

Klasifikasi Pencahayaan Citra Menggunakan Statistik Histogram dan Pembelajaran Mesin

Muhammad Habibi Husni - 13521169

Program Studi Teknik Informatika
Sekolah Teknik Elektro dan Informatika
Institut Teknologi Bandung, Jalan Ganesha 10 Bandung
E-mail: habibihusni18@gmail.com

Abstrak—Pengolahan citra dan kecerdasan buatan (AI) memiliki peran penting dalam meningkatkan kualitas gambar di berbagai aplikasi, seperti fotografi, keamanan, dan sistem rumah pintar. Salah satu tantangan utama dalam pengolahan citra adalah pencahayaan, yang dapat memengaruhi kualitas visual gambar. Penelitian ini mengusulkan model pembelajaran mesin untuk mengklasifikasikan tingkat pencahayaan citra ke dalam kategori seperti sangat gelap, gelap, normal, terang, dan sangat terang. Model ini memanfaatkan statistik histogram citra untuk menilai distribusi intensitas pixel dan menentukan tingkat pencahayaan. Model ini diharapkan dapat diterapkan dalam berbagai bidang, seperti pengaturan eksposur otomatis pada kamera, deteksi area dengan pencahayaan buruk dalam sistem pengawasan, dan penyesuaian pencahayaan pada perangkat pintar. Penelitian ini bertujuan untuk mengembangkan model yang efisien dan akurat dalam mengklasifikasikan pencahayaan citra untuk meningkatkan kualitas aplikasi berbasis citra.

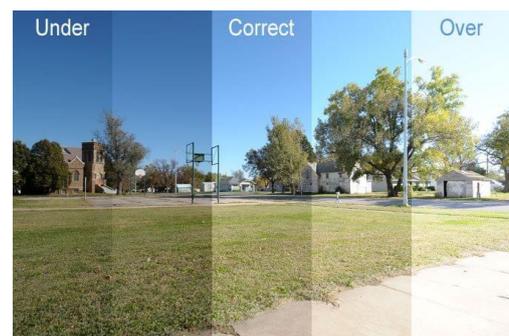
Kata kunci—Citra, Cahaya, Klasifikasi, Pembelajaran mesin, Histogram

I. PENDAHULUAN

Perkembangan teknologi pengolahan citra dan kecerdasan buatan (AI) dalam beberapa tahun terakhir telah membawa dampak signifikan pada berbagai sektor kehidupan, seperti fotografi, keamanan, dan interaksi manusia-komputer. Salah satu faktor penting yang memengaruhi kualitas gambar adalah pencahayaan. Pencahayaan yang buruk dapat menyebabkan gambar menjadi terlalu gelap atau terlalu terang, sehingga mengurangi kualitas visual dan informasi yang terkandung di dalamnya. Oleh karena itu, kemampuan untuk menilai dan mengklasifikasikan tingkat pencahayaan dalam sebuah gambar menjadi sangat penting, terutama dalam konteks aplikasi berbasis komputer dan perangkat pintar.

Pengklasifikasian tingkat cahaya citra seperti, sangat gelap, normal, dan sangat terang, memiliki potensi besar dalam berbagai bidang aplikasi. Di dunia fotografi, model ini dapat membantu kamera dalam mengatur eksposur secara otomatis, memastikan hasil foto yang lebih baik tanpa perlu pengaturan manual. Selain itu, dalam sistem keamanan dan pengawasan, model ini dapat digunakan untuk mendeteksi area dengan pencahayaan yang kurang atau berlebihan, yang bisa memengaruhi efektivitas pemantauan. Dalam bidang rumah pintar dan aplikasi yang berhubungan dengan pengalaman

pengguna, pengklasifikasian tingkat pencahayaan juga dapat dimanfaatkan untuk menyesuaikan pencahayaan secara otomatis untuk kenyamanan pengguna.



