



# Komparasi *Supervised* dan *Self-Supervised Learning* untuk Klasifikasi Sel Darah pada Skenario Keterbatasan Data Berlabel

Misella Mambu<sup>1\*</sup>, Oktavian Abraham Lantang<sup>2</sup>, Salaki Reynaldo Joshua<sup>3</sup>

<sup>1,2,3</sup>Universitas Sam Ratulangi, Manado, Indonesia

## Informasi Artikel

*Sejarah Artikel:*  
 Submit: 29 April 2026  
 Revisi: 13 Juni 2026  
 Diterima: 22 Juni 2026  
 Diterbitkan: 10 Juli 2026

## Kata Kunci

Klasifikasi Sel Darah, *Self-Supervised Learning*, SimCLR, BYOL, ResNet-50, Grad-CAM.

## Korespondensi

E-mail:  
[misellamambu026@students.unsrat.ac.id](mailto:misellamambu026@students.unsrat.ac.id)

## A B S T R A C T

The development of blood cell image classification models is often hindered by the scarcity of labeled data. This study evaluates the effectiveness of supervised baseline models, supervised fine-tuning, and self-supervised learning (SSL) based on SimCLR and BYOL using the ResNet-50 and DenseNet-121 architectures. Data-limited simulation was performed using 10% labeled data for the classification stage and 90% unlabeled data for SSL pre-training on 17,092 images from 8 morphological classes. The results show that SSL achieves competitive performance, with the highest accuracy on ResNet-50 at 95.31% (SimCLR) and 94.27% (BYOL), and on DenseNet-121 at 93.75% (SimCLR) and 89.58% (BYOL). The SSL approach also demonstrated robustness against overfitting, good robustness against class imbalance, and Grad-CAM visualizations that align with medical expert assessments on ResNet-50. In conclusion, SSL effectively optimizes unlabeled data to improve the performance of classification models in scenarios with limited data annotation.

## Abstrak

Pengembangan model klasifikasi citra sel darah sering terkendala oleh keterbatasan data berlabel. Penelitian ini mengevaluasi efektivitas *baseline supervised*, *supervised fine-tuning*, dan *self-supervised learning* (SSL) berbasis SimCLR serta BYOL menggunakan arsitektur ResNet-50 dan DenseNet-121. Simulasi data terbatas dilakukan dengan menggunakan 10% data berlabel untuk tahap klasifikasi dan 90% data tanpa label untuk *pre-training* SSL pada 17.092 citra dari 8 kelas morfologi. Hasil penelitian menunjukkan SSL menghasilkan performa kompetitif dengan akurasi tertinggi pada ResNet-50 sebesar 95,31% (SimCLR) dan 94,27% (BYOL), serta DenseNet-121 sebesar 93,75% (SimCLR) dan 89,58% (BYOL). Pendekatan SSL juga menunjukkan ketahanan yang lebih baik terhadap *overfitting*, ketahanan terhadap ketidakseimbangan kelas, serta visualisasi Grad-CAM yang sesuai dengan penilaian pakar medis pada ResNet-50. Kesimpulannya, SSL efektif mengoptimalkan data tanpa label untuk meningkatkan kinerja model klasifikasi pada skenario keterbatasan anotasi data.

This is an open access article under the CC-BY-SA license



## 1. Pendahuluan

Darah merupakan cairan vital yang memiliki peran sangat penting dalam sistem kekebalan tubuh, transportasi oksigen, nutrisi, dan sisa metabolisme. Keseimbangan dan komposisi sel darah pada seseorang dapat mencerminkan kondisi kesehatannya, sehingga analisis terhadap distribusi sel darah tepi menjadi sangat krusial dalam mendukung analisis morfologi sel darah perifer sebagai tahapan awal dalam proses evaluasi klinis[1]. Seiring dengan perkembangan kecerdasan buatan, *machine learning*, khususnya pendekatan *deep learning*, telah hadir sebagai solusi otomatisasi yang efektif dalam

analisis medis maupun sistem cerdas kesehatan tanpa perlu diprogram secara berulang [2][3][4]. Salah satu metode *machine learning* yang paling umum digunakan dalam mendeteksi dan mengklasifikasi citra adalah pendekatan *supervised learning*. Meskipun pendekatan *supervised learning* ini diketahui efektif, metode ini memiliki masalah utama yakni sangat bergantung pada ketersediaan data berlabel dalam jumlah yang besar. Dalam konteks medis, proses pelabelan (anotasi) citra medis bukanlah tugas yang sederhana. Anotasi citra sel darah secara manual mengharuskan dokter spesialis atau ahli hematologi untuk melakukan observasi mikroskopis satu per satu terhadap puluhan ribu sel. Proses ini sangat menyita waktu (*time-consuming*), rentan terhadap bias kelelahan visual (*human error*), dan membutuhkan biaya operasional yang sangat tinggi [5]. Konsekuensinya, ketersediaan data berlabel menjadi sangat langka dan terbatas. Di sisi lain, data medis yang tidak berlabel umumnya tersedia dalam jumlah yang jauh lebih melimpah.

Untuk mengatasi permasalahan keterbatasan data berlabel tersebut, penelitian ini menawarkan solusi dengan memanfaatkan *self-supervised learning* (SSL). SSL merupakan strategi yang memungkinkan model untuk mempelajari representasi fitur dari data tanpa label terlebih dahulu sebelum dilakukan tugas klasifikasi utama (*downstream task*) dengan sebagian kecil data berlabel [6]. Dalam implementasinya, penelitian ini mengusulkan pemanfaatan dua metode SSL, yaitu SimCLR (*Simple Framework for Contrastive Learning of Visual Representations*) dan BYOL (*Bootstrap Your Own Latent*), yang dipadukan dengan arsitektur *Convolutional Neural Network* (CNN) populer seperti ResNet-50 dan DenseNet-121. Jika SimCLR menggunakan pendekatan *contrastive learning* standar yang mengandalkan pasangan data positif dan negatif, BYOL menawarkan pendekatan inovatif yang mampu mempelajari representasi citra tanpa menggunakan data negatif (*negative pairs*) melalui interaksi antara jaringan online dan jaringan target yang saling belajar satu sama lain. Untuk meningkatkan stabilitas dan efisiensi pelatihan pada dataset yang terbatas, inisialisasi bobot pralatih (*transfer learning*) dari dataset ImageNet juga digunakan [7]. Selain memaksimalkan akurasi, transparansi keputusan model di bidang medis juga sangat penting, sehingga teknik visualisasi Grad-CAM (*Gradient-weighted Class Activation Mapping*) diterapkan untuk menunjukkan bagian citra sel darah mana yang menjadi fokus perhatian model dalam mengambil keputusan.

