

Klasifikasi Kematangan Buah Kelapa Sawit Dengan SimCLR Berbasis HSV Controlled Color Augmentasi

Sulasmi Harahap, Khairi Ibnutama, Zaimah Panjaitan*

Teknologi Informasi dan Manajemen, Sistem Informasi, STMIK Triguna Dharma, Medan, Indonesia
Email: ¹sulasmiharahap01@gmail.com, ²mr.ibnutama@gmail.com, ^{3,*}zaimahp09@gmail.com
Email Penulis Korespondensi: zaimahp09@gmail.com

Submitted 12-05-2026; Accepted 09-06-2026; Published 30-06-2026

Abstrak

Self-supervised learning dengan metode SimCLR memerlukan augmentasi data yang tepat sebagai landasan pembelajaran representasi kontrasif. Pada tugas klasifikasi kematangan buah kelapa sawit, warna merupakan fitur diskriminatif utama, sehingga augmentasi standar *ColorJitter* berbasis RGB berpotensi mendistorsi informasi warna yang kritis. Penelitian ini mengusulkan framework augmentasi berbasis ruang warna HSV dengan delapan konfigurasi parameter (C1–C8) yang ditentukan secara data-driven melalui analisis *Eta-squared* (η^2), dirancang untuk mempertahankan integritas semantik warna kematangan sekaligus menghasilkan positive pairs yang variatif. Eksperimen dilakukan pada 1.016 citra buah kelapa sawit tiga kelas (Mentah, Matang, Terlalu Matang) menggunakan ResNet-18 sebagai encoder SimCLR dengan protokol linear evaluation. Hasil menunjukkan seluruh konfigurasi HSV melampaui Baseline (82,22%), dengan HSV_C1 sebagai konfigurasi terbaik yang mencapai test accuracy 94,44% dan F1-Score Macro 94,46% (+12,22 pp). Analisis η^2 mengonfirmasi komponen Hue sebagai fitur paling diskriminatif antar kelas, sehingga pembatasannya selama augmentasi terbukti esensial untuk kualitas representasi yang dihasilkan. Framework yang diusulkan secara konsisten meningkatkan performa SimCLR pada domain klasifikasi berbasis warna dengan kebutuhan data berlabel yang minimal.

Kata Kunci: Contrastive Learning; Eta-Squared; HSV Augmentasi; Kelapa Sawit; Klasifikasi Kematangan, Self-Supervised Learning;

Abstract

Self-supervised learning with the SimCLR method requires appropriate data augmentation as the foundation for contrastive representation learning. In the task of classifying oil palm fruit maturity, color is the main discriminative feature, so the standard RGB-based *ColorJitter* augmentation has the potential to distort critical color information. This study proposes an augmentation framework based on the HSV color space with eight parameter configurations (C1–C8) determined in a data-driven manner through *Eta-squared* (η^2) analysis, designed to preserve the semantic integrity of maturity color while generating varied positive pairs. Experiments were conducted on 1,016 oil palm fruit images across three classes (Unripe, Ripe, Overripe) using ResNet-18 as the SimCLR encoder with a linear evaluation protocol. The results show that all HSV configurations outperform the Baseline (82.22%), with HSV_C1 being the best configuration, achieving a test accuracy of 94.44% and Macro F1-Score of 94.46% (+12.22 pp). The η^2 analysis confirms that the Hue component is the most discriminative feature between classes, so constraining it during augmentation proves essential for the quality of the resulting representations. The proposed framework consistently improves SimCLR performance in color-based classification domains with minimal labeled data requirements.

Keywords: Contrastive Learning; Eta-Squared; HSV Augmentation; Maturity Classification; Oil Palm; Self-Supervised Learning;

1. PENDAHULUAN

Pada tahun 2022, produktivitas minyak sawit (CPO) Indonesia mencapai 46,82 juta ton dengan volume ekspor sebesar 26,13 juta ton pada tahun 2023, menjadikan Indonesia eksportir CPO terbesar di dunia [1], [2], [3]. Kualitas CPO sangat ditentukan oleh ketepatan penentuan tingkat kematangan buah saat pemanenan [4], [5]. Secara visual, tingkat kematangan ditandai oleh transisi pigmen dari hitam keunguan menjadi oranye kemerahan, namun proses pemanenan manual terhadap kesalahan akibat subjektivitas operator, variabilitas intensitas cahaya, dan keterbatasan jarak pandang [6], [7], [8].

Pendekatan berbasis computer vision, khususnya melalui model *Supervised Learning*, menawarkan solusi yang lebih objektif dan terukur untuk deteksi kematangan secara otomatis [9]. Namun, pengembangan model *Supervised Learning* yang andal umumnya memerlukan dataset berlabel dalam skala besar dengan anotasi pakar, suatu proses yang berbiaya tinggi dan padat tenaga kerja dalam domain pertanian. Seperti penelitian sebelumnya oleh Zulkarnain et al. (2023) berhasil mencapai akurasi tinggi sebesar 97% dalam klasifikasi kematangan TBS menggunakan arsitektur ResNet50, namun metode tersebut sangat bergantung pada ketersediaan dataset berlabel dalam jumlah besar (4.938 citra) [10]. Dan pada penelitian Nur et al. (2022) membuktikan bahwa ketergantungan pada anotasi manual dan dataset berskala besar menjadi hambatan nyata, sebagaimana dilihat dari penelitian tersebut yang harus membatasi dataset pada 350 gambar hasil augmentasi untuk menghindari overfitting. Rendahnya akurasi klasifikasi kematangan (77,20%) dibandingkan deteksi lokasi buah (98,97%) menunjukkan bahwa model supervised masih kesulitan melakukan generalisasi pada tugas-tugas klasifikasi tingkat tinggi tanpa dukungan data berlabel pakar dalam jumlah masif [11].

Dalam implementasi skala industri, proses pelabelan manual oleh pakar memerlukan waktu dan biaya yang tinggi, sehingga diperlukan pendekatan yang mampu meminimalkan kebutuhan data berlabel tanpa mengurangi performa klasifikasi [10]. Tantangan ini mendorong berkembangnya minat terhadap teknik *Self-Supervised Learning* (SSL), yang memungkinkan model mempelajari representasi bermakna dari data tidak berlabel sehingga substansial mengurangi ketergantungan pada dataset anotasi manual [12].

Di antara paradigma SSL, *contrastive learning* telah terbukti sangat efektif dalam memperoleh representasi visual yang robust dengan memaksimalkan konsistensi antar augmented views dari input yang sama [13]. Kerangka SimCLR

memanfaatkan prinsip kontrasitif ini untuk mempelajari representasi visual melalui fungsi kerugian NT-Xent, yang mendekatkan representasi pasangan positif sekaligus memaksimalkan jarak terhadap pasangan negatif dalam ruang laten [14]. Kemampuan SimCLR dalam mempelajari representasi berkualitas tinggi dari data tidak berlabel menjadikannya sangat relevan untuk domain pertanian di mana data berlabel langka dan mahal [9]. Sebagaimana dibuktikan oleh Sornapudi et al. (2024) yang berhasil membangun *backbone* pertanian tangguh untuk berbagai tugas hilir (downstream tasks), dengan hanya menggunakan 1% data berlabel untuk tahap *fine-tuning*, model SSL mereka mampu mencapai akurasi 80,2% pada klasifikasi gambar lapangan [9]. Dalam penelitian Bunyang et al. (2023) membuktikan bahwa SimCLR dapat mengekstraksi fitur visual yang bermakna (seperti tekstur bercak atau pola nekrosis) hanya melalui augmentasi data dan contrastive loss, tanpa melihat label satu kali pun pada tahap awal [15].