Gambar I.1 Perbandingan Citra dengan Berbagai Tingkat Pencahayaan

(Sumber: <https://www.studiobinder.com/blog/what-is-overexposure-in-photography/>)

Meskipun demikian, penerapan model pembelajaran mesin untuk mengklasifikasikan tingkat pencahayaan gambar masih tergolong jarang dibahas dalam literatur yang ada. Sebagian besar penelitian lebih berfokus pada pengolahan gambar secara umum atau peningkatan kualitas citra tanpa memandang konteks pencahayaan secara spesifik. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model pembelajaran mesin yang mampu mengklasifikasikan tingkat pencahayaan pada gambar secara akurat dan efisien. Diharapkan, model ini dapat memberikan kontribusi signifikan dalam meningkatkan aplikasi-aplikasi berbasis citra, khususnya yang berkaitan dengan penyesuaian pencahayaan dan pengolahan gambar.

II. LANDASAN TEORI

A. Citra Digital

Citra adalah sebuah media visual dari objek di dunia nyata yang diakuisisi dan disimpan dalam media tertentu. Salah satunya adalah penyimpanan digital. Pada citra digital, citra direpresentasikan dalam bidang dua dimensi, dengan nilai pada koordinat tertentu bersifat diskrit dan menunjukkan intensitas dari bagian citra tersebut. Komponen ini disebut sebagai *pixel*. Pada citra hitam putih, setiap *pixel* terdiri dari nilai keabu-

abuan yang menunjukkan intensitas cahaya pada titik tersebut. Sedangkan pada citra berwarna, setiap *pixel* terdiri dari tiga kanal berbeda, yang mendeskripsikan warna pada *pixel* tersebut.

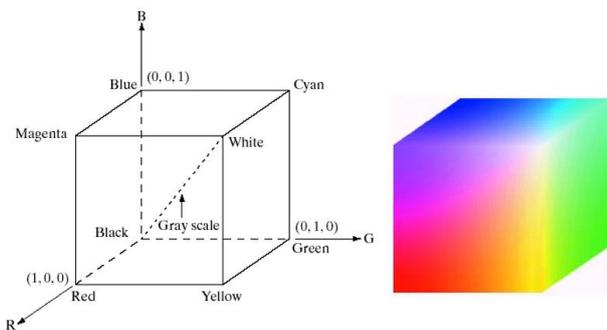
Proses akuisisi citra digital pada umumnya dilakukan melalui perangkat keras seperti kamera digital atau alat pemindai yang dapat mengubah informasi visual dunia nyata menjadi data diskrit yang dapat disimpan dan diolah oleh komputer. Citra digital yang dihasilkan akan berbentuk larik dua dimensi dengan ukuran tertentu, yang disebut sebagai resolusi. Pada citra digital, resolusi yang lebih tinggi menunjukkan *pixel* yang lebih banyak sehingga semakin besar resolusi citra maka akan lebih banyak pula informasi yang diberikan oleh citra tersebut.

B. Ruang Warna

Warna merupakan nilai gelombang yang dapat diterima sistem visual manusia dari dampak pantulan cahaya yang jatuh pada suatu permukaan. Dalam dunia nyata, panjang gelombang warna tampak adalah dari 400 nm (biru) sampai 700 nm (merah). Dalam citra digital, warna dideskripsikan melalui berbagai definisi ruang warna yaitu sebagai berikut.

1) RGB (Red-Green-Blue)

Penelitian memperlihatkan bahwa kombinasi warna yang memberikan rentang warna paling lebar adalah *red* (R), *green* (G), dan *blue* (B). Ketiga warna ini disebut sebagai warna pokok dan digunakan dalam berbagai media. Kombinasi dari komponen ini dapat menghasilkan seluruh warna tampak di dunia nyata. Ketiga warna ini didefinisikan dengan nilai gelombang 700 nm untuk merah, 546.1 nm untuk hijau, dan 435.8 nm untuk warna biru. Model warna RGB digunakan untuk *display* pada layar komputer. Model warna ini bersifat *subtracting*.

