



## DeepSun: Klasifikasi Fase Cahaya Matahari Berdasarkan Warna Menggunakan CNN

Warnia Nengsih<sup>1</sup>, Juni Nurma Sari<sup>2</sup>, Cici Angresta<sup>3</sup>, Hasna Fikriyah Dwinas<sup>4</sup>

<sup>1,3,4</sup>Studi Informatika, Politeknik Caltex Riau, Pekanbaru, Indonesia

<sup>2</sup>Magister Terapan Teknik Komputer, Politeknik Caltex Riau, Pekanbaru, Indonesia

<sup>1</sup>\*warnia@pcr.ac.id, <sup>2</sup>juni@pcr.ac.id, <sup>3</sup>ciciangresta@gmail.com, <sup>4</sup>hasnafikriyah@gmail.com

\*Corresponding Author

Diserahkan: 18 Oktober 2023

Diterima: 10 November 2023

Diterbitkan: 10 Desember 2023

### ABSTRAK

Penelitian ini berbasis metode DeepSun, sebuah sistem yang menggunakan Jaringan Syaraf Tiruan Konvolusi (CNN) untuk mengklasifikasikan fase cahaya matahari berdasarkan warna. Fase cahaya seperti Golden Hour, Blue Hour, dan Pink Hour memiliki karakteristik visual yang khas, dan mengidentifikasi fase cahaya ini secara otomatis dapat memberikan pemahaman yang lebih baik tentang suasana dan estetika suatu gambar. Pendekatan yang diusulkan menggunakan dataset yang terdiri dari gambar-gambar yang dikumpulkan selama berbagai kondisi cahaya matahari. Data tersebut dianotasi dengan label fase cahaya yang sesuai. CNN digunakan untuk mengekstraksi fitur-fitur penting dari gambar-gambar ini. Kemudian, fitur-fitur tersebut digunakan sebagai input untuk pengklasifikasi yang dilatih menggunakan algoritma pembelajaran mesin. Eksperimen dilakukan untuk mengevaluasi kinerja sistem DeepSun. Hasil-hasil yang diperoleh menunjukkan bahwa sistem ini mampu mengklasifikasikan fase cahaya matahari dengan tingkat akurasi yang tinggi. Kesalahan klasifikasi terutama terjadi saat kondisi cahaya yang sangat mirip antara fase-fase tertentu. Namun, dengan meningkatkan jumlah data latih dan peningkatan arsitektur CNN, tingkat akurasi dapat ditingkatkan lebih lanjut. Hasil loss dan accuracy menggunakan 50 epoch untuk mengetahui bagaimana bentuk akurasi dan nilai loss model data yang telah melalui data training dan data validation dengan nilai akurasi data keseluruhan sebesar 96%. Dengan kemampuan untuk mengklasifikasikan fase cahaya matahari secara otomatis, DeepSun dapat membantu pengguna untuk memilih waktu yang tepat dalam mengambil gambar yang berkualitas.

**Kata Kunci :** DeepSun, klasifikasi fase cahaya matahari, warna, CNN

### ABSTRACT

The research is based on the DeepSun method, a system that uses Convolution Artificial Neural Networks (CNNs) to classify the phases of sunlight by color. Light phases such as the Golden Hour, Blue Hour, and Pink Hour have distinctive visual characteristics, and identifying these light phases automatically can provide a better understanding of the mood and aesthetics of an image. The proposed approach uses a dataset consisting of images collected during various sunlight conditions. The data is annotated with the appropriate light phase label. CNNs are used to extract important features from these images. Then, those features are used as inputs for classifiers trained using machine learning algorithms. Experiments were conducted to evaluate the performance of the DeepSun system. The results obtained show that this system is able to classify the phases of sunlight with a high degree of

*accuracy. Misclassification mainly occurs when light conditions are very similar between certain phases. However, by increasing the amount of training data and improving the CNN architecture, the accuracy rate can be further improved. With the ability to classify the phases of sunlight. With the ability to classify the phases of sunlight automatically, DeepSun can help users to choose the right time to take quality pictures. In addition, the system can also be used to improve automatic image processing and editing based on the desired light phase.*