Beberapa penelitian terkait telah mengkaji pemanfaatan *deep learning* dalam analisis citra medis yang menjadi dasar dan acuan dalam penelitian ini. Keandalan arsitektur *Convolutional Neural Network* (CNN), khususnya ResNet-50 dan DenseNet-121, telah dilaporkan secara luas tangguh dan stabil dalam berbagai penelitian untuk klasifikasi citra medis dan deteksi penyakit [8][9][10]. Pemanfaatan pendekatan *Self-Supervised Learning* (SSL) dengan metode SimCLR menunjukkan keunggulan dalam mengekstraksi dan menjaga generalisasi fitur, meskipun pada kondisi ketersediaan data berlabel yang sangat terbatas secara ekstrem [11][12][13]. Selain SimCLR, pendekatan SSL inovatif seperti BYOL (*Bootstrap Your Own Latent*) juga diketahui mampu mencapai performa *state-of-the-art* dan sangat tangguh (*robust*) terhadap perubahan parameter tanpa memerlukan pasangan data negatif (*negative pairs*) [14]. Lebih lanjut, metode BYOL dilaporkan sangat efektif saat diterapkan pada tugas klasifikasi citra medis dalam skenario *semi-supervised* yang hanya memanfaatkan sebagian kecil (10%) data berlabel [15]. Selanjutnya, transparansi keputusan model melalui teknik Grad-CAM juga menjadi krusial untuk memberikan penjelasan visual yang dapat divalidasi presisinya oleh tenaga medis sebagai pendukung evaluasi morfologi klinis [16][17].

Berdasarkan tinjauan penelitian terkait tersebut, ditemukan sebuah kesenjangan penelitian (*research gap*) yang perlu dijawab. Mayoritas penelitian sebelumnya tentang klasifikasi sel darah masih sangat berfokus pada paradigma *supervised learning* standar yang mengasumsikan ketersediaan data berlabel yang melimpah. Di sisi lain, meskipun beberapa penelitian telah mengeksplorasi *self-supervised learning* (SSL) di ranah medis, belum ada penelitian terdahulu yang secara eksplisit membandingkannya secara langsung dan komprehensif antara dua paradigma SSL yang berbeda (seperti SimCLR yang mengandalkan *negative pairs* dan BYOL tanpa *negative pairs*) melawan

pendekatan *baseline supervised* dan *supervised fine-tuning* pada arsitektur CNN yang berbeda (seperti ResNet-50 dan DenseNet-121). Oleh karena itu, perbandingan komprehensif dalam skenario simulasi kelangkaan data ekstrem (hanya menggunakan 10% data berlabel) ini menjadi sebuah kontribusi yang penting. Eksperimen ini dirancang untuk menjawab secara eksplisit strategi pembelajaran mana yang paling optimal dan tangguh (*robust*) dalam memecahkan masalah kelangkaan anotasi data medis, sekaligus menjamin keandalan representasi fiturnya.

Oleh karena itu, tujuan dari penelitian ini adalah untuk menganalisis dan membandingkan efektivitas beberapa strategi pembelajaran, yaitu *baseline supervised*, *supervised fine-tuning*, serta *self-supervised learning* berbasis SimCLR dan BYOL, pada kondisi keterbatasan data berlabel dalam tugas klasifikasi citra sel darah. Untuk memastikan stabilitas dan efisiensi pelatihan, seluruh strategi tersebut diimplementasikan menggunakan arsitektur *Convolutional Neural Network* melalui pendekatan *transfer learning*, di mana model diinisialisasi terlebih dahulu menggunakan bobot pralatih dari ImageNet. Penelitian ini juga bertujuan mengevaluasi sejauh mana pendekatan SSL, yang memanfaatkan 90% data tidak berlabel pada tahap pralatih sebagai strategi adaptasi domain, mampu meningkatkan kualitas representasi fitur dibandingkan pendekatan *supervised* biasa. Melalui penelitian ini, diharapkan dapat ditemukan strategi pelatihan terbaik yang tidak hanya memiliki akurasi klasifikasi yang tinggi di tengah keterbatasan data, tetapi juga memiliki tingkat *overfitting* yang rendah serta mampu menghasilkan justifikasi medis yang transparan melalui visualisasi Grad-CAM.


## 2. Metode Penelitian

### 2.1. Tahapan Penelitian

Penelitian ini menggunakan metode CRISP-DM sebagai kerangka kerja dalam pengembangan dan evaluasi model klasifikasi citra sel darah. Metode ini terdiri dari enam tahapan utama, sebagaimana diilustrasikan pada Gambar 1. Tahap pertama adalah *business understanding*, yang berfokus pada perumusan strategi untuk mengatasi keterbatasan data berlabel melalui perbandingan metode *baseline supervised*, *supervised fine-tuning*, dan *self-supervised learning*. Tahap kedua, *data understanding*, dilakukan dengan menganalisis *Blood Cell Images Dataset* yang memiliki delapan kelas morfologi.

Tahap *data preparation* mencakup prapemrosesan citra, augmentasi data, serta pembagian dataset menjadi data tidak berlabel untuk *pre-training* dan data berlabel untuk klasifikasi. Selanjutnya, tahap modeling membangun model CNN, yaitu ResNet-50 dan DenseNet-121, dengan bobot pralatih ImageNet, serta melatihnya dalam empat skenario pendekatan.

Tahap *evaluation* dilakukan dengan mengukur kinerja model menggunakan metrik akurasi, presisi, recall, F1-score, confusion matrix, dan kurva performa, serta interpretabilitas melalui Grad-CAM yang divalidasi oleh dokter. Tahap terakhir adalah *deployment*, yaitu implementasi model dalam bentuk prototipe aplikasi web sebagai media demonstrasi interaktif.



Gambar 1. Kerangka kerja CRISP-DM [18]

## 2.2. Dataset dan Prapemrosesan Data

Data yang digunakan adalah *Blood Cell Images Dataset* yang terdiri dari 17.092 citra sel darah perifer normal beresolusi 360×363 piksel dan terbagi ke dalam 8 kelas morfologi yaitu *neutrophil*, *eosinophil*, *basophil*, *lymphocyte*, *monocyte*, *immature granulocyte*, *erythroblast*, dan *platelet*. Pembagian dataset dilakukan menjadi dua subset utama, yaitu 90% tanpa label untuk tahap *pre-training* SSL menggunakan SimCLR dan BYOL, serta 10% untuk tahap *downstream task* (yang selanjutnya dibagi menjadi 80% data latih, 10% validasi, dan 10% pengujian). Pembagian dataset ini dilakukan tanpa menerapkan teknik penyeimbangan kelas secara eksplisit. Kondisi ketidakseimbangan kelas (*class imbalance*) ini sengaja dipertahankan guna menganalisis ketangguhan dan pengaruhnya terhadap kinerja model pada masing-masing strategi pembelajaran. Rincian distribusi jumlah citra pada masing-masing kelas untuk setiap tahapan disajikan pada Tabel 1.