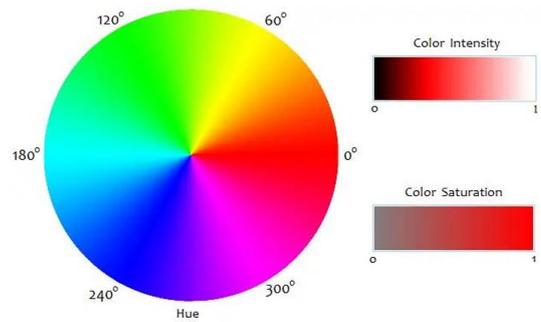


Gambar II.1 Ruang Warna RGB (Sumber: Materi Kuliah)

2) HSI

Merupakan ruang warna yang dibentuk untuk mendeskripsikan warna dengan lebih lazim sesuai persepsi manusia terhadap warna. Manusia mendeskripsikan warna dengan tiga atribut. Pertama adalah *hue* (H), yang menunjukkan warna sebenarnya seperti merah, ungu atau hijau. Kedua adalah *saturation* (S) yang menunjukkan seberapa pekat warna tersebut, dengan nilai *saturation* bernilai 1 menunjukkan warna yang pekat, dan nilai 0 menunjukkan warna tanpa *hue* atau warna putih, dan *intensity* (I) menunjukkan banyaknya cahaya yang diterima pada warna tersebut. Dengan *intensity* bernilai 0

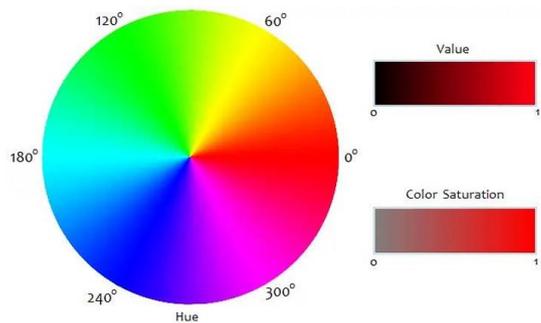
menunjukkan warna hitam, dan *intensity* bernilai 1 menunjukkan warna putih.



Gambar II.2 Ruang Warna HSL (Sumber: Materi Kuliah)

3) HSV

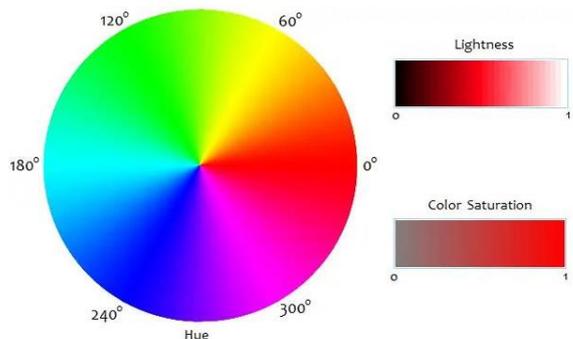
HSV merupakan variasi dari ruang warna HSL, terdiri dari dua komponen yang sama yaitu *hue* (H) dan *saturation* (S), dengan komponen ketiganya adalah *value* (V). *Value* menunjukkan kecerahan sebuah warna dengan rentang [0, 1].



Gambar II.3 Ruang Warna HSV (Sumber: Materi Kuliah)

4) HSL

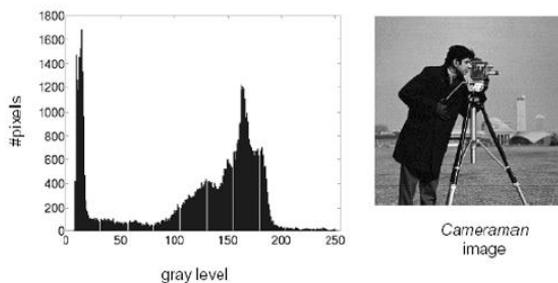
Merupakan variasi dari ruang warna HSI, yaitu dengan deskripsi komponen *hue* dan *saturation* yang sama, namun komponen ketiga dideskripsikan sebagai *lightness* (L). *Lightness* menggambarkan seberapa terang atau gelap suatu warna. Yang menjadi perbedaan dengan komponen *intensity* (I) pada HSI adalah warna murni ditunjukkan dengan nilai *lightness* sebesar 50%.