**Keywords:** *DeepSun, phase classification of sunlight, color, CNN*

## 1. PENDAHULUAN

Fase cahaya matahari adalah istilah yang digunakan untuk menggambarkan kondisi pencahayaan matahari pada suatu lokasi tertentu sepanjang hari. Pada dasarnya, fase cahaya matahari melibatkan perubahan pencahayaan dan bayangan yang dihasilkan oleh posisi matahari di langit. Fase cahaya matahari, seperti *Golden Hour*, *Blue Hour*, dan *Pink Hour*, merupakan periode waktu yang memiliki karakteristik warna yang khas. Keberhasilan dalam mengidentifikasi fase cahaya ini dapat memberikan pemahaman yang lebih baik tentang kondisi cahaya yang mempengaruhi estetika gambar dan memungkinkan fotografer dan pengguna lainnya untuk mengambil foto dengan hasil yang lebih baik.

Meskipun manusia dapat secara intuitif mengenali dan membedakan fase-fase cahaya ini, namun klasifikasi fase cahaya matahari secara otomatis tetap merupakan tantangan. Ini karena perbedaan subtil dalam warna dan intensitas cahaya yang mempengaruhi pengenalan fase cahaya tersebut. Oleh karena itu, pengembangan sebuah sistem yang dapat secara akurat mengklasifikasikan fase cahaya matahari berdasarkan warna menjadi penting.

Metode Deep Learning, terutama Convolutional Neural Networks (CNN), telah menunjukkan keunggulannya dalam pengolahan citra dan pengenalan pola. CNN mampu secara otomatis mengekstraksi fitur-fitur yang penting dari citra, yang dapat digunakan untuk klasifikasi. Dengan memanfaatkan kekuatan CNN, kita dapat mengembangkan sebuah sistem yang mampu mengklasifikasikan fase cahaya matahari berdasarkan warna dengan tingkat akurasi yang tinggi[1],[2].

Penelitian sebelumnya telah mencoba menggunakan metode-metode tradisional untuk mengklasifikasikan fase cahaya matahari. "The long-term variation of solar activity" oleh Yeo, K. L., Solanki, S. K., & Norris, C. yang diterbitkan dalam jurnal *Astronomy & Astrophysics*, mengkaji variasi jangka panjang dalam aktivitas matahari. Dalam artikel ini, para peneliti menganalisis data observasi matahari yang mencakup periode waktu yang panjang untuk memahami pola perubahan dalam aktivitas matahari selama ribuan tahun. Namun, belum ada penelitian yang membahas kemampuan akurasi untuk menangani variasi warna dan intensitas cahaya yang kompleks. Oleh karena itu, penelitian ini bertujuan untuk mengatasi kendala-kendala tersebut dengan memanfaatkan kekuatan CNN dalam klasifikasi fase cahaya matahari berdasarkan warna. Dengan mengembangkan sistem DeepSun mampu mengklasifikasikan fase cahaya matahari secara otomatis.

## 2. LANDASAN TEORI

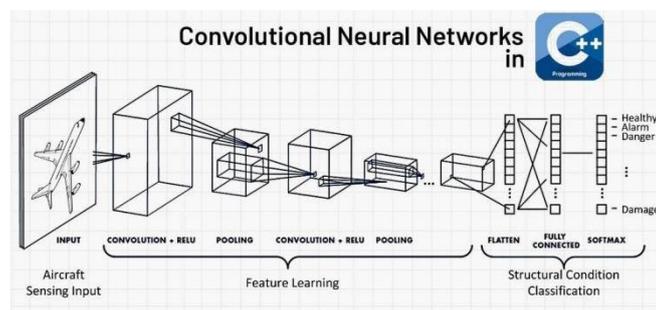
### 2.1 Convolutional Neural Networks (CNN)

CNN adalah jenis arsitektur jaringan saraf tiruan yang telah terbukti berhasil dalam pengolahan citra dan pengenalan pola. CNN terdiri dari lapisan-lapisan konvolusi dan lapisan-lapisan pemampatan, yang memungkinkan ekstraksi fitur secara hierarkis dari citra. Dalam konteks klasifikasi fase cahaya matahari berdasarkan warna, CNN dapat digunakan untuk mengekstraksi fitur-fitur penting dari citra yang berkaitan dengan warna dan intensitas Cahaya[3],[4].

