

Estimasi Jarak Pandang Meteorologi di Bandar Udara Menggunakan Metode Back Propagation dan CNN

Siti Maesaroh^{1*}, Kurnia Muludi², Joko Triloka²

¹ Stasiun Meteorologi Kelas I Radin Inten II, Lampung, Indonesia

² Magister Teknik Informatika, Institut Informatika dan Bisnis Darmajaya, Bandar Lampung, Indonesia

Email: ^{1*}siti.2321211015@mail.darmajaya.ac.id, ²kmuludi@yahoo.com, ³joko.triloka@darmajaya.ac.id

Email Penulis Korespondensi: siti.2321211015@mail.darmajaya.ac.id

Submitted: 18/03/2025; Accepted: 31/05/2025; Published: 01/06/2025

Abstrak—Bandar Udara di Indonesia sering menghadapi masalah cuaca buruk yang mempengaruhi jarak pandang dan berdampak pada operasional penerbangan. Data historis menunjukkan adanya beberapa insiden yang disebabkan oleh penurunan jarak pandang karena adanya kabut ataupun hujan yang mengakibatkan penundaan dan pembatalan penerbangan. Dapat dikatakan bahwa pentingnya estimasi jarak pandang yang lebih akurat untuk meningkatkan keselamatan dan efisiensi operasional di bandar udara. Tujuan dari penelitian ini untuk mengetahui kinerja model Back Propagation dan Convolutional Neural Network (CNN) dalam mengestimasi jarak pandang meteorologi di Bandar Udara karena jarak pandang yang akurat sangat penting dalam menentukan keputusan operasional, terutama pada saat kondisi cuaca buruk. Pemilihan metode Back Propagation didasarkan pada keunggulannya dalam menangani berbagai jenis data dengan dinamis dan terarah sehingga lebih tepat dalam prediksi jarak pandang berdasarkan variabel-variabel meteorologi yang saling terkait. Sedangkan Convolutional Neural Network (CNN) sangat efektif dalam menangani masalah yang melibatkan data berbentuk gambar. Namun saat ini cukup banyak penelitian yang menggunakan CNN untuk pemrosesan text karena hasilnya yang cukup menjanjikan. Data yang digunakan adalah data meteorologi yang mencakup suhu, kelembapan, tekanan udara, kecepatan angin dan parameter lainnya di Bandar Udara Radin Inten II. Dari hasil penelitian ini, model Backpropagation lebih baik dalam ROC AUC (85%) dibandingkan dengan CNN (84%), ini menunjukkan sedikit keunggulan dalam membedakan kelas. Model CNN lebih baik dalam Precision sebesar 71% dibandingkan dengan Back Propagation 70%, yang berarti sedikit lebih baik dalam menghindari prediksi yang salah positif. CNN memiliki korelasi lebih tinggi pada data uji (0.20) dibandingkan dengan Back Propagation (0.18) menunjukkan prediksinya sedikit lebih sejalan dengan data aktual. Selisih korelasi lebih besar pada CNN (0.18) dibandingkan dengan Back Propagation (0.10) menunjukkan kemungkinan overfitting CNN yang lebih tinggi dibandingkan BP. Karena kedua model menunjukkan performa yang hampir sama dan perbedaannya tidak terlalu signifikan, maka pemilihan model bisa bergantung pada kebutuhan spesifik dalam implementasi. Jika tujuannya adalah mendapatkan model yang lebih stabil, maka Backpropagation lebih direkomendasikan karena memiliki selisih korelasi lebih kecil dan ROC AUC lebih tinggi. Namun, jika yang dicari adalah model dengan prediksi yang lebih akurat dalam skenario nyata, maka CNN bisa menjadi pilihan lebih baik karena memiliki Precision lebih tinggi dan korelasi uji lebih baik.