Gambar II.4 Ruang Warna HSL (Sumber: Materi Kuliah)

C. Histogram Citra

Histogram citra adalah representasi visual dari distribusi intensitas pixel dalam sebuah citra, yang menunjukkan jumlah pixel untuk setiap tingkat kecerahan atau grayvalue tertentu. Setiap sumbu horizontal pada histogram mewakili nilai grayvalue, mulai dari nilai terendah (biasanya 0, yang mewakili hitam) hingga nilai tertinggi (biasanya 255, yang mewakili putih pada citra hitam putih). Sumbu vertikal menunjukkan frekuensi atau jumlah pixel yang memiliki nilai grayvalue tertentu. Histogram ini berguna dalam berbagai aplikasi pengolahan citra, seperti analisis kontras, deteksi pencahayaan, dan penyesuaian eksposur, serta dapat membantu dalam proses pemrosesan citra, seperti peningkatan kontras atau segmentasi, dengan memberikan gambaran jelas tentang distribusi pencahayaan pada citra tersebut.



Gambar II.5 Histogram Citra (Sumber: Materi Kuliah)

D. Entropi

Dalam teori informasi, jumlah informasi di dalam sebuah pesan didefinisikan sebagai jumlah bit yang dibutuhkan untuk melakukan *encoding* pesan. Contohnya adalah untuk mendeskripsikan jenis kelamin, cukup memerlukan 1 bit saja yaitu misalnya 0 untuk pria, dan 1 untuk wanita. Hal ini disebut sebagai entropi. Entropi berfungsi untuk memperkirakan jumlah bit rata-rata untuk mengkodekan sebuah elemen pada pesan. Nilai entropi yang tinggi menunjukkan informasi yang lebih variatif dan sebaliknya nilai entropi yang rendah menunjukkan informasi yang sederhana. Berikut adalah persamaan untuk menghitung entropi.

$$H(X) = -\sum_{i=1}^n p_i \log(p_i)$$

dengan p_i menunjukkan peluang munculnya elemen ke- i .

E. Pembelajaran Mesin

Pembelajaran mesin atau *machine learning* merupakan cabang dari kecerdasan buatan yang memungkinkan komputer untuk berpikir dan belajar dengan menyesuaikan tindakan yang diambil guna meningkatkan akurasi. Dalam praktiknya, model pembelajaran mesin sangat terkait dengan statistik komputasi dan optimasi matematika yang menghubungkan model tersebut dengan data statistik. Metode ini telah diterapkan dalam berbagai bidang, seperti deteksi penipuan, pengenalan wajah,

pengenalan karakter, rekomendasi produk, dan prediksi lalu lintas. Berbagai algoritma atau model pembelajaran mesin adalah sebagai berikut.

1) Logistic Regression

Logistic regression adalah sebuah mode yang bertujuan untuk menemukan bentuk garis pembagi logistik yang paling ideal dalam tugas klasifikasi biner.

2) Decision Tree

Yaitu sebuah algoritma pembelajaran mesin yang digunakan untuk permasalahan pengklasifikasian. Algoritma ini bekerja dengan melakukan *decision* berurutan untuk membagi kolom kategorikal maupun numerical

3) Random Forest

Merupakan model yang terdiri dari beberapa *decision tree*. Untuk melakukan pengklasifikasian, model ini akan melakukan sistem *voting* terhadap seluruh *decision tree* dan memakai nilai *voting* terbanyak untuk menentukan klasifikasi. *Decision tree* pada model ini melakukan pertumbuhan dengan algoritma tertentu.

4) Support Vector Machine (SVM)

SVM adalah model pembelajaran mesin yang memetakan fitur input ke dalam ruang n -dimensi. Lalu model ini menentukan garis terbaik untuk membagi seluruh kelas pada ruang ini.

III. PEMBAHASAN

Pada bab ini akan dijelaskan tahap-tahap pembentukan solusi, mulai dari pengumpulan data, ekstraksi fitur, seleksi fitur, pemilihan model, *parameter tuning*, pelatihan model, dan pengujian.