**Tabel 1.** Distribusi Pembagian Dataset per Kelas

| Kelas Sel Darah                                 | Data Latih<br>(80%) | Data Validasi<br>(10%) | Data Uji<br>(10%) | Total Data Berlabel<br>(10% dari Dataset) |
|-------------------------------------------------|---------------------|------------------------|-------------------|-------------------------------------------|
| <i>Neutrophil</i>                               | 272                 | 30                     | 37                | 339                                       |
| <i>Eosinophil</i>                               | 223                 | 31                     | 40                | 294                                       |
| <i>Immature Granulocyte</i>                     | 235                 | 30                     | 32                | 297                                       |
| <i>Platelet</i>                                 | 179                 | 23                     | 22                | 224                                       |
| <i>Monocyte</i>                                 | 127                 | 11                     | 23                | 161                                       |
| <i>Erythroblast</i>                             | 114                 | 7                      | 10                | 131                                       |
| <i>Lymphocyte</i>                               | 100                 | 14                     | 13                | 127                                       |
| <i>Basophil</i>                                 | 94                  | 14                     | 15                | 123                                       |
| Subtotal<br>(Tahap Klasifikasi)                 | 1.344               | 160                    | 192               | 1.696                                     |
| Total Data Tidak Berlabel<br>(Pre-Training SSL) | -                   | -                      | -                 | 15.396                                    |
| Total Keseluruhan Dataset                       | -                   | -                      | -                 | 17.092                                    |

Selanjutnya, seluruh citra diubah ukurannya menjadi 224×224 piksel. Teknik augmentasi diterapkan untuk meningkatkan variasi fitur dan meminimalkan risiko overfitting. Skenario augmentasi dirancang berbeda, di mana tahap SSL menggunakan transformasi yang lebih agresif untuk adaptasi fitur, sedangkan tahap *downstream task* menggunakan transformasi yang lebih ringan. Untuk memperjelas perbedaan tersebut, Tabel 2 menjabarkan rincian teknik augmentasi yang digunakan pada masing-masing tahap.

**Tabel 2.** Augmentasi Tahap *Pre-Training* dan Klasifikasi

| Augmentasi         | SSL <i>Pre-Training</i> | <i>Downstream Task</i> | <i>Supervised</i> |
|--------------------|-------------------------|------------------------|-------------------|
| <i>Resize</i>      | 256×256                 | -                      | -                 |
| <i>Crop</i>        | 224×224                 | -                      | -                 |
| <i>Flip V</i>      | <i>Vertical</i>         | -                      | -                 |
| <i>Flip H</i>      | <i>Horizontal</i>       | <i>Horizontal</i>      | <i>Horizontal</i> |
| <i>Translation</i> | -                       | 0.1                    | 0.1               |
| <i>Rotation</i>    | 0.3                     | 0.1                    | 0.1               |
| <i>Zoom</i>        | 0.2                     | 0.1                    | 0.1               |
| <i>Contrast</i>    | 0.5                     | -                      | -                 |
| <i>Brightness</i>  | 0.5                     | -                      | -                 |

## 2.3. Skenario Pemodelan dan Eksperimen

Penelitian ini menggunakan dua arsitektur *Convolutional Neural Network* (CNN) yang dikenal tangguh dalam mengekstraksi fitur kompleks pada citra mikroskopis medis [19], yaitu ResNet-50 dan DenseNet-121 yang sangat stabil saat menggunakan pendekatan *transfer learning* [20]. Kedua arsitektur ini diinisialisasi menggunakan bobot pralatih (*pre-trained weights*) dari ImageNet. Terdapat empat skenario eksperimen pemodelan yang dibandingkan:

### 1. Baseline Supervised

Lapisan ekstraksi fitur (*encoder*) dari model dibekukan (*freeze*) sepenuhnya. Pelatihan hanya dilakukan pada lapisan klasifikasi akhir menggunakan 10% data berlabel.

2. *Supervised Fine-Tuning*

Sebagian lapisan *encoder* dibuka (*unfreeze*) dan disesuaikan kembali bobotnya (*fine-tuning*) menggunakan 10% data berlabel, guna menyesuaikan representasi fitur dengan domain citra sel darah.

3. *Self-Supervised Learning* (SimCLR)

Proses dibagi menjadi dua tahap. Tahap pertama adalah *pre-training* menggunakan 90% data tidak berlabel untuk mempelajari representasi fitur visual melalui pendekatan *contrastive learning* dengan fungsi *Normalized Temperature-Scaled Cross Entropy* (NT-Xent) Loss. Tahap kedua (*downstream task*), *encoder* hasil *pre-training* dibekukan, dan lapisan klasifikasi dilatih menggunakan 10% data berlabel.

4. *Self-Supervised Learning* (BYOL)

Proses dibagi menjadi dua tahap. Tahap pertama adalah *pre-training* menggunakan 90% data tidak berlabel untuk mempelajari representasi fitur visual melalui interaksi antara jaringan online (*online network*) dan jaringan target (*target network*) tanpa memerlukan pasangan data negatif (*negative pairs*), dengan menggunakan fungsi *Mean Squared Error* (MSE) Loss. Tahap kedua (*downstream task*), *encoder* hasil *pre-training* dibekukan, dan lapisan klasifikasi dilatih menggunakan 10% data berlabel.

Pelatihan model dilakukan menggunakan platform komputasi berbasis *cloud* *Kaggle Notebook* yang dilengkapi dengan akselerator Multi-GPU (2 buah NVIDIA Tesla T4) untuk mengoptimalkan waktu komputasi. Untuk memastikan eksperimen dapat direplikasi (*reproducibility*), nilai random *seed* ditetapkan sebesar 123 pada saat pemuatan dataset. Eksperimen dalam penelitian ini dirancang untuk dijalankan satu kali (*single run*) guna mengoptimalkan efisiensi komputasi *cloud*. Sebagai kompensasi dari ketiadaan pengulangan eksperimen, penetapan random *seed* statis diterapkan untuk mengontrol variabilitas inisialisasi, memastikan bahwa tahapan pelatihan bersifat deterministik dan hasil akhirnya dapat direplikasi. Seluruh model dilatih dengan ukuran *batch* 32, menggunakan algoritma optimasi Adam. Proses pelatihan mengimplementasikan mekanisme *early stopping* dengan batas maksimum *epoch* 25 untuk klasifikasi dan 30 untuk *pre-training*, yang bertujuan untuk menghentikan pelatihan secara otomatis saat tidak ada lagi peningkatan performa guna mencegah terjadinya *overfitting*. *Learning rate* ditetapkan sebesar 1e-4 untuk skenario *baseline* dan SSL, serta diturunkan menjadi 1e-5 pada saat transisi ke fase *unfreeze* di skenario *fine-tuning*. Fungsi kerugian (*loss function*) yang digunakan adalah *Normalized Temperature-Scaled Cross Entropy* (NT-Xent) untuk SimCLR, *Mean Squared Error* (MSE) untuk BYOL, dan *Cross-Entropy* untuk tahap klasifikasi. Tabel 3 berikut merangkum perbedaan perlakuan antara metode *Baseline*, *Fine-Tuning*, dan *Self-Supervised Learning* (SSL).