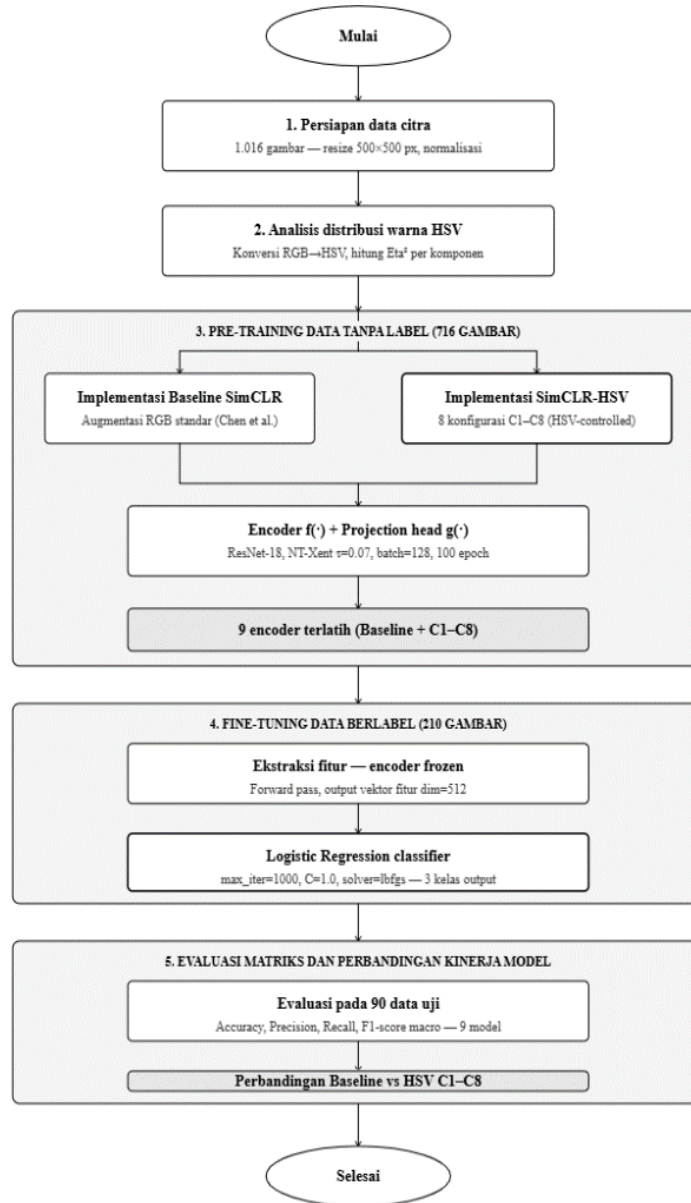
Meskipun SimCLR telah terbukti unggul dalam pembelajaran representasi citra secara mandiri (*self-supervised*), terdapat konflik fundamental SimCLR ketika diterapkan pada deteksi kematangan sawit. Mekanisme augmentasi warna standar SimCLR dirancang untuk dataset umum seperti ImageNet yang bersifat semantik-agnostik terhadap warna, sehingga tidak sesuai untuk domain yang justru sangat bergantung pada warna sebagai fitur diskriminatif utama. *ColorJitter* standar SimCLR menerapkan perturbasi *brightness*, *contrast*, *saturation*, dan *hue* secara agresif pada ruang warna RGB distorsi yang dalam domain umum bertujuan membangun invariansi yang berguna, namun dalam konteks klasifikasi kematangan buah kelapa sawit justru secara aktif menghapus informasi warna kematangan yang bersifat esensial [16]. Sebagaimana diidentifikasi dalam literatur terbaru Zini et al. (2022), *ColorJitter* tradisional memicu efek *color-crippling* yang melumpuhkan kemampuan model dalam mengekstraksi fitur kromatik. Dalam konteks kelapa sawit, di mana perbedaan fraksi kematangan sangat bergantung pada rasio intensitas warna, penggunaan augmentasi warna yang agresif secara aktif menghapus sinyal kematangan tersebut [17]. Akibatnya, encoder yang dilatih dengan augmentasi standar dipaksa membangun invariansi terhadap informasi yang seharusnya dipertahankan, menghasilkan representasi yang kurang diskriminatif untuk membedakan kelas kematangan. Inilah celah metodologis yang menjadi fokus utama penelitian ini.

Untuk mengatasi konflik tersebut, penelitian ini mengusulkan pengendalian augmentasi warna SimCLR melalui ruang warna HSV dengan parameter yang ditentukan secara data-driven menggunakan analisis *Eta-squared* (η^2). Berbeda dari pendekatan *trial-and-error*, η^2 digunakan untuk mengukur secara statistik kontribusi diskriminatif setiap komponen warna Hue, Saturation, dan Value terhadap pemisahan antar kelas kematangan pada dataset aktual. Hasil analisis menjadi landasan ilmiah dalam menentukan seberapa besar setiap komponen boleh diperturbasi: Hue yang terbukti paling diskriminatif dibatasi perturbasi-nya untuk mempertahankan informasi kematangan, sementara Saturation dan Value divariasikan lebih bebas untuk membangun invariansi terhadap kondisi pencahayaan lapangan sebagaimana tantangan yang diidentifikasi pada sistem inspeksi visual kelapa sawit [18], [19], [20]. Delapan konfigurasi parameter HSV (C1–C8) dirancang secara sistematis untuk mengeksplorasi spektrum *trade-off* antara preservasi informasi warna dan diversitas augmentasi kontrasitif. Untuk memvalidasi efektivitas pendekatan yang diusulkan, kinerja delapan konfigurasi SimCLR-HSV (C1–C8) dievaluasi dan dibandingkan secara sistematis terhadap Baseline SimCLR standar menggunakan protokol *linear evaluation* pada dataset buah kelapa sawit tiga kelas, sehingga peningkatan performa yang dihasilkan dapat dikuantifikasi secara empiris.

Sejauh tinjauan literatur yang dilakukan, integrasi antara kerangka SimCLR dan pengendalian augmentasi berbasis HSV yang dikontrol secara data-driven melalui analisis η^2 belum pernah dieksplorasi sebelumnya untuk klasifikasi tingkat kematangan buah kelapa sawit. Penelitian ini diharapkan memberikan kontribusi empiris dalam dua aspek: pertama, membuktikan bahwa pengendalian ruang warna augmentasi adalah variabel desain yang kritis bukan sekadar hyperparameter dalam *contrastive learning* berbasis domain warna; dan kedua, menyediakan panduan data-driven yang dapat diadopsi untuk domain klasifikasi berbasis warna lainnya yang menghadapi permasalahan serupa.

2. METODOLOGI PENELITIAN


Metode penelitian menggunakan pendekatan eksperimental untuk membandingkan performa SimCLR standar dengan SimCLR berbasis HSV dalam mengklasifikasikan tiga tingkat kematangan sawit dengan beberapa tahapan yang disusun untuk mencapai hasil akhir sesuai yang diinginkan. Gambar 1 menunjukkan alur penelitian yang diterapkan pada klasifikasi kematangan buah kelapa sawit, dari persiapan data hingga mencapai hasil akhir deteksi kematangan buah kelapa sawit.