Convolutional Neural Network (CNN) adalah jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data berupa citra dan pola spasial. CNN terdiri dari lapisan-lapisan konvolusi

dan lapisan-lapisan pemampatan (pooling), yang membantu dalam mengekstraksi fitur-fitur penting dari data input. Fitur kunci dari CNN adalah kemampuannya untuk melakukan konvolusi pada citra menggunakan berbagai filter untuk mendeteksi pola-pola visual seperti tepi, tekstur, atau bentuk. Filter ini dipelajari oleh jaringan secara otomatis selama proses pelatihan dan mampu menangkap fitur-fitur yang relevan dari citra. Selain konvolusi, CNN juga menggunakan lapisan pemampatan (pooling) untuk mengurangi dimensi spasial dari fitur yang dihasilkan, sehingga mengurangi jumlah parameter yang perlu dihitung dan menjaga invariansi terhadap translasi dalam citra[5].

Setelah melalui serangkaian lapisan konvolusi dan pemampatan, fitur-fitur yang dihasilkan akan disampel dan dikonversi menjadi representasi vektor menggunakan lapisan-lapisan terhubung penuh (fully connected layers). Lapisan-lapisan ini bertindak sebagai pengklasifikasi akhir yang menghubungkan fitur-fitur yang dihasilkan dengan kelas-kelas yang diinginkan.



**Gambar 1** Arsitektur Convolutional Neural Network

CNN memiliki keunggulan dalam kemampuannya untuk secara otomatis mengekstrak fitur-fitur penting dari data gambar tanpa memerlukan ekstraksi fitur manual.

## 2.2 Fase Cahaya Matahari

Fase cahaya matahari adalah periode waktu yang memiliki karakteristik warna dan intensitas cahaya yang khas. Golden Hour terjadi pada pagi hari dan menjelang matahari terbenam, di mana cahaya matahari memiliki warna keemasan yang hangat. Blue Hour terjadi di antara Golden Hour dan malam hari, di mana cahaya matahari memiliki warna biru keunguan. Pink Hour terjadi sesaat setelah matahari terbenam, di mana cahaya matahari memiliki warna merah muda yang lembut. Pengenalan fase cahaya ini dapat memberikan pemahaman yang lebih baik tentang kondisi cahaya yang mempengaruhi estetika gambar.

## 2.3 Klasifikasi Citra

Klasifikasi citra adalah tugas untuk mengelompokkan citra-citra ke dalam kategori-kategori yang telah ditentukan berdasarkan fitur-fitur yang relevan. Dalam konteks penelitian ini, klasifikasi citra digunakan untuk mengklasifikasikan fase cahaya matahari berdasarkan warna. CNN dapat digunakan sebagai alat yang kuat untuk mengekstraksi fitur-fitur penting dari citra dan mengklasifikasikannya ke dalam kategori-kategori yang diinginkan[6].

## 2.4 Ekstraksi Fitur

Pengolahan citra melibatkan serangkaian teknik dan algoritma untuk memanipulasi dan menganalisis citra. Dalam penelitian ini, pengolahan citra digunakan untuk mempersiapkan data latih dan data uji sebelum dimasukkan ke dalam model CNN. Ini termasuk normalisasi intensitas cahaya, transformasi warna, dan penerapan teknik pra-pemrosesan citra lainnya untuk memastikan konsistensi dan keberlanjutan dalam klasifikasi fase cahaya matahari[7].