Tabel 3. Rincian Konfigurasi

| Aspek              | <i>Baseline</i> SL   | <i>Fine-Tuning</i> SL   | SSL                                      |
|--------------------|----------------------|-------------------------|------------------------------------------|
| <i>Pretraining</i> | ImageNet             | ImageNet                | ImageNet, SimCLR, BYOL                   |
| <i>Encoder</i>     | <i>Freeze</i>        | <i>Freeze, Unfreeze</i> | <i>Trainable</i> saat <i>pretraining</i> |
| Tahap Training     | 1 tahap              | 2 tahap                 | 2 tahap                                  |
| Tujuan             | Klasifikasi langsung | Adaptasi berbasis label | Adaptasi tanpa label                     |

### 3. Hasil dan Pembahasan

Bagian ini menyajikan hasil eksperimen dan pembahasan mengenai klasifikasi citra sel darah pada skenario simulasi keterbatasan data berlabel. Evaluasi dilakukan terhadap dua arsitektur *Convolutional Neural Network* (CNN), yaitu ResNet-50 dan DenseNet-121. Analisis difokuskan pada perbandingan efektivitas empat strategi pembelajaran, yakni *baseline supervised*, *supervised fine-tuning*, dan *self-supervised learning* (SSL) berbasis metode SimCLR dan BYOL. Pembahasan pada bagian ini akan dibagi ke dalam tiga fokus utama, yang meliputi, evaluasi kinerja klasifikasi dan stabilitas pelatihan model,

analisis ketangguhan model dalam menangani ketidakseimbangan kelas (*class imbalance*), serta evaluasi terhadap tingkat interpretabilitas keputusan model melalui visualisasi Grad-CAM yang divalidasi oleh pakar medis. Pemaparan hasil juga dilengkapi dengan tabel performa dan grafik kurva untuk memperjelas perbandingan antar metode.

### 3.1. Analisis Kinerja Klasifikasi dan Stabilitas Model

Pengujian kinerja klasifikasi dilakukan untuk mengevaluasi kemampuan arsitektur ResNet-50 dan DenseNet-121 pada kondisi ketersediaan data berlabel yang sangat terbatas, yaitu hanya 10%. Berdasarkan hasil pengujian, terlihat adanya perbedaan performa yang jelas di antara keempat strategi pembelajaran yang diterapkan. Ringkasan perbandingan hasil akurasi pengujian dari masing-masing model dapat dilihat pada Tabel 4.



**Tabel 4.** Perbandingan Hasil Akurasi Pengujian

| Arsitektur   | <i>Baseline Supervised</i> | <i>Supervised Fine-Tuning</i> | <i>Self-Supervised (SimCLR)</i> | <i>Self-Supervised (BYOL)</i> |
|--------------|----------------------------|-------------------------------|---------------------------------|-------------------------------|
| ResNet-50    | 79.69%                     | 93.23%                        | 95.31%                          | 94,27%                        |
| DenseNet-121 | 73.44%                     | 93.75%                        | 93.75%                          | 89,58%                        |



Berdasarkan Tabel 4, pendekatan *baseline supervised* menunjukkan performa yang paling rendah, di mana ResNet-50 hanya mencapai akurasi sebesar 79,69% dan DenseNet-121 sebesar 73,44%. Ketika model diberikan fleksibilitas untuk menyesuaikan bobotnya secara spesifik terhadap domain citra sel darah melalui *supervised fine-tuning*, kedua arsitektur mengalami peningkatan akurasi yang sangat tajam, yakni mencapai 93,23% pada ResNet-50 dan 93,75% pada DenseNet-121. Namun, hasil paling optimal dicapai melalui pendekatan *self-supervised learning* (SSL). Metode berbasis SimCLR menghasilkan akurasi tertinggi sebesar 95,31% pada ResNet-50, serta akurasi yang setara dengan *fine-tuning* sebesar 93,75% pada arsitektur DenseNet-121, sementara metode berbasis BYOL turut memberikan performa yang kompetitif dengan capaian akurasi sebesar 94,27% pada ResNet-50 dan 89,58% pada DenseNet-121.

Keunggulan performa ResNet-50 dibandingkan DenseNet-121 pada skenario SSL dipengaruhi oleh perbedaan kapasitas arsitektur. ResNet-50 yang memiliki jumlah parameter jauh lebih besar mampu menyerap representasi fitur yang lebih kompleks selama tahap *pre-training* tanpa label. Sebaliknya, DenseNet-121 yang mengandalkan penggabungan fitur padat (*dense connections*) cenderung lebih sensitif terhadap pendekatan algoritma SSL. Ketiadaan data negatif (*negative pairs*) pada metode BYOL membuat arsitektur DenseNet-121 sedikit lebih kesulitan merumuskan batas pemisah antar kelas sel darah sejelas metode SimCLR, sehingga peningkatan performanya menjadi lebih terbatas.



Selanjutnya dilakukan analisis terhadap stabilitas model selama proses pelatihan, metode *baseline supervised* menunjukkan kemampuan belajar yang terbatas akibat keterbatasan representasi fitur umum dari ImageNet karena seluruh lapisan dibekukan. Sebaliknya, metode *supervised fine-tuning* sangat rentan *overfitting* karena kapasitas model yang besar cenderung menghafal data latih yang terbatas. Hal ini ditunjukkan oleh gap akurasi pelatihan dan validasi yang besar, ResNet-50 mencapai akurasi pelatihan 99,27% dan validasi 90,00% (gap 9,27%), sedangkan DenseNet-121 menghasilkan gap sebesar 7,47%. Sebaliknya, pendekatan *self-supervised learning* (SSL), baik menggunakan metode SimCLR maupun BYOL, menunjukkan pola pelatihan yang paling stabil dan berhasil mencapai kondisi yang ideal (*good fit*). Sebagai bukti visual untuk membandingkan tingkat stabilitas tersebut, Gambar 2 menyajikan komparasi langsung antara metode *Supervised Fine-Tuning* yang mewakili kondisi rentan *overfitting* berhadapan dengan metode *Self-Supervised* (BYOL) yang mewakili kondisi paling stabil (*good fit*).