Gambar 1. Alur penelitian Klasifikasi Kematangan Buah Kelapa Sawit Menggunakan SimCLR

2.1 Persiapan Dataset

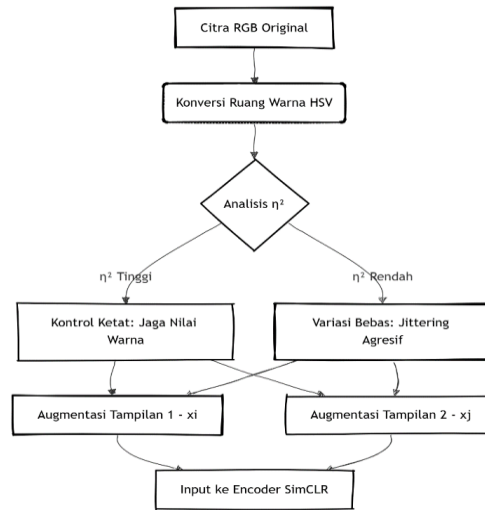
Objek penelitian adalah Tandan Buah Segar (TBS) kelapa sawit yang diambil langsung dari lokasi perkebunan di Labuhan Batu Selatan. Dataset terdiri dari 1.016 data citra buah kelapa sawit yang mencakup buah mentah, matang dan terlalu matang. Sebelum masuk ke tahap pelatihan dilakukan *preprocessing dataset* dengan menormalisasikan ukuran semua data citra menjadi 500 x 500 px, kemudian pembagian data dilakukan secara strategis: 70,47% (716 gambar) untuk data pre-training tanpa label, 20,67% (210 gambar) untuk data fine-tuning berlabel, dan 8,86% (90 gambar) untuk data uji, dari total 1.016 data citra. Gambar 2 menunjukkan contoh data citra buah kelapa sawit berdasarkan tingkat kematangan: (a) mentah, (b) matang, dan (c) terlalu matang.



Gambar 2. Buah kelapa sawit: (a) mentah, (b) matang, dan (c) terlalu matang.

2.2 Analisis Distribusi Warna HSV

Tahap analisis distribusi warna HSV ditentukan secara *data-driven* melalui analisis *Eta-Square* (η^2) bertujuan mengukur proporsi variansi antar kelas terhadap variasi total untuk setiap komponen HSV dengan menggunakan Analisis Varians (ANOVA) satu arah yang akan digunakan untuk menentukan parameter konfigurasi baseline SimCLR dan SimCLR berbasis HSV. Gambar 3 menjabarkan tahapan yang dilakukan untuk menganalisis distribusi warna pada data citra buah kelapa sawit.



Gambar 3. Alur Analisis Distribusi Warna HSV

Untuk menjelaskan lebih lanjut tahapan yang dilakukan pada gambar 3 dalam analisis distribusi warna HSV secara berurutan. Berikut langkah-langkah yang dilakukan meliputi:

2.2.1 Konversi citra RGB ke ruang warna HSV

Sebelum citra RGB di konversi ke HSV, RGB terlebih dahulu dinormalisasikan ke rentang [0-1] dengan menggunakan persamaan (1), (2), dan (3):

$$R_n = \frac{R}{255} \quad (1)$$

$$G_n = \frac{G}{255} \quad (2)$$

$$B_n = \frac{B}{255} \quad (3)$$

Setelah RGB dinormalisasikan ke rentang 0-1, setiap nilai komponen RGB di konversi ke HSV menggunakan persamaan (4), (5) dan (6):

$$V = \max(R_n, G_n, B_n) \quad (4)$$

$$S = \frac{\max - \min}{\max} = S \quad (5)$$

$$H = \begin{cases} 60^\circ x \left(\frac{G-B}{\max-\min} \bmod 6 \right) & \text{jika } (\max = R) \\ 60^\circ x \left(\frac{B-R}{\max-\min} + 2 \right) & \text{jika } (\max = G) \\ 60^\circ x \left(\frac{R-G}{\max-\min} + 4 \right) & \text{jika } (\max = B) \end{cases} \quad (6)$$

2.2.2 Analisis Eta-Square (η^2)

Setelah ekstraksi nilai Hue (H), Saturation (S), dan Value (V), dilakukan uji Analisis Varians (ANOVA) satu arah untuk mengukur tingkat diskriminabilitas setiap saluran terhadap kategori kematangan (mentah, matang, dan terlalu matang). Dari hasil ANOVA, nilai *Eta-Square* (η^2) dihitung untuk menguantifikasi proporsi variansi antar kelas terhadap variansi total. Langkah pertama dalam menghitung *Eta-Square* (η^2) adalah memecah total variabilitas data menjadi dua komponen utama:

a. Jumlah Kuadrat Antar Kelompok (*Sum of Squares Between Groups*):

$$SS_{between} = \sum_{i=1}^K n_i (\bar{X}_i - \bar{X}_{total})^2 \quad (7)$$

b. total variasi dari seluruh sampel data warna *Sum of Square Total* (SS_{total}):

$$SS_{total} = \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{total})^2 \quad (8)$$

Untuk menguji signifikan perbedaan rata-rata antar kelompok dihitung statistic F (ANOVA) menggunakan persamaan:

$$F = \frac{MS_{between}}{MS_{within}} \quad (9)$$

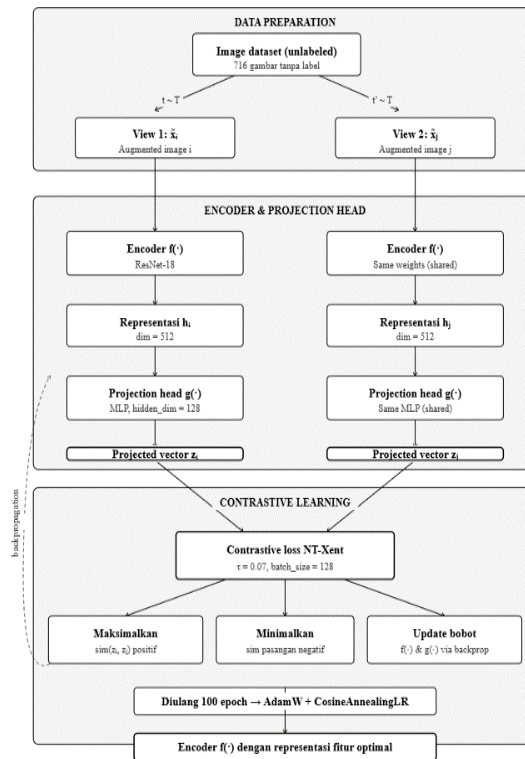
Di mana MS adalah *Mean Square* yang diperoleh dari pembagian SS dengan derajat kebebasan (*degrees of freedom*) masing-masing. Nilai Eta-square digunakan untuk mengukur kekuatan diskriminasi warna, untuk menghitung eta-square menggunakan persamaan:

$$\eta^2 = \frac{SS_{between}}{SS_{total}} \quad (10)$$

Nilai *Eta-Square* (η^2) yang mendekati 1 mengindikasikan kontribusi signifikan komponen warna tersebut dalam membedakan tingkat kematangan. Hasil analisis ini menjadi landasan empiris dalam menetapkan kebijakan augmentasi: komponen dengan Eta-Square (η^2) tertinggi akan dijaga konsistensinya (distorsi minimal) untuk menghindari pergeseran semantik, sementara komponen dengan *Eta-Square* (η^2) rendah diberikan rentang variasi yang lebih luas untuk meningkatkan ketahanan model terhadap gangguan eksternal. Pendekatan berbasis data (*data-driven*) ini menentukan rentang parameter augmentasi pada konfigurasi C1-C8.

2.3 Pre-Training Data Tanpa Label

Ada dua tahap utama dalam proses SimCLR yaitu pre-training dan fine-tuning. Pada gambar 4 dijelaskan alur proses pre-training yang diterapkan kedua jalur paralel Baseline menggunakan *ColorJitter* standar RGB, dan SimCLR-HSV.



Gambar 4. Alur Proses Pre-Training

Pada tahap pre-training, SimCLR menggunakan ResNet-18 sebagai *encoder* $f(\cdot)$ untuk mempelajari representasi visual dari 716 gambar tanpa label [9], [14], [21]. Setiap gambar dalam mini-batch diaugmentasi dua kali secara independen menggunakan transformasi acak ($t \sim T$ dan $t' \sim T$) untuk menghasilkan pasangan positif (\tilde{x}_i dan \tilde{x}_j) [22].