Kata Kunci: Estimasi; Jarak Pandang; Back Propagation; CNN; Cuaca; Bandara

Abstract—Airports in Indonesia often face bad weather problems that affect visibility and impact flight operations. Historical data shows several incidents caused by decreased visibility due to fog or rain that resulted in flight delays and cancellations. It can be said that the importance of more accurate visibility estimates to improve safety and operational efficiency at airports. The purpose of this study was to determine the performance of the Back Propagation and Convolutional Neural Network (CNN) models in estimating meteorological visibility at airports because accurate visibility is very important in determining operational decisions, especially during bad weather conditions. The selection of the Back Propagation method is based on its advantages in handling various types of data dynamically and in a directed manner so that it is more precise in predicting visibility based on interrelated meteorological variables. While Convolutional Neural Network (CNN) is very effective in handling problems involving image data. However, currently there are quite a lot of studies that use CNN for text processing because the results are quite promising. The data used is meteorological data that includes temperature, humidity, air pressure, wind speed and other parameters at Radin Inten II Airport. From the results of this study, the Backpropagation model is better in ROC AUC (85%) compared to CNN (84%), this shows a slight advantage in distinguishing classes. The CNN model is better in Precision by 71% compared to Back Propagation 70%, which means it is slightly better at avoiding false positive predictions. CNN has a higher correlation on the test data (0.20) compared to Back Propagation (0.18) indicating its predictions are slightly more in line with the actual data. The larger correlation difference in CNN (0.18) compared to Back Propagation (0.10) indicates a higher possibility of CNN overfitting compared to BP. Since both models show almost the same performance and the difference is not too significant, the choice of model can depend on the specific needs in the implementation. If the goal is to get a more stable model, then Backpropagation is more recommended because it has a smaller correlation difference and higher ROC AUC. However, if what is sought is a model with more accurate predictions in real scenarios, then CNN can be a better choice because it has higher Precision and better test correlation.

Keywords: Estimation; Visibility; Back Propagation; CNN; Weather; Airport

1. PENDAHULUAN

Bandar Udara merupakan suatu wilayah yang digunakan untuk pesawat mendarat juga lepas landas, pergerakan penumpang dan barang dengan dilengkapi fasilitas - fasilitas keselamatan dan keamanan penerbangan [1]. Aktivitas penerbangan sangat dipengaruhi oleh perubahan kondisi cuaca [2]. Bandar Udara Radin Inten II yang terletak di Kabupaten Lampung Selatan memiliki peran penting dalam transportasi udara di wilayah Lampung. Namun, salah satu tantangan yang dihadapi adalah fluktuasi kondisi cuaca yang dapat mempengaruhi jarak pandang (*visibility*). *Visibility* dapat diartikan sejauh mana suatu objek atau titik tertentu dapat dilihat jelas oleh pengamat [3]. Cuaca menggambarkan kondisi atmosfer yang diukur secara menyeluruh meliputi perubahan, perkembangan dan timbul atau

hilangnya suatu fenomena udara tertentu [4]. Meskipun Bandar Udara Radin Inten II sudah dilengkapi dengan Approach Lighting System (ALS) yang merupakan sistem pencahayaan jalur pendaratan pesawat, tetapi pilot tetap memerlukan data visibility untuk keperluan lepas landas dan pendaratan [5].

Pada peraturan Menteri Perhubungan KM No. 18 Tahun 2010, jarak pandang yang aman dalam penerbangan ditetapkan sejauh lima kilometer [6]. Visibility hingga kurang dari 5 km berpotensi mengganggu operasional penerbangan [7]. Secara umum visibility rendah terjadi karna adanya kabut ataupun asap yang disebabkan oleh keadaan cuaca disekitar. Faktor-faktor yang mempengaruhi keadaan suatu cuaca yakni antara lain suhu, tekanan udara, kecepatan angin serta curah hujan [8]. Suhu adalah suatu besaran yang menyatakan ukuran derajat suatu benda atau lingkungan [9]. Tekanan udara adalah gaya per satuan luas oleh partikel-partikel udara yang berada di atmosfer bumi. Variasi tekanan udara di berbagai tempat mempengaruhi pergerakan angin dan pola cuaca [10]. Angin merupakan pergerakan udara dari tempat dengan tekanan tinggi menuju ke tempat dengan tekanan rendah. Arah dan kecepatan angin dipengaruhi oleh variasi tekanan atmosfer dan topografi [10]. Curah hujan adalah jumlah air yang turun ke permukaan bumi dalam suatu waktu yang dihitung dalam satuan millimeter (mm) di atas permukaan tanah [11]. Berkurangnya jarak pandang dapat berdampak negatif terhadap efisiensi operasional bandar udara dan keselamatan penerbangan karena dapat mengakibatkan keterlambatan atau penundaan keberangkatan penerbangan hingga kecelakaan yang berujung pada munculnya korban jiwa. Oleh karena itu, estimasi jarak pandang meteorologi yang akurat berdasarkan kondisi cuaca sangat penting untuk meningkatkan keselamatan penerbangan dan mengurangi risiko kecelakaan.