(a)



(b)



(c)



**Gambar 2.** Menampilkan stabilitas pelatihan (a) *Supervised Fine-Tuning* dan (b) *Self-Supervised (BYOL)* pada arsitektur ResNet-50; serta (c) *Supervised Fine-Tuning* dan (d) *Self-Supervised (BYOL)* pada arsitektur DenseNet-121.

Berdasarkan visualisasi pada Gambar 2, dapat dilihat bahwa pada metode SSL (BYOL), pergerakan kurva pelatihan dan validasi saling berhimpitan secara konsisten sepanjang proses pelatihan, berbanding terbalik dengan metode *fine-tuning* yang memiliki jarak kurva melebar. Selisih akurasi (gap) pada metode SimCLR berhasil ditekan dengan baik menjadi hanya 3,08% pada ResNet-50 dan 2,72% pada DenseNet-121. Lebih lanjut, ketahanan yang tak kalah optimal juga ditunjukkan oleh metode BYOL, di mana gap akurasi mampu ditekan hingga 2,31% pada ResNet-50 dan sama sekali tidak menunjukkan indikasi *overfitting* pada arsitektur DenseNet-121 (gap 1,44%). Kestabilan tingkat tinggi pada kedua arsitektur ini mengonfirmasi bahwa adaptasi representasi domain menggunakan 90% data tidak berlabel pada tahap *pre-training* membuat model jauh lebih siap dalam melakukan generalisasi terhadap data baru tanpa mengalami *overfitting* yang berlebihan. Dengan demikian, SSL menawarkan keseimbangan yang optimal antara pencapaian akurasi klasifikasi yang tinggi dan stabilitas generalisasi model. Rincian perbandingan metrik akurasi pelatihan dan validasi beserta selisih (gap) untuk masing-masing model disajikan pada Tabel 5.

**Tabel 5.** Perbandingan Gap Akurasi Training dan Validation

| Arsitektur   | Metode Pembelajaran | Akurasi Training | Akurasi Validation | Selisih (Gap) |
|--------------|---------------------|------------------|--------------------|---------------|
| ResNet-50    | Baseline (SL)       | 86,83%           | 80,00%             | 6,83%         |
|              | Fine-Tuning (SL)    | 99,27%           | 90,00%             | 9,27%         |
|              | SimCLR (SSL)        | 96,83%           | 93,75%             | 3,08%         |
|              | BYOL (SSL)          | 95,43%           | 93,12%             | 2,31%         |
| DenseNet-121 | Baseline (SL)       | 73,15%           | 63,75%             | 9,40%         |
|              | Fine-Tuning (SL)    | 94,34%           | 86,87%             | 7,47%         |
|              | SimCLR (SSL)        | 93,97%           | 91,25%             | 2,72%         |
|              | BYOL (SSL)          | 91,68%           | 93,12%             | 1,44%         |

### 3.2. Evaluasi Penanganan Ketidakseimbangan Data (*Class Imbalance*)

Dalam pengujian terhadap 192 data uji, terdapat ketidakseimbangan distribusi jumlah sampel antar kelas (*class imbalance*). Beberapa kelas seperti *erythroblast* (10 data), *lymphocyte* (13 data), dan *basophil* (15 data) merupakan kelas minoritas, sedangkan *eosinophil* (40 data) dan *neutrophil* (37 data) adalah kelas mayoritas. Karena penelitian ini tidak menerapkan teknik penyeimbangan data secara eksplisit, evaluasi terhadap bias model menjadi sangat penting. Analisis ini dilakukan dengan membandingkan nilai *Macro F1-Score* dan *Weighted F1-Score* sebagaimana disajikan pada Tabel 6.

**Tabel 6.** Perbandingan Nilai *Macro F1-Score* dan *Weighted F1-Score* pada Setiap Arsitektur dan Strategi Pembelajaran

| Arsitektur   | Metode                  | <i>Macro F1</i> | <i>Weighted F1</i> | Selisih |
|--------------|-------------------------|-----------------|--------------------|---------|
| ResNet-50    | <i>Baseline</i> (SL)    | 0.77            | 0.80               | 0.03    |
|              | <i>Fine-Tuning</i> (SL) | 0.93            | 0.93               | 0.00    |
|              | SimCLR (SSL)            | 0.94            | 0.95               | 0.01    |
|              | BYOL (SSL)              | 0.92            | 0.94               | 0.02    |
| DenseNet-121 | <i>Baseline</i> (SL)    | 0.72            | 0.73               | 0.01    |
|              | <i>Fine-Tuning</i> (SL) | 0.94            | 0.94               | 0.00    |
|              | SimCLR (SSL)            | 0.93            | 0.94               | 0.01    |
|              | BYOL (SSL)              | 0.88            | 0.90               | 0.02    |

Berdasarkan Tabel 6, pendekatan *baseline supervised* menunjukkan kerentanan tertinggi terhadap ketidakseimbangan kelas. Pada ResNet-50, terdapat selisih sebesar 0,03 antara *Macro F1* dan *Weighted F1*, yang menunjukkan adanya bias kuat di mana model cenderung memihak pada kelas mayoritas dan kesulitan mengenali kelas minoritas. Meskipun selisih pada DenseNet-121 lebih kecil (0,01), performa agregatnya sangat rendah (0,72), mengindikasikan bahwa fitur pralatih umum dari ImageNet tidak cukup representatif ketika seluruh lapisan *encoder* dibekukan. Sebaliknya, pendekatan *supervised fine-tuning* mampu mengatasi ketimpangan ini. Kedua arsitektur menghasilkan nilai *Macro F1* dan *Weighted F1* yang identik (selisih 0,00), mengindikasikan bahwa penyesuaian bobot pada sebagian lapisan *encoder* membuat model tidak lagi bias terhadap kelas mayoritas.