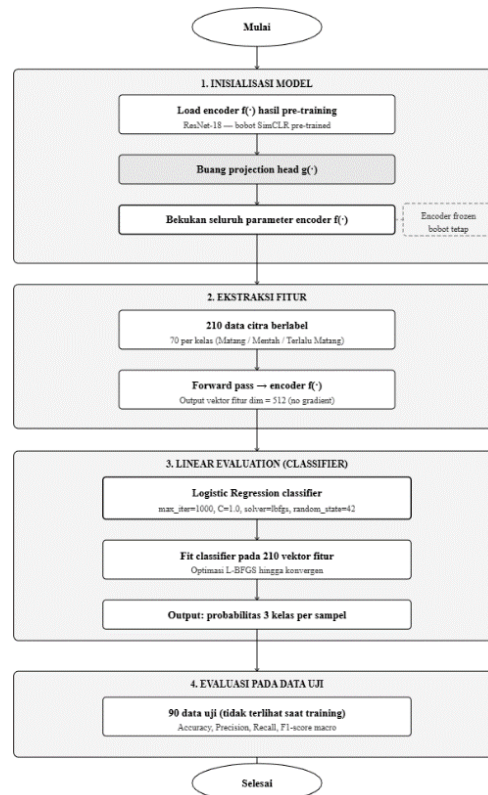
Kedua view pada kedua proses pre-training dilewatkan melalui *encoder* $f(\cdot)$ berbagi bobot untuk menghasilkan vektor representasi berdimensi 512, kemudian dipetakan oleh *projection head non-linear* $g(\cdot)$ berupa MLP (hidden_dim=128) ke vektor proyeksi z_i dan z_j di ruang laten yang lebih rendah. Fungsi kerugian NT-Xent ($\tau=0,07$, batch=128) diterapkan untuk memaksimalkan similaritas kosinus pasangan positif sekaligus meminimalkan similaritas terhadap $2(N-1)$ pasangan negatif dalam satu batch sesuai persamaan (11) [23]:

$$\ell_{i,j} = - \frac{\log\left(\exp\left(\frac{\text{sim}(z_i z_j)}{\tau}\right)\right)}{\sum_{k=1}^{2N} \mathbb{1}_{[k \neq j]} \exp\left(\frac{\text{sim}(z_i z_k)}{\tau}\right)} \quad (11)$$

Dalam proses augmentasi pada tahap pre-training ini SimCLR dijalankan dalam dua jalur paralel Baseline menggunakan *ColorJitter* standar RGB, dan SimCLR-HSV menggunakan augmentasi terkontrol pada ruang HSV dengan 8 konfigurasi (C1–C8).

2.4 Fine Tuning Data Berlabel

Setelah pre-training, tahap fine-tuning dilakukan menggunakan protokol linear evaluation untuk melihat seberapa baik model belajar dari data tanpa label pada tahap pre-training. Gambar 5 menunjukkan tahapan Fine Tuning yang diterapkan pada penelitian ini.



Gambar 5. Proses Fine Tuning

Projection head g(.) dibuang dan seluruh parameter *encoder* dibekukan sepenuhnya (*fully frozen*) agar representasi yang telah dipelajari tidak berubah [24]. *Encoder* yang dibekukan kemudian digunakan untuk mengekstrak vektor fitur berdimensi 512 dari 210 data berlabel tanpa perhitungan gradien, yang selanjutnya digunakan untuk melatih Logistic Regression classifier ($\text{max_iter}=1000$, $C=1.0$, $\text{solver}=\text{lbfgs}$) menggunakan algoritma L-BFGS hingga konvergen. *Classifier* menghasilkan probabilitas untuk tiga kelas output (Mentah, Mentah, Terlalu Matang).


2.5 Evaluasi Matriks Dan Perbandingan Kinerja Model

Pada tahap ini akan dilakukan evaluasi performa model dengan menggunakan 90 sampel data citra untuk klasifikasi kematangan kelapa sawit yang belum pernah dilihat model sebelumnya. Menggunakan beberapa matriks standart seperti accuracy, precision, recall, dan F1-Score Macro dan confusion matriks. Kemudian membandingkan antara performa model menggunakan baseline SimCLR standar dengan SimCLR berbasis HSV.

3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Visual dan Distribusi Warna Dataset

Penelitian ini menggunakan dataset 1.016 citra Tandan Buah Segar (TBS) kelapa sawit yang terdiri dari tiga kelas kematangan. Gambar 6 menunjukkan contoh visual warna buah kelapa sawit pada setiap tingkat kematangan: (a) mentah, (b) matang, dan (c) terlalu matang.



Gambar 6. Visual warna Buah kelapa sawit: (a) mentah, (b) matang, dan (c) terlalu matang.

Seperti yang ditampilkan pada Gambar 6, perbedaan visual antar kelas dapat diidentifikasi secara langsung melalui karakteristik warna dominan: kelas Mentah didominasi warna hitam keunguan dengan kecerahan rendah, kelas Matang menampilkan warna merah-oranye cerah, dan kelas Terlalu Matang menunjukkan merah tua kecokelatan dengan saturasi yang bervariasi. Perbedaan visual inilah yang menjadi landasan hipotesis bahwa komponen warna dalam ruang HSV khususnya Hue berpotensi menjadi fitur diskriminatif utama yang harus dijaga konsistensinya selama augmentasi.

Untuk mengonfirmasi hipotesis tersebut secara statistik, dilakukan konversi citra RGB ke ruang warna HSV menggunakan persamaan (1)-(6) yang telah dijabarkan pada sub-bagian 2.2. Tabel 1 menampilkan sampel 12 piksel nyata yang diambil dari gambar representatif masing-masing kelas pada posisi yang seragam, beserta nilai HSV hasil konversinya.

Tabel 1. Sampel Piksel RGB dan Hasil Konversi HSV dari Gambar Representatif per Kelas (Skala OpenCV: $H \in [0,179]$, S dan $V \in [0,255]$)

Label	Kelas	R	G	B	H(OpenCV)	S	V	H(derajat)	Interpretasi Warna
P1-Ma	Matang	253	225	222	3	31	253	06.00	Merah
P2-Ma	Matang	165	88	98	176	119	165	352.00.00	Merah
P3-Ma	Matang	175	167	156	17	28	175	34.00.00	Oranye-Kuning
P4-Ma	Matang	210	119	116	1	114	210	02.00	Merah
P1-Me	Mentah	103	83	76	8	67	103	16.00	Oranye-Kuning
P2-Me	Mentah	160	144	147	174	26	160	348.00.00	Merah
P3-Me	Mentah	132	120	130	155	23	132	310.00.00	Ungu-Merah
P4-Me	Mentah	100	73	80	172	69	100	344.00.00	Merah
P1-Te	Terlalu Matang	78	64	63	2	49	78	04.00	Merah
P2-Te	Terlalu Matang	84	42	28	7	170	84	14.00	Merah
P3-Te	Terlalu Matang	222	209	203	9	22	222	18.00	Oranye-Kuning
P4-Te	Terlalu Matang	147	121	106	11	71	147	22.00	Oranye-Kuning

Berdasarkan Tabel 1, pola distribusi nilai H antar kelas sudah tampak nyata: kelas Terlalu Matang memiliki nilai H yang sangat terkonsentrasi di rentang rendah (2–11), kelas Matang memiliki H bervariasi (1–176) dengan dominasi nilai rendah (merah), sementara kelas Mentah memiliki H tersebar di rentang tinggi (8–174) yang mencerminkan nuansa warna lebih kompleks. Perbedaan distribusi ini kemudian dikuantifikasi menggunakan persamaan (7)–(10) untuk menghasilkan nilai η^2 per komponen. Tabel 2 merangkum hasil perhitungan η^2 beserta mean per kelas dan kebijakan augmentasi yang dihasilkan.