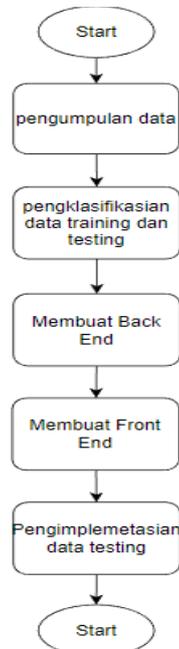
## 2.5 Pengolahan Citra

Pengolahan citra melibatkan serangkaian teknik dan algoritma untuk memanipulasi dan menganalisis citra. Dalam penelitian ini, pengolahan citra digunakan untuk mempersiapkan data latih dan data uji

sebelum dimasukkan ke dalam model CNN[8]. Ini termasuk normalisasi intensitas cahaya, transformasi warna, dan penerapan teknik pra-pemrosesan citra lainnya untuk memastikan konsistensi dan keberlanjutan dalam klasifikasi fase cahaya matahari.

### 3. METODE PENELITIAN

Berikut merupakan alur dari penelitian ini:



**Gambar 2 Metode Penelitian**

#### 3.1 Pengumpulan Data

Dataset yang digunakan berupa public dataset berupa gambar dari fase cahaya matahari untuk 3 fase yang sudah ditetapkan diantaranya fase Golden Hour, Blue Hour, Pink Hour sebanyak 300 dataset dengan rincian terdapat 3 label yang dimana setiap label memiliki 100 dataset. Data harus dianotasi dengan label fase cahaya yang sesuai. Data citra perlu dipersiapkan sebelum dimasukkan ke dalam model CNN. Langkah-langkah pra-pemrosesan termasuk normalisasi intensitas cahaya, penyesuaian ukuran dan resolusi citra, serta penerapan teknik pra-pemrosesan lainnya untuk meningkatkan kualitas dan konsistensi data.

#### 3.2 Pembagian Dataset

Dataset citra yang dikumpulkan perlu dibagi menjadi tiga subset: data latih (training set), data validasi (validation set), dan data uji (test set). Penentuan data training dan data testing menggunakan ratio perbandingan 70:30.

#### 3.3 Develop System Dari Sisi Back End Menggunakan Python

Langkah selanjutnya adalah merancang arsitektur CNN yang sesuai untuk tugas klasifikasi fase cahaya matahari berdasarkan warna. Arsitektur CNN harus terdiri dari lapisan-lapisan konvolusi, lapisan pemampatan, dan lapisan-lapisan terhubung penuh yang memadai untuk mengklasifikasikan fase cahaya.

#### 3.4 Develop System Dari Sisi Front End

Mendvelop system dari sisi tampilan (interface) meliputi data, dan hasil prediksi

### 3.5 Implementasi dan Pengujian Sistem

Model CNN harus dilatih menggunakan data latih. Pelatihan dilakukan dengan memberikan data latih ke model dan menyesuaikan parameter-parameter jaringan menggunakan algoritma pembelajaran mesin seperti backpropagation. Tujuan pelatihan adalah untuk mengoptimalkan fungsi kerugian dengan mengurangi kesalahan klasifikasi dan meningkatkan akurasi model. Selama pelatihan, validasi model dilakukan menggunakan data validasi yang terpisah dari data latih. Hal ini dilakukan untuk memonitor kinerja model dan mencegah overfitting (penyesuaian berlebihan) terhadap data latih.

Setelah pelatihan selesai, model CNN akan dievaluasi menggunakan data uji yang terpisah dari data latih dan data validasi[9],[10][11]. Performa model diukur dengan menggunakan metrik-metrik seperti akurasi, presisi, dan recall. Jika hasil evaluasi model memenuhi kriteria yang diinginkan, model dapat digunakan untuk klasifikasi fase cahaya matahari berdasarkan warna. Hasil klasifikasi yang diperoleh dari model CNN dievaluasi dan dianalisis. Analisis ini dapat mencakup perbandingan performa antara fase cahaya yang berbeda, identifikasi kesalahan klasifikasi yang umum, dan pemahaman tentang karakteristik visual yang mempengaruhi pengenalan fase cahaya[13],[14][15].