Sementara itu, pendekatan *self-supervised learning* (SSL) juga menunjukkan performa yang tangguh dan stabil. meskipun terdapat perbedaan karakteristik ketahanan antara metode SimCLR dan BYOL. Pada metode SimCLR, terdapat selisih kecil (0,01) akibat sedikit penurunan performa pada kelas dengan data sangat terbatas seperti *erythroblast*, namun secara keseluruhan nilai *Macro F1* yang dihasilkan tetap sangat tinggi (0,94 untuk ResNet-50 dan 0,93 untuk DenseNet-121). Di sisi lain, metode BYOL menunjukkan selisih metrik yang sedikit lebih lebar yaitu sebesar 0,02 pada kedua arsitektur. Secara spesifik, ResNet-50 dengan BYOL mencatatkan *Macro F1* sebesar 0,92 dan *Weighted F1* 0,94, sedangkan DenseNet-121 memperoleh *Macro F1* 0,88 dan *Weighted F1* 0,90. Selisih yang sedikit lebih besar pada BYOL ini mengindikasikan adanya kecenderungan bias yang lebih kentara terhadap kelas mayoritas dibandingkan SimCLR. Hal ini diduga karena algoritma BYOL yang tidak membandingkan pasangan data negatif (*negative pairs*) membuatnya sedikit lebih kesulitan membedakan batas kelas minoritas secara tegas jika dibandingkan dengan SimCLR. Meskipun demikian, metode SSL ini menegaskan bahwa adaptasi domain menggunakan data tidak berlabel mampu membangun representasi fitur yang kaya dan mendalam, sehingga mengompensasi keterbatasan data anotasi pada kelas minoritas dengan jauh lebih baik.


Untuk mengevaluasi performa klasifikasi secara lebih spesifik akibat dampak dari ketidakseimbangan jumlah data tersebut, rincian nilai *precision*, *recall*, dan *F1-score* pada masing-masing kelas sel darah untuk seluruh strategi pembelajaran pada arsitektur ResNet-50 disajikan pada Tabel 7.

**Tabel 7.** Perbandingan Metrik per Kelas pada Arsitektur ResNet-50

| Metode                        | Kelas               | <i>Precision</i> | <i>Recall</i> | <i>F1-Score</i> |
|-------------------------------|---------------------|------------------|---------------|-----------------|
| <i>Baseline Supervised</i>    | <i>Basophil</i>     | 0.50             | 0.67          | 0.57            |
|                               | <i>Eosinophil</i>   | 0.83             | 0.88          | 0.85            |
|                               | <i>Erythroblast</i> | 1.00             | 0.50          | 0.67            |
|                               | <i>Ig</i>           | 0.73             | 0.84          | 0.78            |
|                               | <i>Lymphocyte</i>   | 1.00             | 0.69          | 0.82            |
|                               | <i>Monocyte</i>     | 0.81             | 0.57          | 0.67            |
|                               | <i>Neutrophil</i>   | 0.80             | 0.86          | 0.83            |
|                               | <i>Platelet</i>     | 0.96             | 1.00          | 0.98            |
| <i>Supervised Fine-Tuning</i> | <i>Basophil</i>     | 0.87             | 0.87          | 0.87            |
|                               | <i>Eosinophil</i>   | 0.93             | 0.97          | 0.95            |
|                               | <i>Erythroblast</i> | 1.00             | 0.80          | 0.89            |

|                             |              |      |      |      |
|-----------------------------|--------------|------|------|------|
| Self-Supervised<br>(SimCLR) | Ig           | 0.88 | 0.88 | 0.88 |
|                             | Lymphocyte   | 1.00 | 1.00 | 1.00 |
|                             | Monocyte     | 0.88 | 0.91 | 0.89 |
|                             | Neutrophil   | 0.97 | 0.95 | 0.96 |
|                             | Platelet     | 1.00 | 1.00 | 1.00 |
|                             | Basophil     | 1.00 | 0.87 | 0.93 |
|                             | Eosinophil   | 1.00 | 1.00 | 1.00 |
|                             | Erythroblast | 1.00 | 0.70 | 0.82 |
|                             | Ig           | 0.86 | 0.97 | 0.91 |
|                             | Lymphocyte   | 1.00 | 0.92 | 0.96 |
| Self-Supervised<br>(BYOL)   | Monocyte     | 0.85 | 0.96 | 0.90 |
|                             | Neutrophil   | 1.00 | 0.97 | 0.99 |
|                             | Platelet     | 1.00 | 1.00 | 1.00 |
|                             | Basophil     | 0.88 | 1.00 | 0.94 |
|                             | Eosinophil   | 1.00 | 1.00 | 1.00 |
|                             | Erythroblast | 1.00 | 0.90 | 0.95 |
|                             | Ig           | 0.91 | 0.97 | 0.94 |
|                             | Lymphocyte   | 1.00 | 0.54 | 0.70 |
|                             | Monocyte     | 0.78 | 0.91 | 0.84 |
|                             | Neutrophil   | 1.00 | 0.97 | 0.99 |
|                             | Platelet     | 1.00 | 1.00 | 1.00 |

Untuk memberikan gambaran visual yang lebih jelas mengenai pola misklasifikasi akibat ketidakseimbangan data, Gambar 3 menampilkan perbandingan *confusion matrix*. Visualisasi ini difokuskan pada arsitektur dengan performa paling optimal (ResNet-50) guna membandingkan secara komprehensif distribusi prediksi dari keempat strategi pembelajaran yang diuji, yaitu *baseline supervised*, *supervised fine-tuning*, serta *self-supervised learning* (SimCLR dan BYOL).



**Gambar 3.** Menampilkan *Confusion Matrix* pada arsitektur ResNet-50: (a) *Baseline Supervised*, (b) *Supervised Fine-Tuning*, (c) *Self-Supervised (SimCLR)*, dan (d) *Self-Supervised (BYOL)*.

Tabel 7 dan Gambar 3 memberikan gambaran komprehensif mengenai distribusi prediksi dan letak misklasifikasi model. Pada metode *baseline supervised*, model menunjukkan kerentanan yang tinggi terhadap ketidakseimbangan data. Hal ini terlihat dari rendahnya metrik *recall* pada kelas minoritas (seperti *erythroblast* dan *monocyte*) serta tebakan yang menyebar secara tidak terarah pada *confusion matrix* (Gambar 3a). Di sisi lain, metode *supervised fine-tuning* (Gambar 3b) menunjukkan perbaikan yang substansial dengan prediksi yang terkonsentrasi pada diagonal utama, meskipun pencapaian ini diiringi oleh indikasi *overfitting* pada fase pelatihan sebelumnya.

Sementara itu, pendekatan *self-supervised learning* berhasil menawarkan solusi yang optimal dan stabil. Metode SimCLR (Gambar 3c) memperlihatkan distribusi prediksi yang sangat rapi dan berhasil meminimalisir kesalahan klasifikasi secara tajam, yang terlihat dari nilai presisi yang mencapai angka 1,00 pada sebagian besar kelas minoritas. Pendekatan BYOL (Gambar 3d) juga memberikan tingkat presisi yang tinggi pada sebagian besar kelas, namun pada kelas dengan kemiripan visual tertentu, algoritma ini mengalami sedikit tantangan. Ketiadaan data negatif pada BYOL menyebabkan sedikit penurunan *recall* pada kelas *lymphocyte* dan menciptakan pola kebingungan yang spesifik antara *lymphocyte* dan *monocyte*. Secara keseluruhan, hasil ini menegaskan bahwa strategi SSL khususnya SimCLR memiliki kemampuan representasi fitur paling merata dan *robust* tanpa memihak pada kelas mayoritas.