A. Pengumpulan Data

Karena tidak banyak penelitian yang membahas topik ini, dataset yang didesain secara khusus untuk melakukan klasifikasi tingkat cahaya sulit untuk ditemukan. Oleh karena itu, pada penelitian ini menggunakan dataset citra umum yang memiliki beragam tipe citra, seperti citra pemandangan, citra perkotaan, dan lain-lain. Dataset yang digunakan pada penelitian ini adalah *Stanford Background Dataset*. Lalu, dilakukan *preprocessing* untuk menghasilkan berbagai citra dengan berbagai tingkat pencahayaan dengan metode sintetik. Untuk membantu pemrosesan tersebut, digunakan kelas *ImageEnhancement.Brightness* yang disediakan oleh *library Pillow*. Kelas ini dapat merubah tingkat pencahayaan melalui sebuah masukan rasio, dengan rasio 1.0 mengembalikan citra asli, rasio < 1.0 mengembalikan citra dengan cahaya yang lebih redup, dan rasio > 1.0 mengembalikan citra dengan cahaya yang lebih terang. Dengan penggunaan model ini, tingkat pencahayaan pada dataset dapat didefinisikan secara diskrit. Untuk jangkauan tingkat pencahayaan, digunakan persamaan kuadrat untuk menghasilkan tingkat pencahayaan dengan perbedaan yang jelas. Pada penelitian ini, didefinisikan lima kelas tingkat pencahayaan yaitu, sangat gelap, gelap, normal, terang, dan sangat terang.

```
factor = [0.0,0.4,0.8,1.2,1.6,2.0]
light_level = [i**2 for i in factor] # persamaan kuadrat
print(light_level)
#[0.0, 0.16000000000000003, 0.6400000000000001, 1.44, 2.5600000000000005, 4.0]
label = ['very_dark', 'dark', 'normal', 'bright', 'very_bright']
```

B. Ekstraksi Fitur

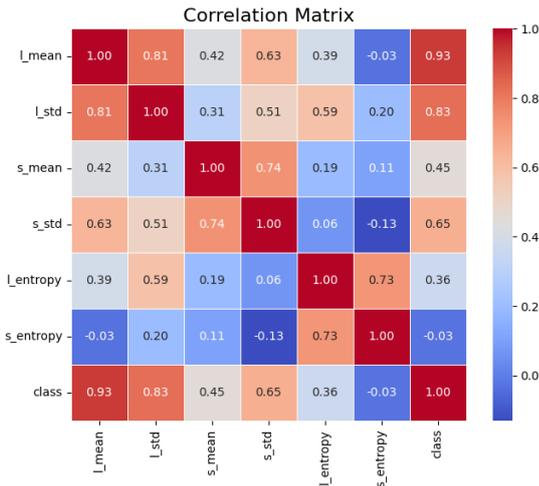
Selanjutnya, dilakukan perolehan fitur yang deskriptif untuk permasalahan penelitian ini. Untuk Langkah awal, fitur diambil dari statistik dari histogram citra. Pada penelitian ini, statistik yang diambil adalah rata-rata, standar deviasi, dan entropi. Statistik ini diambil dari komponen S dan L pada citra dengan ruang warna HSL. Komponen ini diambil karena karakteristik citra cahaya rendah yang memiliki tingkat pencahayaan yang rendah, serta warna yang pudar.

L_mean	L_std	S_mean	S_std	L_entropy	S_entropy	class
3.56	1.63	94.11	57.25	2.51	2.99	0
4.95	2.07	90.81	54.56	2.73	3.24	0
10.79	4.14	83.86	45.45	3.67	4.92	0
38.45	14.52	79.41	39.61	5.39	6.39	1
63.13	23.64	78.78	38.92	6.04	6.62	1

C. Seleksi Fitur

Untuk pemilihan fitur yang tepat, perlu dilakukan analisis statistik terhadap seluruh fitur. Berikut adalah hasil analisis statistik fitur beserta matriks korelasinya.