## 4. HASIL DAN PEMBAHASAN

Setelah langkah-langkah pra-pemrosesan dan pembangunan arsitektur CNN selesai, model CNN perlu dilatih menggunakan data latih dan divalidasi menggunakan data validasi. Selama pelatihan, parameter-model akan diperbarui berdasarkan hasil validasi untuk meningkatkan performa model. Setelah pelatihan selesai, model CNN yang telah dilatih perlu disimpan dalam format H5. Format H5 adalah format penyimpanan yang efisien dan mendukung struktur hierarkis untuk menyimpan data model. Ini memungkinkan kita untuk menyimpan semua parameter-model, arsitektur, dan konfigurasi lainnya dalam satu file. Selanjutnya melakukan serialisasi model CNN ke dalam format H5. Fungsi-fungsi ini akan mengumpulkan semua informasi yang diperlukan tentang model, termasuk bobot dan bias dari setiap lapisan, dan menyimpannya dalam file H5. Setelah model CNN disimpan dalam format H5, kita dapat menggunakan model tersebut untuk melakukan klasifikasi fase cahaya matahari berdasarkan warna pada data baru. Dalam bahasa pemrograman yang relevan, kita dapat mengimpor model H5 yang disimpan dan menggunakan fungsi-fungsi untuk memuat model dan melakukan prediksi pada citra-citra baru.

Menginisialisasi model CNN dengan arsitektur yang telah dirancang. Ini melibatkan pembuatan objek model menggunakan library seperti TensorFlow atau Keras, dan menambahkan lapisan-lapisan yang diperlukan, termasuk lapisan konvolusi. Setelah model CNN diinisialisasi, langkah selanjutnya adalah menentukan layer-layer mana yang akan dilatih. Setelah semua konfigurasi ditentukan, proses pelatihan dimulai dengan memberikan data latih ke model. Data latih terdiri dari citra-citra yang telah dikumpulkan dan dianotasi dengan fase cahaya matahari yang tepat. Proses pelatihan melibatkan penghitungan gradien dan pembaruan parameter-parameter dalam layer-layer yang dilatih menggunakan metode optimasi yang telah ditentukan.

```
[58] history = model.fit(train_generator,
                        validation_data=validation_generator,
                        epochs=50,
                        verbose=2)

34/34 - 12s - loss: 0.1183 - accuracy: 0.9704 - val_loss: 0.0293 - val_accuracy: 1.0000 - 12s/epoch - 364ms/step
Epoch 47/50
34/34 - 12s - loss: 0.4212 - accuracy: 0.8704 - val_loss: 0.0052 - val_accuracy: 1.0000 - 12s/epoch - 363ms/step
Epoch 48/50
34/34 - 12s - loss: 0.0927 - accuracy: 0.9815 - val_loss: 0.0058 - val_accuracy: 1.0000 - 12s/epoch - 367ms/step
Epoch 49/50
34/34 - 12s - loss: 0.0249 - accuracy: 0.9963 - val_loss: 0.0217 - val_accuracy: 1.0000 - 12s/epoch - 356ms/step
Epoch 50/50
34/34 - 12s - loss: 0.0300 - accuracy: 0.9889 - val_loss: 0.0048 - val_accuracy: 1.0000 - 12s/epoch - 359ms/step
```

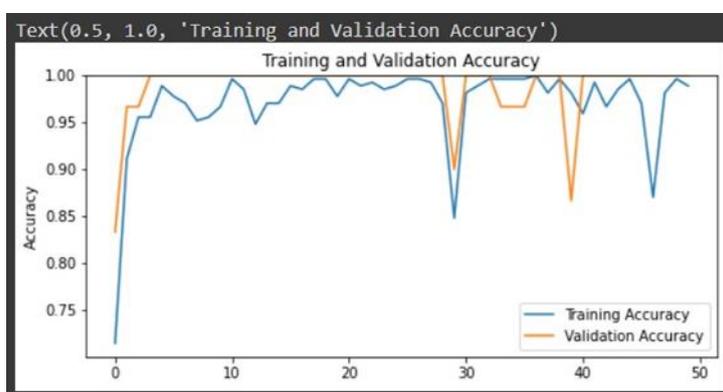
Gambar 3 Pelatihan setiap layer

Selama proses pelatihan, validasi dengan data validasi digunakan untuk memantau kinerja model dan mencegah overfitting. Data validasi terdiri dari citra-citra yang tidak digunakan dalam pelatihan, tetapi digunakan untuk mengevaluasi performa model secara objektif.