### 3.3. Analisis Interpretabilitas Model Berdasarkan Grad-CAM

Selain evaluasi performa kuantitatif, penelitian ini juga melakukan evaluasi terhadap interpretabilitas model menggunakan teknik visualisasi Grad-CAM (*Gradient-weighted Class Activation Mapping*). Visualisasi ini dievaluasi oleh seorang responden ahli, yaitu dokter spesialis patologi klinik. Penilaian dilakukan menggunakan kuesioner berbasis skala *Likert* 1 hingga 5 (dimana nilai 1 menunjukkan sangat tidak sesuai, dan nilai 5 menunjukkan sangat sesuai). Parameter penilaian mencakup tiga aspek utama, yaitu (1) tampilan visual, (2) fungsionalitas model, dan (3) keterkaitan area yang disorot dengan pengetahuan medis pada setiap kelas sel darah. Nilai dari responden kemudian diolah dengan menghitung rata-rata skor pada setiap aspek. Ringkasan hasil rata-rata evaluasi interpretabilitas dari kedua arsitektur disajikan pada Tabel 8.


**Tabel 8.** Perbandingan Rata-Rata Evaluasi Interpretabilitas Model

| Arsitektur   | <i>Baseline Supervised</i> | <i>Supervised Fine-Tuning</i> | <i>Self-Supervised (SimCLR)</i> | <i>Self-Supervised (BYOL)</i> |
|--------------|----------------------------|-------------------------------|---------------------------------|-------------------------------|
| ResNet-50    | 3,17                       | 3,75                          | 3,63                            | 3,25                          |
| DenseNet-121 | 3,25                       | 3,5                           | 3                               | 2,63                          |


Berdasarkan Tabel 8, arsitektur ResNet-50 secara umum menunjukkan keunggulan dengan memperoleh skor evaluasi pakar yang lebih tinggi terkait kesesuaian medis dibandingkan DenseNet-121, terutama pada metode *fine-tuning* dan *self-supervised learning* (SimCLR). Secara keseluruhan, metode *supervised fine-tuning* memperoleh skor tertinggi pada kedua arsitektur (3,75 untuk ResNet-50 dan 3,50 untuk DenseNet-121). Hal ini mengindikasikan bahwa proses penyesuaian bobot (*unfreeze*) memungkinkan model menyoroti area fitur morfologi sel darah dengan sangat jelas. Namun, tingginya kualitas visual pada *fine-tuning* ini diiringi dengan indikasi *overfitting* pada fase pelatihannya. Temuan ini menegaskan bahwa visualisasi *heatmap* yang baik secara kasat mata tidak selalu menjamin kemampuan generalisasi model yang optimal terhadap data baru. Di sisi lain, metode *baseline supervised* menunjukkan kualitas visualisasi yang cukup moderat pada kedua arsitektur. Hal ini terjadi karena seluruh lapisan encoder dibekukan dan hanya mengandalkan fitur bawaan ImageNet, sehingga fokus perhatian model terkadang belum sepenuhnya presisi pada objek sel darah utama dibandingkan metode yang mengalami adaptasi fitur.

Sementara itu, metode *self-supervised learning* (SSL) menawarkan hasil yang menarik. Pada arsitektur DenseNet-121, skor visual SSL turun menjadi 3,00 untuk metode SimCLR dan anjlok ke angka


2,63 untuk metode BYOL, meskipun model ini memiliki stabilitas generalisasi (*good fit*) yang sangat baik. Penurunan kualitas visual pada metode BYOL ini diakibatkan oleh ketiadaan pasangan data negatif (*negative pairs*), yang membuat arsitektur dengan koneksi padat seperti DenseNet-121 kesulitan merumuskan fitur pembeda yang jelas untuk diinterpretasikan secara medis. Namun, pada arsitektur ResNet-50, metode SSL berhasil mencapai skor interpretabilitas yang tinggi, yakni 3,63 untuk SimCLR (hampir mendekati skor *fine-tuning*) dan 3,25 untuk BYOL. Hal ini menunjukkan bahwa kapasitas parameter ResNet-50 yang lebih besar mampu memanfaatkan 90% data tidak berlabel pada tahap *pre-training* secara lebih efektif untuk memperbaiki fokus visual pada kelas-kelas yang sulit dikenali, seperti *platelet* dan *erythroblast*. Dengan demikian, penerapan SSL berbasis SimCLR pada arsitektur ResNet-50 mengindikasikan keseimbangan yang paling optimal antara pencapaian akurasi klasifikasi tertinggi, ketahanan terhadap *overfitting*, dan transparansi justifikasi medis yang dapat diandalkan oleh dokter.



(a)



(b)



**Gambar 4.** Menampilkan Hasil Visualisasi Grad-CAM untuk Metode (a) *Baseline Supervised*, (b) *Supervised Fine-Tuning*, (c) *Self-Supervised (SimCLR)*, dan (d) *Self-Supervised (BYOL)* pada arsitektur ResNet-50

#### 4. Kesimpulan

Penelitian ini membandingkan efektivitas *baseline supervised*, *supervised fine-tuning*, dan *self-supervised learning (SSL)* berbasis SimCLR dan BYOL pada klasifikasi citra sel darah dengan kondisi keterbatasan data berlabel (10%). Hasil pengujian mengindikasikan bahwa pendekatan SSL efektif dalam meningkatkan performa klasifikasi. Akurasi tertinggi dicapai oleh arsitektur ResNet-50 menggunakan metode SimCLR (95,31%) dan BYOL (94,27%), yang mengungguli pendekatan *fine-tuning* dan *baseline*. Pemanfaatan data tidak berlabel pada tahap *pre-training* SSL mampu membangun representasi fitur yang konsisten, meminimalkan indikasi *overfitting* (dengan ketahanan terbaik pada metode BYOL), dan mengurangi bias terhadap kelas mayoritas. Terkait aspek interpretabilitas, arsitektur ResNet-50 menghasilkan visualisasi Grad-CAM yang lebih sesuai dengan interpretasi pakar medis dibandingkan DenseNet-121, di mana metode SSL (terutama SimCLR) menawarkan keseimbangan paling optimal antara stabilitas pelatihan, performa klasifikasi, dan kualitas transparansi justifikasi medis.