Tabel 2. Statistik Deskriptif Mean HSV per Kelas dan Hasil Eta-squared (η^2) sebagai Dasar Perancangan Parameter Augmentasi

Channel	Mean Matang	Mean Mentah	Mean Terlalu Matang	Grand Mean	SS_between	SS_total	η^2	Kebijakan Augmentasi
H (Hue)	49,25	127,25	7,25	61,25	29.664,00	70.460,25	0,4210	h_gain dibatasi ketat
V (Value)	200,75	123,75	132,75	152,42	14.178,67	34.854,92	0,4068	v_gain Variasi sedang
S (Saturation)	73,00	46,25	78,00	65,75	2.331,50	24.306,25	0,0959	s_gain variasi lebar

Berdasarkan Tabel 2, urutan diskriminabilitas komponen HSV adalah H ($\eta^2=0,4210$) > V ($\eta^2=0,4068$) > S ($\eta^2=0,0959$). Komponen Hue memiliki η^2 tertinggi, mengkonfirmasi bahwa transisi rona warna dari hitam keunguan (Mentah) menuju oranye-merah (Matang) dan merah tua (Terlalu Matang) merupakan sinyal pembeda utama antar kelas. Komponen Saturation memiliki η^2 terendah (0,0959), mengindikasikan bahwa tingkat kejenuhan warna lebih dipengaruhi kondisi pencahayaan lapangan daripada kelas kematangan itu sendiri. Berdasarkan temuan ini, parameter augmentasi dirancang proporsional terhadap nilai η^2 : komponen dengan η^2 tinggi mendapat rentang distorsi kecil agar semantik warnanya terjaga, sementara komponen η^2 rendah mendapat rentang distorsi besar untuk membangun invariansi


pencapaian. Tabel 3 merangkum delapan konfigurasi yang dihasilkan, mencakup spektrum dari konservatif (C1) hingga agresif (C8), dan dibandingkan terhadap Baseline SimCLR standar.

Tabel 3. Konfigurasi Parameter Augmentasi Baseline SimCLR dan SimCLR-HSV Berdasarkan Hasil Analisis η^2

Kode	h_gain (°)	s_gain	v_gain	Deskripsi
Baseline	hue=0.1 ($\pm 18^\circ$)	sat=0.50	bright=0.50	Distorsi RGB agresif, semua saluran terdistorsi bebas
C1	8	0.15	0.30	Hue paling ketat, S & V rendah → paling konservatif
C2	8	0.20	0.15	Hue ketat, V paling ketat (0.15) kecerahan terjaga
C3	10	0.30	0.12	Hue sedang, V ekstrem ketat (0.12) → label "Eta ² -Proporsional"
C4	15	0.40	0.15	Hue mulai longgar, S agresif, V ketat
C5	20	0.40	0.30	Hue & S agresif, V sedang
C6	30	0.50	0.35	Hue paling longgar kedua, semua parameter besar
C7	20	0.40	0.50	Sama H & S dengan C5, tapi V paling besar (0.50)
C8	40	0.40	0.30	Hue paling ekstrem, S & V sedang

Seperti yang terlihat pada Tabel 3, nilai h_gain seluruh konfigurasi HSV (8° – 40°) lebih kecil dibandingkan Baseline ($\pm 18^\circ$ setara ± 9 unit OpenCV) mencerminkan kebijakan bahwa Hue sebagai komponen paling diskriminatif harus dijaga konsistensinya. Sebagai ilustrasi, piksel P1-Ma dengan $H=3$ pada konfigurasi C1 (h_gain= 8°) hanya dapat bergeser maksimal ± 4 unit OpenCV ke rentang [0,7] masih dalam zona warna merah yang sama. Sebaliknya pada Baseline, pergeseran hingga ± 9 unit berpotensi menggeser $H=3$ ke rentang $H=12$ yang sudah masuk ke zona oranye, secara aktif menghapus sinyal kematangan.

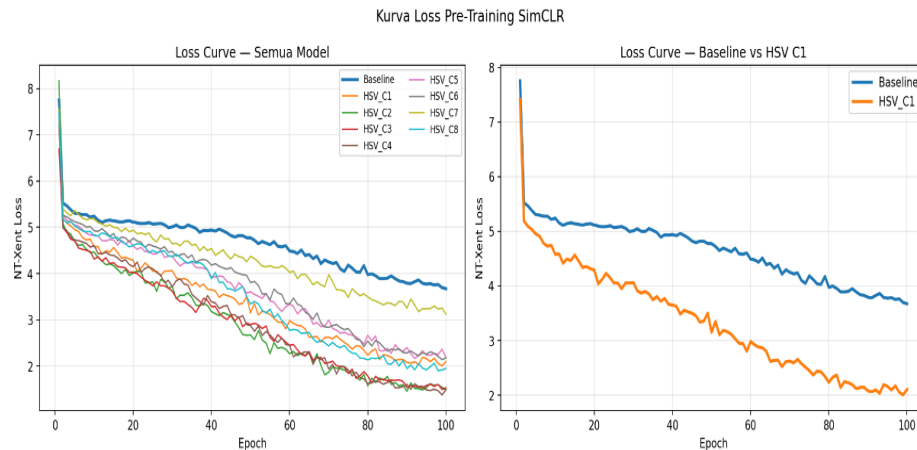
Dampak nyata dari perbedaan strategi ini dapat dilihat pada Gambar 6 yang menampilkan visualisasi positive pairs. Pada Baseline, View 1 hampir kehilangan seluruh informasi warna hingga mendekati grayscale dan View 2 berubah kekuningan tidak natural. Berbeda dengan itu, konfigurasi HSV menunjukkan gradasi distorsi yang lebih terstruktur: C1 menghasilkan kedua view yang paling mirip dengan warna merah-oranye buah masih terjaga; C2 dan C3 menampilkan kedua view yang flat dan seragam akibat v_gain sangat kecil (0,15 dan 0,12); C4–C6 menampilkan kontras yang semakin besar antara View 1 yang berwarna dan View 2 yang semakin desaturasi seiring peningkatan s_gain hingga 0,50; C7 menonjol dengan perbedaan kecerahan paling jelas antar kedua viewnya akibat v_gain=0,50 tertinggi; sedangkan C8 menampilkan View 1 paling gelap keunguan akibat pergeseran hue ekstrem 40° . Secara keseluruhan, C1, C5, dan C6 mencapai keseimbangan optimal antara preservasi semantik warna dan diversitas augmentasi kontrasif yang dibutuhkan SimCLR. Gambar 6 menunjukkan visual warna sesuai dengan konfigurasi parameter augmentasi Baseline SimCLR dan SimCLR-HSV berdasarkan hasil analisis η^2



Gambar 6. Visualisasi Positive Pairs

3.2 Dinamika Konvergensi Pre-Training SimCLR

Menggunakan parameter augmentasi dari Tabel 3, SimCLR dijalankan dalam dua jalur paralel pada 716 gambar tanpa label selama 100 epoch. Gambar 7 menyajikan kurva loss NT-Xent selama pre-training untuk seluruh 9 model.