	L_mean	L_std	S_mean	S_std	L_entropy	S_entropy	class
count	10725.000000	10725.000000	10725.000000	10725.000000	10725.000000	10725.000000	10725.000000
mean	112.611061	48.010473	55.329689	54.601122	6.257184	5.675361	2.000000
std	61.926307	24.066265	34.230668	25.567127	1.198200	1.090381	1.414279
min	0.000000	0.000000	0.000000	0.000000	-0.000000	-0.000000	0.000000
25%	59.391078	28.368009	30.562617	33.452710	5.722302	5.188562	1.000000
50%	118.148398	52.549106	47.109388	50.845051	6.567944	5.869378	2.000000
75%	165.391641	67.452388	71.039344	74.471282	7.125758	6.418549	3.000000
max	247.350000	112.481405	235.252088	125.721086	7.842582	7.692869	4.000000



Berdasarkan hasil analisis statistik di atas, dapat dilihat bahwa seluruh fitur memiliki korelasi yang cukup kuat terhadap kelas target, dengan pengecualian pada fitur entropi komponen S. Oleh karena itu, fitur yang digunakan pada penelitian ini adalah rata-rata dan standar deviasi komponen L beserta rata-rata, standar deviasi, dan entropi komponen L.

D. Pemilihan Model

Selanjutnya dilakukan eksperimen pemilihan model pembelajaran mesin yang memberikan kinerja yang paling baik secara umum. Proses ini dilakukan dengan pelatihan dan pengujian berbagai model pembelajaran mesin tanpa parameter tambahan dan menggunakan akurasi sebagai metrik kinerjanya. Pada penelitian ini, model-model yang diujikan adalah *logistic regression*, *decision tree classifier*, *random forest classifier*, dan *SVM* yang disediakan oleh *library* scikit learn. Setelah dilakukan pengujian, ditemukan hasil akurasi model sebagai berikut.

```
Model Performance:
Logistic Regression: 0.77
Decision Tree Classifier: 0.75
Random Forest Classifier: 0.82
Support Vector Machine: 0.78
```

Pada hasil di atas, dapat dilihat model dengan kinerja terbaik adalah random forest classifier sebesar 82%. Maka, untuk penelitian ini diputuskan untuk menggunakan model *random forest classifier*.

E. Parameter Tuning

Untuk memperoleh kinerja paling maksimal dari sebuah model, diperlukan penentuan parameter yang tepat. Pada penelitian ini, pencarian parameter dilakukan menggunakan *grid search* atau pencarian terhadap kemungkinan parameter yang didefinisikan.

```
rf = RandomForestClassifier(random_state=42)

param_grid = {
    'n_estimators': [50, 100, 200], # Banyak tree
    'max_features': ['sqrt', 'log2'], # Banyak fitur yang dipertimbangkan
    'min_samples_split': [2, 5, 10], # Sampel minimum untuk split node
    'min_samples_leaf': [1, 2, 4], # Sampel minimum untuk menjadi node daun
    'max_depth': [None, 10, 20] # Kedalaman maksimum tree
}

grid_search = GridSearchCV(
    estimator=rf,
    param_grid=param_grid,
    scoring='accuracy', # Menggunakan akurasi sebagai metrik
    cv=5, # 5-fold cross-validation
    verbose=2, # Tampilkan proses
    n_jobs=-1 # Menggunakan seluruh core cpu
)

grid_search.fit(X_train, y_train)

# menampilkan parameter terbaik
print("Best parameters found:", grid_search.best_params_)
print("Best cross-validated accuracy:", grid_search.best_score_)
```

Setelah algoritma dijalankan, ditemukan parameter terbaik adalah sebagai berikut.

```
Best parameters found: {'max_depth': 20, 'max_features': 'sqrt',
'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 100}
Best cross-validated accuracy: 0.8134032634032635
```

F. Pelatihan Model

Berdasarkan parameter yang ditemukan, selanjutnya adalah melakukan pelatihan model.

```

scaler = StandardScaler()
scaler.fit(X)
X = scaler.transform(X)

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

rf = RandomForestClassifier(
    random_state=42,
    max_features='sqrt',
    min_samples_leaf=1,
    min_samples_split=2,
    max_depth=20,
    n_estimators=100)

rf.fit(X_train, y_train)
y_pred = rf.predict(X_test)

# Evaluasi model
print("\nClassification Report:")
print(classification_report(y_test, y_pred))