Meskipun demikian, penelitian ini memiliki keterbatasan karena pengujian hanya dilakukan pada dataset citra sel darah perifer normal. Oleh karena itu, klasifikasi morfologi sel darah dalam studi ini belum dapat secara langsung merepresentasikan diagnosis suatu penyakit klinis. Untuk penelitian selanjutnya, disarankan melakukan pengujian pada dataset klinis yang mencakup sel darah abnormal (seperti malaria atau leukemia), menerapkan teknik penyeimbangan data secara eksplisit (*data*

*balancing*) untuk menangani kelas minoritas, serta memvalidasi model menggunakan data dari instansi atau rumah sakit yang berbeda guna menguji kemampuan generalisasi model pada data eksternal.

## Daftar Pustaka

- [1] S. B. Boly and M. Akbar, "Segmentasi Citra Sel Darah Menggunakan Convolutional Neural Network," vol. 6, no. 2, pp. 390–398, 2024, [Online]. Available: <https://www.kaggle.com/jeetblahiri>
- [2] E. Retnoningsih and R. Pramudita, "Mengenal Machine Learning Dengan Teknik Supervised dan Unsupervised Learning Menggunakan Python," *BINA INSANI ICT JOURNAL*, vol. 7, no. 2, pp. 156–165, 2020, [Online]. Available: <https://www.python.org/>
- [3] Ade Ryan Pratama, Farmin Wabula, Haekal Ilmandry, Maria Laura Isabela, Mugi Raharjo, and Ronald Sianipar, "Literature Review The Impact of Machine Learning in Modern Industries," *Nian Tana Sikka : Jurnal ilmiah Mahasiswa*, vol. 3, no. 1, pp. 177–182, Jan. 2025, doi: 10.59603/niantanasikka.v3i1.680.
- [4] S. R. Joshua, S. Shin, J. H. Lee, and S. K. Kim, "Health to Eat: A Smart Plate with Food Recognition, Classification, and Weight Measurement for Type-2 Diabetic Mellitus Patients' Nutrition Control," *Sensors*, vol. 23, no. 3, Feb. 2023, doi: 10.3390/s23031656.
- [5] A. Chowdhury, J. Rosenthal, J. Waring, and R. Umeton, "Applying self-supervised learning to medicine: Review of the state of the art and medical implementations," Sep. 01, 2021, *MDPI*. doi: 10.3390/informatics8030059.
- [6] N. Jia *et al.*, "A fine-grained image classification algorithm based on self-supervised learning and multi-feature fusion of blood cells," *Sci. Rep.*, vol. 14, no. 1, p. 22964, Dec. 2024, doi: 10.1038/s41598-024-74753-2.
- [7] I. Putu Agus, K. Hidjah, N. Sulistianingsih, and G. Hendro, "Implementasi Arsitektur Deep Convolutional Neural Network (CNN) dengan Transfer Learning untuk Klasifikasi Penyakit Kulit," *JTIM 2025*, vol. 7, no. 3, pp. 461–477, 2025, doi: 10.35746/jtim.v7i3.734.
- [8] Y. I. Salsabila, H. Mustofa, and M. A. Ulinuha, "KLASIFIKASI CITRA TUMOR OTAK MENGGUNAKAN TEKNIK TRANSFER LEARNING PADA ARSITEKTUR RESNET-50," *Journal of Information System, Informatics and Computing*, vol. 9, no. 1, p. 128, Jun. 2025, doi: 10.52362/jisicom.v9i1.1925.
- [9] M. Putra *et al.*, "Image Analysis of Skin Diseases Using DenseNet-121 Architecture," *Journal Medical Informatics Technology*, pp. 73–78, Jun. 2025, doi: 10.37034/medinftech.v3i2.99.
- [10] O. Soedradjat, R. Magdalena, and N. Pratiwi, "DETEKSI GANGGUAN PARU-PARU BERBASIS CITRA X-RAY MENGGUNAKAN DEEP LEARNING," 2022.
- [11] S. C. Huang, A. Pareek, M. Jensen, M. P. Lungren, S. Yeung, and A. S. Chaudhari, "Self-supervised learning for medical image classification: a systematic review and implementation guidelines," Dec. 01, 2023, *Nature Research*. doi: 10.1038/s41746-023-00811-0.
- [12] C. Li, F. Li, L. Zhang, A. Yang, Z. Hu, and M. He, "Intrusion Detection for Industrial Control Systems Based on Improved Contrastive Learning SimCLR," *Applied Sciences (Switzerland)*, vol. 13, no. 16, Aug. 2023, doi: 10.3390/app13169227.
- [13] C. Agastya, S. Ghebremusse, I. Anderson, C. Reed, H. Vahabi, and A. Todeschini, "Self-supervised Contrastive Learning for Irrigation Detection in Satellite Imagery," Aug. 2021, [Online]. Available: <http://arxiv.org/abs/2108.05484>
- [14] J.-B. Grill *et al.*, "Bootstrap your own latent: A new approach to self-supervised Learning," Sep. 2020, [Online]. Available: <http://arxiv.org/abs/2006.07733>
- [15] D. Zeng, Y. Wu, X. Hu, X. Xu, J. Hu, and Y. Shi, "Additional Positive Enables Better Representation Learning for Medical Images," May 2023, [Online]. Available: <http://arxiv.org/abs/2306.00112>
- [16] H. Moujahid *et al.*, "Combining cnn and grad-cam for covid-19 disease prediction and visual explanation," *Intelligent Automation and Soft Computing*, vol. 32, no. 2, pp. 723–745, 2022, doi: 10.32604/iasc.2022.022179.
- [17] A. Verdaus Saputra and W. Setiawan, "KLASIFIKASI CITRA HISTOPATOLOGI KANKER PARU-PARU MENGGUNAKAN RESNET50 DENGAN INTERPRETASI GRAD-CAM," 2026.
- [18] M. A. Hasanah, S. Soim, and A. S. Handayani, "Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir," 2021. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [19] O. Lantang, G. Terdik, A. Hajdu, and A. Tiba, "Comparison of single and ensemble-based convolutional neural networks for cancerous image classification," *Annales Mathematicae et Informaticae*, vol. 54, pp. 45–56, 2021, doi: 10.33039/ami.2021.03.013.

- [20] S. R. Joshua, K. Y. Palilingan, S. P. Lengkong, and S. Park, "Deep Learning-Driven Solar Fault Detection in Solar-Hydrogen AIoT Systems: Implementing CNN VGG16, ResNet-50, DenseNet121, and EfficientNetB0 in a University-Based Framework," *Hydrogen*, vol. 7, no. 1, p. 1, Dec. 2025, doi: 10.3390/hydrogen7010001.