Selama pelatihan, learning rate, jumlah epoch, dan ukuran batch dapat disesuaikan untuk memperbaiki performa model. Pengaturan yang tepat dapat membantu model mencapai konvergensi yang baik dan meningkatkan akurasi klasifikasi fase cahaya matahari.

Perhatikan bagaimana loss atau akurasi model berubah seiring dengan jumlah epoch yang meningkat. Jika terjadi penurunan yang signifikan pada loss atau peningkatan yang stabil pada akurasi, ini dapat menunjukkan bahwa model hampir mencapai konvergensi. Dalam hal ini, jumlah epoch bisa lebih kecil.

Evaluasi Model dilakukan selama pelatihan menggunakan data validasi. Jika model mulai menunjukkan indikasi overfitting pada data latih, seperti peningkatan loss pada data validasi, bisa jadi tanda bahwa pelatihan sudah cukup dan model perlu dihentikan sebelum mencapai jumlah epoch yang ditentukan

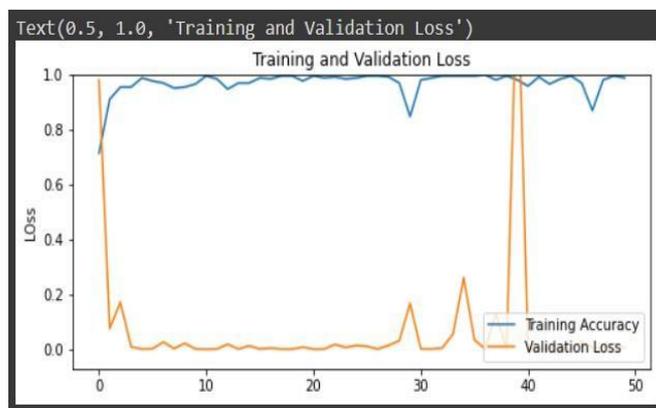


Gambar 4 Grafik Akurasi Data Training

Grafik akurasi data training adalah representasi visual dari bagaimana akurasi model CNN berkembang selama pelatihan seiring dengan jumlah epoch yang meningkat. Biasanya, sumbu x pada grafik akan mewakili jumlah epoch, sementara sumbu y akan mewakili akurasi.

Pada awal pelatihan, akurasi mungkin rendah karena model CNN belum mengetahui pola yang ada dalam data latih. Namun, seiring dengan penyesuaian parameter model melalui proses optimisasi, akurasi akan meningkat seiring dengan peningkatan jumlah epoch.

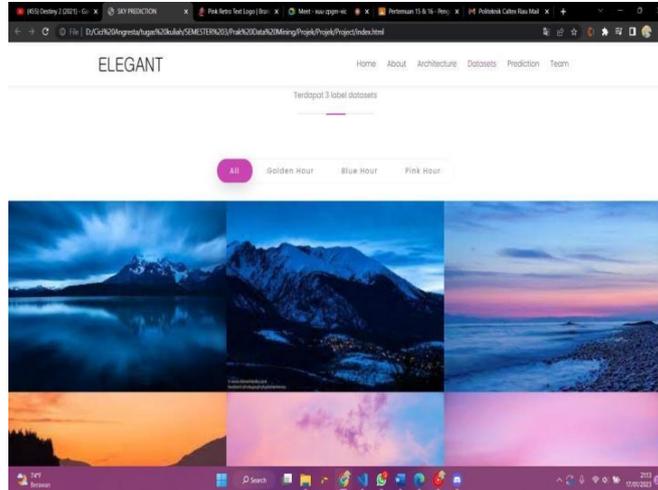
Grafik akurasi data training yang ideal akan menunjukkan peningkatan yang stabil dan berkelanjutan seiring dengan peningkatan jumlah epoch. Namun, ada kemungkinan bahwa akurasi akan mencapai titik jenuh di mana peningkatan akurasi menjadi lebih lambat.