Terdapat beberapa penelitian yang sudah dilakukan dalam menentukan estimasi jarak pandang meteorologi, seperti pada Tahun 2020, Wai Lun Lo dkk melakukan penelitian dengan *Support Vector Machine (SVM)* untuk memprediksi estimasi visibilitas dengan gambar digital dari lokasi yang dipilih. Hasil penelitian dapat mengklasifikasikan wilayah gambar efektif ke dalam rentang visibilitas yang berbeda dan kesalahan prediksi dapat kurang dari 12,6% [12]. Di tahun yang sama Venkata R. Duddu dkk menggunakan *Back-propagation neural network* pada penelitiannya untuk memprediksi visibilitas pada jalan raya dengan prediktabilitas lebih tinggi untuk kondisi kabut normal dibandingkan dengan kondisi visibilitas yang sangat rendah (kabut tebal/padat) [13]. Pada Tahun 2023 Lady Silk Moonlight dkk melakukan penelitian sistem prediksi visibilitas yang dibangun untuk meningkatkan keselamatan dan keamanan penerbangan. Hasil nilai akurasi sistem prediksi visibilitas yang dibangun menggunakan metode *backpropagation* yaitu bernilai 93,22% atau nilai RMSE sebesar 0,06776 [14]. Pada Tahun 2023 juga Adi Saputra dkk melakukan penelitian prakiraan cuaca dengan metode *backpropagation* dengan akurasi pengujian terbaik sebesar 74.359% [15]. Selanjutnya di Tahun 2024 Penelitian yang dilakukan oleh Fadel Muhammad Madjid untuk menentukan prediksi visibility menggunakan *Long Short-Term Memory (LSTM)* dan *Multi Layer Perceptron (MLP)*, menunjukkan bahwa model LSTM lebih bagus untuk memprediksi visibility selama 3 jam, 6 jam serta 12 jam ke depan. Sementara untuk memprediksi visibility 6 jam lebih baik menggunakan model MLP [16].


Penelitian ini bertujuan untuk mengembangkan sebuah sistem estimasi jarak pandang meteorologi yang lebih akurat dan efisien dengan metode Back Propagation dan Convolutional Neural Network (CNN). Penelitian menggunakan metode Back Propagation dan Convolutional Neural Network (CNN) diharapkan dapat meningkatkan presisi estimasi jarak pandang dengan mengolah data meteorologi yang ada.

2. METODOLOGI PENELITIAN

Metode penelitian merupakan suatu tahapan untuk mencapai suatu kebenaran atau fakta menggunakan pencarian dengan cara menemukan suatu kebenaran [17]. Metodologi penelitian untuk Estimasi Jarak Pandang Meteorologi dengan Menggunakan Metode Back Propagation dan Convolutional Neural Network (CNN) di Bandar Udara Radin Inten II Lampung melibatkan beberapa tahapan, antara lain :

2.1 Tahapan Penelitian

Tahapan penelitian untuk Estimasi Jarak Pandang Meteorologi dengan Menggunakan Metode Back Propagation dan Convolutional Neural Network (CNN) di Bandar Udara Radin Inten II digambarkan pada Gambar 1 dibawah ini.



Gambar 1. Diagram Alur Penelitian

2.1.1 Pengumpulan Data

Langkah awal yang dilakukan adalah menumpulkan data yang di dapatkan dari Stasiun Meteorologi Kelas I Radin Inten II berupa data meteorologi yang mencakup beberapa parameter yang dapat mempengaruhi jarak pandang dengan rentang waktu data per jam selama 1 tahun yaitu Tahun 2022. Jumlah data keseluruhan dalam penelitian ini adalah 8760 baris. Parameter tersebut antara lain suhu udara, kelembapan relatif, kecepatan angin, titik embun, suhu bola basah, QFE, QFF dan Visibility.

2.1.2 Pra Pemrosesan Data

Kegunaan pra pemrosesan data adalah untuk mengubah data mentah sehingga dapat meningkatkan kualitas data yang akan di analisis [18]. Pada proses pra pemrosesan data, data dinormalisasi untuk memastikan semua fitur memiliki skala yang sama. Pada proses ini juga data hilang atau tidak valid diperbaiki atau dihapus untuk memastikan semua data normal. Selanjutnya, data akan dipisahkan menjadi dua bagian, yaitu data pelatihan (training set) untuk melatih model dan data pengujian (testing set) untuk mengukur keakuratan model yang telah dilatih.