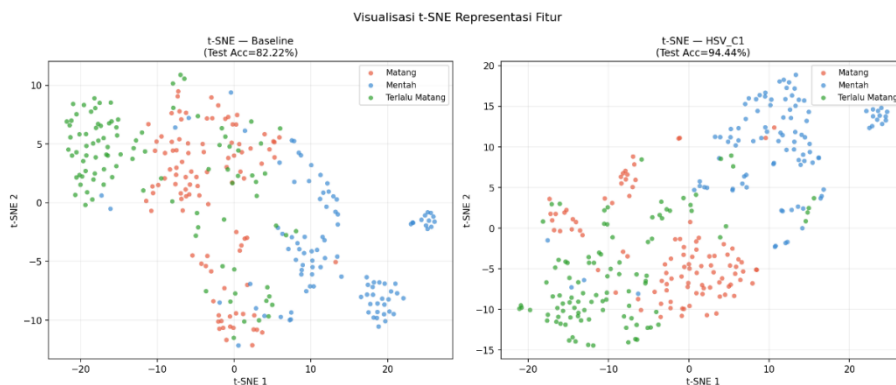


Gambar 7. Kurva Loss Pre-Training SimCLR

Berdasarkan Gambar 7, terdapat perbedaan signifikan dalam pola penurunan loss antara Baseline dan seluruh konfigurasi HSV. Model Baseline menunjukkan penurunan loss paling lambat dengan nilai akhir tertinggi ($\approx 3,7$). Kondisi ini konsisten dengan mekanisme augmentasi RGB yang mendistorsi semua saluran secara seragam seperti yang ditunjukkan pada analisis piksel di sub-bagian 3.1, distorsi H yang tidak terkontrol menghasilkan pasangan positif (\tilde{x}_i, \tilde{x}_j) yang secara semantik ambigu, sehingga fungsi loss NT-Xent pada persamaan (11) sulit dioptimalkan. Seluruh konfigurasi HSV menunjukkan konvergensi yang lebih cepat dengan nilai loss akhir lebih rendah, berkisar antara $\approx 1,5$ hingga $\approx 3,2$. HSV_C1 secara khusus mencatat penurunan loss yang paling konsisten dan stabil dengan nilai akhir sekitar 2,1 terendah di antara semua konfigurasi. Hal ini selaras dengan nilai h_gain terkecil (8°) yang memastikan kedua augmented views dari gambar yang sama mempertahankan karakteristik rona yang koheren, memudahkan encoder membangun representasi yang saling mirip antara pasangan positif. Sebaliknya, HSV_C8 dengan h_gain ekstrem 40° menunjukkan loss akhir yang relatif lebih tinggi ($\approx 3,2$) dibandingkan C1, mengkonfirmasi bahwa pergeseran Hue yang terlalu besar tetap berdampak negatif meskipun masih lebih baik dari Baseline RGB.

3.3 Kualitas Representasi Fitur pada Linear Evaluation

Setelah 9 encoder terlatih diperoleh tahap fine-tuning dilakukan, seluruh parameter encoder dibekukan sepenuhnya dan vektor fitur berdimensi 512 diekstrak dari 210 data berlabel. Logistic Regression kemudian dilatih di atas vektor fitur tersebut sebagaimana dijelaskan pada sub-bagian 2.4. Gambar 8 menyajikan visualisasi t-SNE dari vektor fitur yang dihasilkan encoder Baseline dan HSV_C1 untuk memvalidasi kualitas representasi secara visual sebelum evaluasi numerik.



Gambar 8. t-SNE dari representasi fitur

Berdasarkan Gambar 8, representasi Baseline menunjukkan ketiga kluster yang saling tumpang tindih signifikan terutama antara kelas Matang dan Terlalu Matang tanpa batas pemisah yang tegas dalam ruang laten. Kondisi ini secara langsung menjelaskan keterbatasan Baseline: batas keputusan linear dari Logistic Regression tidak dapat memisahkan kelas yang bertumpang tindih. Pola tumpang tindih ini konsisten dengan temuan pada Tabel 2 nilai $\eta^2_H=0,4210$ yang diperoleh dari sampel piksel Terlalu Matang (H rata-rata 7,25) dan Matang (H rata-rata 49,25) menunjukkan perbedaan distribusi yang signifikan secara statistik, namun augmentasi RGB yang agresif merusak sinyal tersebut sehingga encoder

gagal mempelajarinya. Sebaliknya, HSV_C1 menunjukkan pemisahan kluster yang jauh lebih bersih: kelas Mentah membentuk kluster kompak di bagian atas, Matang mengelompok di tengah-bawah, dan Terlalu Matang terpisah di bagian bawah. Meskipun masih terdapat beberapa titik outlier yang berkorelasi dengan 5 sampel yang salah diklasifikasikan, kualitas pemisahan yang lebih baik ini membuktikan secara visual bahwa pembatasan h_gain pada augmentasi HSV berhasil mempertahankan sinyal warna kematangan selama pre-training.

3.4 Perbandingan Kinerja Klasifikasi Baseline dan SimCLR-HSV

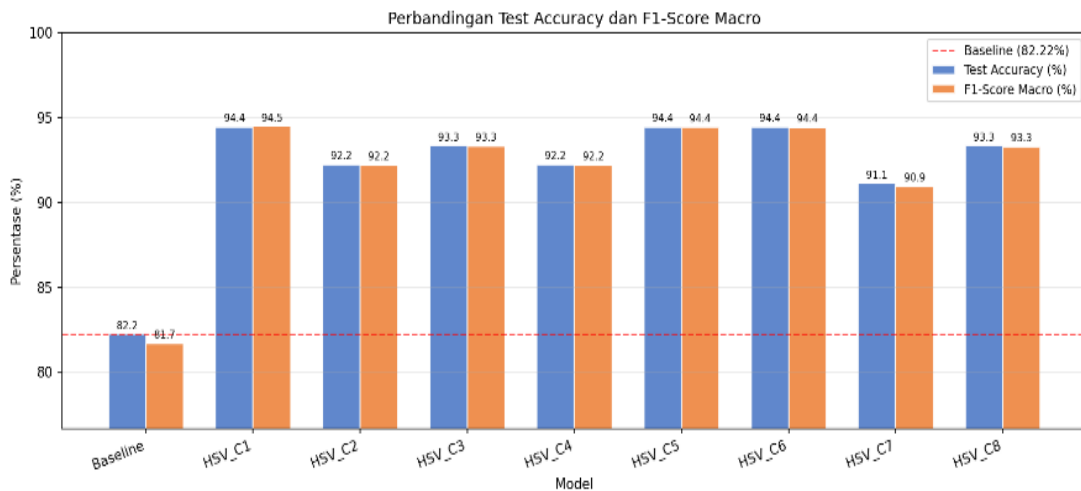
3.4.1 Evaluasi Akurasi dan F1-Score Macro

Evaluasi dilakukan pada 90 data uji yang sepenuhnya diisolasi dari proses pelatihan. Tabel 4 menyajikan hasil evaluasi lengkap seluruh 9 model berdasarkan metrik accuracy, precision macro (P-Mac), recall macro (R-Mac), F1-Score Macro (F1-Mac), F1-Score per kelas, training accuracy, dan peringkat keseluruhan.