```

G. Pengujian

Pengujian yang dilakukan adalah dengan melakukan pengujian terhadap data test yang sudah di-split sebelum dilakukan pelatihan. Berikut adalah hasil evaluasi model dalam metrik akurasi, precision, recall, dan f1-score.

```

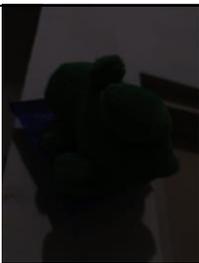
Classification Report:
precision    recall  f1-score   support

 0         0.95     0.96     0.96     426
 1         0.90     0.87     0.89     459
 2         0.76     0.77     0.76     429
 3         0.68     0.65     0.67     421
 4         0.78     0.82     0.80     410

 accuracy                   0.82     2145
 macro avg          0.81     0.81     0.81     2145
 weighted avg       0.82     0.82     0.82     2145

```

Berdasarkan data di atas, model yang telah dilatih memiliki akurasi sebesar 82% dengan nilai f1-score yang cukup tinggi pada kelas 0 (sangat gelap) dan 1 (gelap), namun mengalami penurunan skor pada kelas 3 (terang) dan 4 (sangat terang) terutama kelas 3. Hal ini menunjukkan model masih kesulitan dalam membedakan citra “terang” dari citra “normal” dan “sangat terang”. Selain pengujian pada data pengujian dari dataset, juga dilakukan pengujian terhadap citra yang diambil secara manual dengan menggunakan *smartphone* dengan berbagai tingkat ISO.

Citra	ISO	Klasifikasi
	100	Sangat gelap

	400	Gelap
	1000	Normal
	2000	Normal
	5000	Sangat Terang

IV. KESIMPULAN

Penggunaan model pembelajaran mesin, khususnya random forest classifier, dan fitur berbasis statistik histogram citra telah menunjukkan efektivitas yang cukup baik dalam mengklasifikasikan citra dengan tingkat kecerahan yang bervariasi, seperti sangat gelap, gelap, normal, terang, dan sangat terang. Hasilnya menunjukkan bahwa model ini mampu mengenali pola-pola yang kompleks dalam data citra, sehingga memberikan akurasi yang memadai pada sebagian besar kategori tersebut. Namun, model ini masih menghadapi tantangan dalam menentukan ambang batas yang tepat untuk mengklasifikasikan citra dengan cahaya terang dibandingkan kategori lainnya. Hal ini mengindikasikan perlunya penyempurnaan lebih lanjut, baik dalam pemilihan fitur maupun pengoptimalan parameter model, agar kinerjanya

dapat ditingkatkan dalam menangani kategori citra yang lebih sulit.

LINK GITHUB

<https://github.com/habibibi/makalah-if4073>

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Tuhan Yang Maha Esa atas nikmat dan berkah yang telah diberikan sehingga penulis mampu menyelesaikan tugas ini dengan lancar dan baik. Penulis juga mengucapkan rasa terima kasih yang besar kepada Pak Rinaldi Munir selaku dosen mata kuliah Pemrosesan Citra Digital yang telah banyak membimbing dan memberikan berbagai ilmu dalam mata kuliah ini.

REFERENCES

- [1] <https://informatika.stei.itb.ac.id/~rinaldi.munir/Citra/2024-2025/16-Warna-bagian1-2024.pdf>. Diakses pada 15 Januari 2025
- [2] <https://informatika.stei.itb.ac.id/~rinaldi.munir/Citra/2024-2025/16-Warna-bagian1-2024.pdf>. Diakses pada 15 Januari 2025
- [3] <https://informatika.stei.itb.ac.id/~rinaldi.munir/Citra/2024-2025/06-Image-Histogram-2024.pdf>. Diakses pada 15 Januari 2025

- [4] <https://informatika.stei.itb.ac.id/~rinaldi.munir/Citra/2024-2025/25-Image-Compression-Bagian1-2024.pdf>. Diakses pada 15 Januari 2025
- [5] Rafael C. Gonzales, & Richard E. Woods (2008). Digital Image Processing (4th ed.). Pearson.
- [6] <https://www.simplilearn.com/10-algorithms-machine-learning-engineers-need-to-know-article>. Diakses pada 15 Januari 2025

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, 15 Januari 2024



Muhammad Habibi Husni (13521169)