patch sputum.

LINK GITHUB

<https://github.com/Mirza114/GBFS-MicroGraph-Optimasi-Region-Bacilli-Color-Score-.git>

ACKNOWLEDGMENT

Penulis mengucapkan terima kasih kepada Dr. Ir. Rinaldi Munir, M.T. selaku dosen pengampu mata kuliah Strategi Algoritma atas arahan, materi, dan kesempatan yang diberikan dalam penyusunan makalah ini. Melalui tugas ini, penulis dapat memahami penerapan konsep Strategi Algoritma, khususnya metode search, dalam penyelesaian permasalahan berbasis citra digital.

REFERENCES

- [1] Chen, H., Gu, W., Zhang, H., Yang, Y., & Qian, L. (2024). Research on improved YOLOv8s model for detecting mycobacterium tuberculosis. *Heliyon*, 10(18), e38088. <https://doi.org/10.1016/j.heliyon.2024.e38088>

- [2] Sigit, R., Yuniarti, H., Karlita, T., Kusumawati, R., (2025). Real-Time Tuberculosis Bacteria Detection Using YOLOv8. *JOIV International Journal on Informatics Visualization*, 9(5), 1988–1994. <https://doi.org/10.62527/joiv.9.5.3147>
- [3] Greeshma, K., & Vishnukumar, S. (2025). Enhanced Tuberculosis Bacilli Detection using Attention-Residual U-Net and Ensemble Classification. *arXiv preprint arXiv:2501.03539*. <https://doi.org/10.48550/arXiv.2501.03539>
- [4] Israel, U., Marks, M., Dilip, R., Li, Q., Schwartz, M., Pradhan, E., Pao, E., Li, S., Pearson-Goulart, A., Perona, P., Gkioxari, G., Barnowski, R., Yue, Y., & Van Valen, D. (2023). A Foundation Model for Cell Segmentation. *arXiv preprint arXiv:2311.11004*. <https://doi.org/10.48550/arXiv.2311.11004>
- [5] Wang, H., Guo, S., Ye, J., Deng, Z., Cheng, J., Li, T., Chen, J., Su, Y., Huang, Z., Shen, Y., Fu, B., Zhang, S., He, J., & Qiao, Y. (2024). SAM-Med3D: Towards General-purpose Segmentation Models for Volumetric Medical Images. *arXiv preprint arXiv:2310.15161*. <https://doi.org/10.48550/arXiv.2310.15161>
- [6] Du, Y., Bai, F., Huang, T., & Zhao, B. (2024). SegVol: Universal and Interactive Volumetric Medical Image Segmentation. *Advances in Neural Information Processing Systems*, 37, 4310–4322. <https://doi.org/10.48550/arXiv.2311.13385>
- [7] He, Y., Guo, P., Tang, Y., Myronenko, A., Nath, V., Xu, Z., Yang, D., Zhao, C., Simon, B., Belue, M., Harmon, S., Turkbey, B., Xu, D., & Li, W. (2024). VISTA3D: A Unified Segmentation Foundation Model For 3D Medical Imaging. *arXiv preprint arXiv:2406.05285*. <https://doi.org/10.48550/arXiv.2406.05285>
- [8] Cheng, D., Qin, Z., Jiang, Z., Zhang, S., Lao, Q., & Li, K. (2023). SAM on Medical Images: A Comprehensive Study on Three Prompt Modes. *arXiv preprint arXiv:2305.00035*. <https://doi.org/10.48550/arXiv.2305.00035>
- [9] Zhu, H., Liu, X., Xue, R., Zhang, Z., Bai, Y., Wen, S., Xu, Y., Ergu, D., Cai, Y., & Zhao, Y. (2026). SSS: Semi-Supervised SAM-2 with efficient prompting for medical imaging segmentation. *Biomedical Signal Processing and Control*, 120(Part A), 110039. <https://doi.org/10.1016/j.bspc.2026.110039>
- [10] Costa, M. G. F. (2025). DDS1 - Dataset of patch images derived from sputum smear microscopy images for the development of bacillus detection methods. *Figshare*. <https://doi.org/10.6084/m9.figshare.27209667>

PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 1 Juni 2025



Mirza Tsabita Wafa'Ana
13524114