Gambar 5 Grafik Akurasi Data Loss

Dua gambar diatas adalah gambar grafik akurasi pada data training dan data loss. Grafik tersebut merupakan perintah dari library matplotlib.

Perancangan front-end untuk penelitian ini melibatkan pembuatan antarmuka pengguna yang intuitif dan menarik untuk berinteraksi dengan sistem klasifikasi fase cahaya matahari.

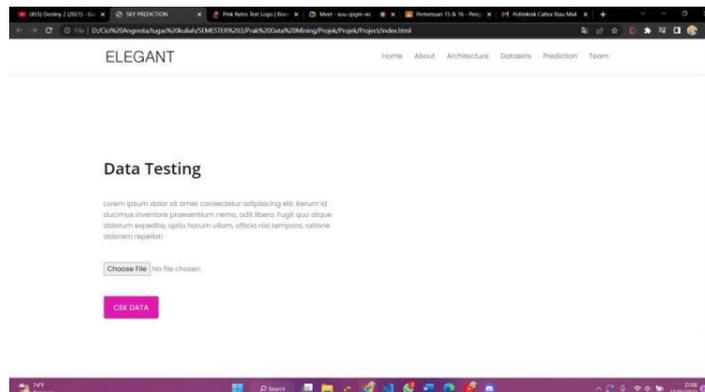


Gambar 6 Halaman Home

Halaman ini merupakan halaman home yang berisi penjelasan tentang fase cahaya matahari. Pada gambar 6 memuat laman mengenai proses prediksi. Dimana pengguna nanti memasukkan dataset dari salahsatu citra fase cahaya matahari. Sistem akan membantu pengguna dalam memprediksi dataset tersebut masuk ke dalam klasifikasi yang mana.

Tabel 1 Hasil Loss dan Accuracy menggunakan 50 Epoch

Epoch	Loss	Acc	Val_Loss	Val_acc
1	1.1699	0.4444	0.7894	0.5556
2	0.6978	0.7131	0.4675	0.7963
3	0.5036	0.8000	0.3864	0.8333
4	0.3176	0.8747	0.4038	0.8704
5	0.6907	0.8101	0.1746	0.9444
6	0.2683	0.9010	0.1803	0.9444
7	0.1642	0.9374	0.1882	0.9444
8	0.1395	0.9556	0.5267	0.9074
9	0.1613	0.9535	0.0740	0.9815
10	0.0920	0.9697	0.2101	0.9444
....	....	....	.....	....
48	0.0011	1.0000	0.0438	0.9815
49	0.0037	1.0000	0.0942	0.9630



Gambar 7 Laman Prediksi

Pada gambar 7 menampilkan laman dari hasil prediksi pada saat pengguna melakukan proses prediksi sebuah citra cahaya matahari

Hasil loss dan accuracy menggunakan 50 epoch untuk mengetahui bagaimana bentuk akurasi dan nilai loss model data yang telah melalui data training dan data validation dengan nilai akurasi data keseluruhan sebesar 96%.

## 5. KESIMPULAN

Dalam penelitian DeepSun: Klasifikasi Fase Cahaya Matahari berdasarkan warna menggunakan CNN, dapat mengklasifikasikan fase cahaya matahari berdasarkan warna dengan akurasi yang baik. Dalam penelitian ini, menggunakan dataset yang mencakup berbagai contoh gambar fase cahaya matahari dengan label yang tepat.