Tabel 4. Hasil Evaluasi Performa Semua Model

Model	Acc (%)	P-Mac	R-Mac	F1-Mac	F1-Matang	F1-Mentah	F1-TriMtg	TrainAcc	Rank
Baseline	82.22	82.22	82.22	81.66	80.00	90.91	74.07	92.86	9
HSV_C1	94.44	94.72	94.44	94.46	93.55	95.08	94.74	100.00	1
HSV_C2	92.22	92.41	92.22	92.19	91.80	93.55	91.23	100.00	4
HSV_C3	93.33	93.75	93.33	93.32	93.55	93.55	92.86	100.00	3
HSV_C4	92.22	92.41	92.22	92.19	91.80	93.55	91.23	98.57	4
HSV_C5	94.44	94.51	94.44	94.42	91.80	98.36	93.10	99.05	1
HSV_C6	94.44	94.50	94.44	94.40	93.33	96.77	93.10	98.57	1
HSV_C7	91.11	91.19	91.11	90.94	96.77	90.32	85.71	99.05	7
HSV_C8	93.33	93.46	93.33	93.27	91.80	96.77	91.23	98.57	3

Berdasarkan Tabel 4, seluruh konfigurasi HSV secara konsisten melampaui performa Baseline pada semua metrik. Baseline hanya mencapai test accuracy 82,22% dengan F1-Score Macro 81,66%, sementara tiga konfigurasi terbaik HSV_C1, HSV_C5, dan HSV_C6 masing-masing meraih test accuracy 94,44%, mewakili peningkatan absolut 12,22 poin persentase. HSV_C1 mencatat F1-Score Macro tertinggi sebesar 94,46%, menjadikannya konfigurasi paling unggul secara keseluruhan. Hasil ini selaras dengan nilai $\eta^2_H=0,4210$ dari Tabel 2: konfigurasi dengan h_gain paling ketat (C1, $h=8^\circ$) menghasilkan representasi terbaik karena paling konsisten menjaga informasi Hue yang merupakan komponen paling diskriminatif. Bahkan konfigurasi terendah HSV_C7 (91,11%) masih mengungguli Baseline sebesar 8,89 poin persentase. Gambar 9 memperlihatkan perbandingan visual test accuracy dan F1-Score Macro seluruh model.




Gambar 9. Perbandingan Tes Accuracy dan F1-Score Macro

3.4.2 Analisis Per Kelas dan Confusion Matrix

Berdasarkan Gambar 10 menyajikan confusion matrix perbandingan antara Baseline dan HSV_C1 pada 90 data uji. Baseline menunjukkan kelemahan terbesar pada kelas Terlalu Matang dengan recall hanya 66,7%: dari 30 sampel, hanya 20 yang benar; 6 sampel salah diklasifikasikan sebagai Matang dan 4 sampel sebagai Mentah. Pola kegagalan ini konsisten dengan hasil analisis Tabel 2 — nilai $\eta^2_V=0,4068$ menunjukkan bahwa Value juga memiliki diskriminabilitas sedang, dan pada kelas Terlalu Matang distribusi V (mean=132,75) cukup tumpang tindih dengan kelas Mentah (mean=123,75), sehingga representasi Baseline yang dilatih dengan augmentasi RGB agresif tidak mampu membedakan keduanya. HSV_C1 berhasil memperbaiki secara signifikan: kelas Matang meningkat dari 80,0% menjadi 96,7% (+16,7 pp), Terlalu Matang dari 66,7% menjadi 90,0% (+23,3 pp), dan total misklasifikasi turun dari 16 menjadi hanya 5 sampel. Kelas Mentah mengalami penurunan kecil dari 100,0% menjadi 96,7% (-3,3 pp) tradeoff yang dapat diterima mengingat peningkatan besar pada dua kelas lainnya dan F1-Score Macro keseluruhan meningkat dari 81,66% menjadi 94,46%. Dari

perspektif operasional, peningkatan recall kelas Terlalu Matang memiliki implikasi langsung pada kualitas produksi CPO, karena mengurangi risiko buah dengan kadar asam lemak bebas (ALB) tinggi yang lolos ke jalur pengolahan.













Gambar 10. Analisis confusion matrix

3.5 Generalisasi Model pada Data Baru

Untuk mengevaluasi kemampuan generalisasi model terhadap data di luar distribusi pelatihan, dilakukan pengujian inferensi menggunakan 15 citra baru yang tidak pernah digunakan selama pre-training maupun fine-tuning, diambil langsung dari lapangan dengan kondisi pencahayaan dan sudut pengambilan yang bervariasi. Prediksi akhir setiap gambar ditentukan melalui mekanisme voting majority dari 9 model kelas yang dipilih oleh minimal 5 dari 9 model ditetapkan sebagai prediksi final. Tabel 5 menyajikan hasil prediksi lengkap per sampel beserta hasil voting.

Tabel 5. Hasil Prediksi Voting Majority 15 Sampel Data Baru (Ma=Matang, Me=Mentah, TM=Terlalu Matang)

No	Nama File	Baseline	C1	C2	C3	C4	C5	C6	C7	C8	Voting
1		TM	Ma	Me	Me	Me	Ma	Me	Ma	Ma	Matang (4/9)
2		Me	Ma	Me	Me	Me	Me	Me	Ma	Me	Mentah (7/9)
3		Me	Ma	Me	Me	Me	Ma	Me	Ma	Me	Mentah (6/9)
4		Me	Me	Me	Me	Me	Me	Me	Me	Me	Mentah (9/9)
5		Me	Me	Me	Me	Me	Me	Me	Me	Me	Mentah (9/9)
6		TM	Ma	Ma	Me	Me	Ma	Ma	Ma	Ma	Matang (6/9)
7		Me	Ma	Me	Me	Me	Ma	Ma	Ma	Ma	Matang (5/9)
8		Me	Ma	TM	Me	Me	Ma	Ma	Ma	Ma	Matang (5/9)
9		Me	TM	TM	TM	TM	TM	Me	Me	Me	Terlalu Matang (5/9)
10		Me	Ma	Me	Me	Me	Ma	Ma	Ma	Ma	Matang (5/9)

11		Me	Me	Me	Me	Me	Me	Me	Ma	Me	Mentah (8/9)
12		Ma	TM	TM	TM	TM	Ma	Ma	Me	TM	Terlalu Matang (5/9)
13		Ma	Ma	TM	TM	TM	Ma	Ma	Ma	Ma	Matang (6/9)
14		Ma	TM	TM	TM	TM	TM	Ma	Me	Ma	Terlalu Matang (5/9)
15		TM	TM	TM	TM	TM	TM	Ma	Me	Ma	Terlalu Matang (6/9)

Berdasarkan Tabel 5, dari 15 sampel yang diuji voting majority menghasilkan 6 prediksi Matang, 5 prediksi Mentah, dan 4 prediksi Terlalu Matang. Terdapat 2 sampel dengan konsensus penuh (9/9), 6 sampel dengan mayoritas kuat (6-8/9), dan 7 sampel dengan hasil ambigu (4-5/9) yang mencerminkan kesamaan visual tinggi antar kelas pada gambar tersebut. Pola yang paling menonjol dari Tabel 5 adalah konsistensi kegagalan Baseline: pada sampel 9, 12, 14, dan 15 yang terklasifikasi sebagai Terlalu Matang oleh mayoritas model, Baseline memberikan prediksi yang menyimpang dari konsensus pola yang sepenuhnya konsisten dengan recall kelas Terlalu Matang Baseline yang hanya 66,7% pada evaluasi formal di Tabel 4. Sebaliknya, HSV_C1 memberikan prediksi yang selaras dengan voting majority pada 13 dari 15 kasus, memperkuat posisinya sebagai konfigurasi paling andal. Secara keseluruhan, hasil pengujian inferensi ini mengkonfirmasi bahwa pendekatan SimCLR berbasis HSV dengan mekanisme voting majority dari 9 konfigurasi mampu menghasilkan sistem klasifikasi kematangan buah kelapa sawit yang tidak hanya akurat pada data uji formal, tetapi juga memiliki kemampuan generalisasi yang baik terhadap citra lapangan dengan kondisi pengambilan yang bervariasi.

4. KESIMPULAN

Penelitian ini membuktikan bahwa augmentasi warna berbasis ruang warna HSV yang terkontrol secara data-driven merupakan strategi yang lebih tepat dibandingkan augmentasi ColorJitter RGB standar dalam kerangka SimCLR untuk domain klasifikasi kematangan buah kelapa sawit, di mana hasil analisis Eta-squared (η^2) mengkonfirmasi bahwa komponen Hue ($\eta^2=0,4210$) adalah fitur paling diskriminatif antar kelas temuan yang menjawab hipotesis utama penelitian bahwa augmentasi yang terlalu agresif pada ruang RGB tidak hanya gagal membangun invariansi yang bermakna, tetapi secara aktif merusak informasi warna semantik yang menjadi satu-satunya sinyal pembeda kematangan. Kontribusi ilmiah utama terletak pada pendekatan data-driven dalam merancang strategi augmentasi domain-spesifik, di mana konsistensi keunggulan seluruh delapan konfigurasi HSV (peningkatan 8,89 sampai 12,22 poin persentase terhadap Baseline) menegaskan bahwa pengendalian ruang warna augmentasi adalah variabel desain yang kritis dalam contrastive learning berbasis domain warna bukan sekadar hyperparameter yang dapat diabaikan sehingga pemilihan ruang warna augmentasi merupakan keputusan desain yang berdampak signifikan terhadap kualitas representasi yang dipelajari secara self-supervised. Dari sisi aplikasi, pendekatan SimCLR-HSV ini berpotensi diimplementasikan sebagai modul klasifikasi kematangan berbasis kamera pada sistem pemanenan kelapa sawit semi-otomatis di mana data berlabel sangat terbatas, dan untuk penelitian selanjutnya eksplorasi dapat diarahkan pada encoder yang lebih dalam seperti ResNet-50 atau Vision Transformer, pengujian pada dataset yang lebih beragam, serta pengembangan strategi augmentasi adaptif yang secara otomatis menyesuaikan parameter HSV berdasarkan karakteristik distribusi warna batch selama pre-training berlangsung.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada pemilik perkebunan perseorangan di lokasi Labuhan Batu Selatan atas dukungan fasilitas dan lingkungan penelitian yang kondusif selama berjalannya studi ini. Apresiasi khusus disampaikan kepada pihak STMIK dan dosen pembimbing yang telah memberikan bimbingan serta arahan selama proses penelitian berlangsung.

REFERENCES

- [1] "Kelapa Sawit Sebagai Pahlawan Devisa Indonesia - Beranda." Accessed: Dec. 21, 2025. [Online]. Available: <https://www.bpdp.or.id/kelapa-sawit-sebagai-pahlawan-devisa-indonesia>
- [2] Ministry of Agriculture, "Palm Oil Outlook," pp. 1–23, 2024.
- [3] D. R. Sulistyaningrum, M. A. Azahari, B. Setiyono, and D. Adzkya, *Identification of the Maturity Level of Oil Palm Fruit Using a Combination of the You Only Look Once Version 8 Model and Convolutional Neural Network*, vol. 2024, no. Ictaff 2024.

- Atlantis Press International BV, 2025. doi: 10.2991/978-94-6463-825-7_13.
- [4] A. W. Setiawan, "Palm Oil Fresh Fruit Bunch Grading System Using Multispectral Image Analysis in HSV," pp. 85–88, 2020.
 - [5] Afrisawati, "Pemilihan buah kelapa sawit unggul untuk dijadikan cpo menggunakan metode mfep di pks sei mangkei ptn iv," *J. Sci. Soc. Res.*, vol. 4307, no. 1, pp. 52–56, 2025.
 - [6] S. I. & Uyun, S. Guslianto, "Klasifikasi Kematangan Buah Sawit Berdasarkan," vol. 9, no. 3, pp. 407–414, 2023.
 - [7] R. Triyogi, R. Magdalena, and B. Hidayat, "Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolution Neural Network Deep Learning," vol. 1, no. 1, pp. 22–27, 2023.
 - [8] X. Zhou, X. Hu, and J. Sun, "A review of fruit ripeness recognition methods based on deep learning," *Cyber-Physical Syst.*, vol. 11, no. 4, pp. 508–542, Oct. 2025, doi: 10.1080/23335777.2025.2467639;WGROU:STRING:PUBLICATION.
 - [9] S. Sornapudi and R. Singh, "Self-Supervised Backbone Framework for Diverse Agricultural Vision Tasks," 2024, [Online]. Available: <http://arxiv.org/abs/2403.15248>
 - [10] J. Zulkamain and T. Hidayat, "Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan Deep Learning," vol. 12, no. 3, pp. 748–758, 2023.
 - [11] S. Nur *et al.*, "Image Detection and Classification of Oil Palm Fruit Bunches," pp. 108–113, 2022.
 - [12] H. Li *et al.*, "An improved YOLOv5s model for assessing apple graspability in automated harvesting scene," *Front. Plant Sci.*, vol. 14, no. December, pp. 1–15, 2023, doi: 10.3389/fpls.2023.1323453.
 - [13] J. Li *et al.*, "Label-efficient learning in agriculture: A comprehensive review," *Comput. Electron. Agric.*, vol. 215, p. 108412, Dec. 2023, doi: 10.1016/J.COMPAG.2023.108412.
 - [14] T. Chen, S. Kornblith, M. Norouzi, and G. Hinton, "A Simple Framework for Contrastive Learning of Visual Representations," no. Figure 1, 2019.
 - [15] S. Bunyang *et al.*, "Self-supervised learning advanced plant disease image classification with SimCLR," *Adv. Comput. Intell.* 2023 35, vol. 3, no. 5, pp. 18-, Oct. 2023, doi: 10.1007/S43674-023-00065-Z.
 - [16] L. A. Varga, H. Frank, and A. Zell, "Self-supervised Pretraining for Hyperspectral Classification of Fruit Ripeness," pp. 97–108.
 - [17] S. Zini, A. Gomez-villa, M. Buzzelli, and M. Bicocca, "Planckian Jitter : countering the color-crippling effects of color jitter on self-supervised training," vol. 1, pp. 1–15.
 - [18] M. Haziq, I. Azmi, F. H. Hashim, A. B. Huddin, and M. S. Sajab, "Correlation Study between the Organic Compounds and Ripening Stages of Oil Palm Fruitlets Based on the Raman Spectra," 2022.
 - [19] R. Nasirly, F. Arsy, and R. Qolby, "Comparison of Machine Learning Algorithms for Palm Oil Fresh Fruit Bunch (FFB) Ripeness," vol. 69, no. 1, pp. 39–48, 2025.
 - [20] S. Zolfagharnassab, A. Rashid, B. Mohamed, R. Ehsani, H. Z. Jaafar, and I. Bin Aris, "Classification of Oil Palm Fresh Fruit Bunches Based on Their Maturity Using Thermal Imaging Technique," pp. 1–20, 2022.
 - [21] M. L. Marszalek, B. Le Saux, P. P. Mathieu, A. Nowakowski, and D. Springer, "Self-Supervised Learning - a Way To Minimize Time and Effort for Precision Agriculture?," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 43, no. B3-2022, pp. 1327–1333, 2022, doi: 10.5194/isprs-archives-XLIII-B3-2022-1327-2022.
 - [22] V. Margapuri and M. Neilsen, "Classification of Seeds using Domain Randomization on Self-Supervised Learning Frameworks," *2021 IEEE Symp. Ser. Comput. Intell. SSCI 2021 - Proc.*, 2021, doi: 10.1109/SSCI50451.2021.9659998.
 - [23] K. Nguyen, Y. Nguyen, and B. Le, "Semi-Supervised Learning, Transfer Learning, and Knowledge Distillation with SimCLR," 2021, [Online]. Available: <http://arxiv.org/abs/2108.00587>
 - [24] J. Y. Goh, Y. Md Yunos, and M. S. Mohamed Ali, "Fresh Fruit Bunch Ripeness Classification Methods: A Review," *Food Bioprocess Technol.*, vol. 18, no. 1, pp. 183–206, 2025, doi: 10.1007/s11947-024-03483-0.