Melalui proses pelatihan, model CNN berhasil mempelajari pola-pola visual yang ada dalam gambar fase cahaya matahari. Arsitektur CNN yang digunakan terdiri dari beberapa layer konvolusi dan pooling untuk mengekstraksi fitur-fitur penting dari gambar. Pengujian akurasi menggunakan dataset pengujian yang terpisah. Hasil loss dan accuracy menggunakan 50 epoch untuk mengetahui bagaimana bentuk akurasi dan nilai loss model data yang telah melalui data training dan data validation dengan nilai akurasi data keseluruhan sebesar 96%. Namun, penelitian ini juga menunjukkan adanya potensi untuk pengembangan lebih lanjut. Dalam penelitian mendatang, dapat dilakukan peningkatan lebih lanjut pada arsitektur CNN, eksplorasi penggunaan transfer learning, atau penambahan data latih untuk meningkatkan performa model.

## DAFTAR PUSTAKA

- [1] Alotaibi, A., & Mahmood, A.. "Automatic Segmentation and Classification of Sun Phase Images Using Convolutional Neural Networks". IEEE Access, 9,2021, 131119-131134.
- [2] Sheppard, C., Chilcott, A., & Wong, K. W. (2021). Sun Classifications Using Convolutional Neural Networks for Astronomical Image Data. In Proceedings of the International MultiConference of Engineers and Computer Scientists (IMECS), Vol II.
- [3] Liu, J., Liu, J., Guo, T., & Chen, L. 2021. Sun Exposure Classification Based on Deep Learning. In 2021 IEEE 12th International Conference on Software Engineering and Service Science (ICSESS) (pp. 1325-1328). IEEE.
- [4] Gupta, P., Kumar, S., & Mandal, J. K. 2020. Solar Phase Recognition using CNN. In 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT) (pp. 1-5). IEEE.
- [5] I. Wulandari, H. Yasin, and T. Widiharih, "Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (CNN)," J. Gaussian, vol. 9, no. 3, pp. 273–282, 2020, doi: 10.14710/j.gauss.v9i3.27416.
- [6] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," J. Informatics Comput. Sci., vol. 01, pp. 104–108, 2019.
- [7] C. Umam and L. Budi Handoko, "Convolutional Neural Network (CNN) Untuk Identifikasi Karakter Hiragana," Pros. Semin. Nas. Lppm Ump, vol. 0, no. 0, pp. 527–533, 2020.
- [8] A. R. Maulana and N. Rochmawati, "Opinion Mining Terhadap Pemberitaan Corona di Instagram menggunakan Convolutional Neural Network," JINACS J. Informatics Comput. Sci., vol. 02, no. 01,2020, pp. 53–59
- [9] A. Kholik, A. Harjoko, and W. Wahyono, "Classification of Traffic Vehicle Density Using Deep Learning," IJCCS (Indonesian J. Comput. Cybern. Syst., vol. 14, no. 1, p. 69, 2020, doi: 10.22146/ijccs.50376
- [10] Z. J. Wang *et al.*, "CNN Explainer: Learning Convolutional Neural Networks with Interactive Visualization," Apr. 2020, doi: 10.1109/TVCG.2020.3030418.
- [11] A. Peryanto, A. Yudhana, and R. Umar, "Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation," 2020. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>

- [12] F. Fitra Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," vol. 01, no. 02, 2019.
- [13] E. N. Arrofiqoh and H. Harintaka, "Implementasi Metode Convolutional Neural Network untuk Klasifikasi Tanaman pada Citra Resolusi Tinggi," vol. 24, no. 2, p. 61, Nov. 2018, doi: 10.24895/jig.2018.24- 2.810.
- [14] Lorentius, C.A dkk.. "Pengenalan Aksara Jawa dengan Menggunakan Metode Convolutional Neural Network". Jurnal Infra Vol.7, No.1.2019.
- [15] Arrofiqoh, Erlyna Nour dan Harintaka.. Implementasi Metode Convolutional Neural Network untuk Klasifikasi Tanaman pada Citra Resolusi Tinggi. Jurnal Geomatika. Vol : 24, No : 2. 61-68, 2018