2.1.3 Pembangunan Model

Proses pembangunan model bertujuan untuk menghasilkan model yang mampu memperkirakan jarak pandang berdasarkan data meteorologi yang didapat. Model yang dibangun menggunakan metode back propagation dan CNN dengan bantuan bahasa pemrograman Python, yaitu bahasa pemrograman interpretatif, berorientasi objek dan semantik yang dinamis [10].

2.1.4 Pelatihan dan Pengujian Data

Data dibagi menjadi dua, 80 % untuk proses pelatihan data dan 20 % untuk proses pengujian data. Dengan Back Propagation, diproses ini meminimalkan kesalahan prediksi model dengan cara mengadjust bobot antar neuron berdasarkan error yang dihasilkan pada setiap iterasi. Setelah pelatihan selesai, data diuji menggunakan data uji untuk mengukur keakuratan data dalam memprediksi jarak pandang. Pada proses pelatihan data dengan CNN, Model dilatih dengan 100 epoch dan batch size 32. Setelah model selesai dilatih, model diuji pada data training dan testing untuk mengambil kelas dengan probabilitas tertinggi sebagai prediksi.


2.1.5 Evaluasi

Data dievaluasi menggunakan berbagai metrik untuk menilai performa model, diantaranya Root Mean Squared Error (RMSE) atau Mean Absolute Error (MAE) untuk mengetahui sejauh mana prediksi mendekati nilai jarak pandang yang sebenarnya dan Confusion matrix yang merupakan hasil kesimpulan kinerja proses klasifikasi relatif terhadap data uji sehingga diketahui seberapa baik performa model yang digunakan.

2.1 Metode Penyelesaian

2.1.1 Back Propagation

Jaringan syaraf tiruan adalah sebuah model pembelajaran terhadap penerimaan informasi yang memiliki sistem kerja seperti otak manusia [19]. Backpropagation termasuk jaringan syaraf tiruan dalam melakukan prakiraan atau prediksi dengan baik [20]. Model backpropagation menyesuaikan beberapa bobot jaringan syaraf tiruan dengan arah mundur berdasarkan nilai kesalahan selama proses pelatihan [21]. Dalam Forward Propagation, data input dilewatkan melalui jaringan untuk menghasilkan output. Perhitungan Error sebagai selisih antara output aktual dan output yang diharapkan. Error disebarkan kembali melalui jaringan untuk memperbarui bobot dan bias menggunakan algoritma optimasi seperti Gradient Descent. Dalam jaringan backpropagation terdapat 3 (tiga) lapisan (layer), meliputi lapisan input, lapisan tersembunyi dan lapisan output. Setiap lapisan terdiri dari satu atau lebih neuron.



Gambar 2. Lapisan Jaringan Back Propagation[10]

Gambar 2 adalah gambaran tentang lapisan – lapisan yang terdapat dalam jaringan Back Propagation. Lapisan input merupakan Lapisan yang menerima data awal. Lapisan tersembunyi adalah lapisan yang melakukan pemrosesan antara input dan output, dapat terdiri dari satu atau lebih lapisan. Lapisan output merupakan Lapisan yang menghasilkan output akhir dari jaringan. Semakin banyaknya lapisan tersembunyi sebagai lapisan maka semakin banyak neuron untuk dilatih dalam mencari pola yang terbaik. Setiap koneksi yang terhubung antar neuron mempunyai bobot yang menentukan seberapa kuat sinyal akan ditransmisikan. Bias adalah nilai tambahan yang membantu mengatur output dari neuron. Fungsi aktivasi digunakan untuk memperkenalkan non-linearitas ke dalam jaringan sehingga mampu memodelkan hubungan yang kompleks.

Dalam penelitian ini data pada kolom 'Visibility' digunakan sebagai target untuk prediksi. Nilai-nilai visibilitas kemudian dikonversi ke dalam bentuk kategori (kelas) sesuai rentang nilai yang telah ditentukan:

```
def convert_visibility(value):
    if 56 <= value <= 60:
        return 5
    elif value == 50:
        return 4
    elif 30 <= value <= 49:
        return 3
    elif 15 <= value <= 29:
        return 2
    elif 1 <= value <= 14:
        return 1
    return 0 # Default jika tidak memenuhi kondisi
```

Fungsi `convert_visibility()` ini mengonversi nilai visibilitas ke dalam kategori kelas antara 0 hingga 5. Setelah mengonversi target menjadi kategori, data dibagi menjadi fitur (x) dan target (y). Fitur mencakup kolom-kolom seperti 'BK', 'BB', 'TD', dan lainnya, sementara target adalah kolom 'Visibility' yang sudah dikategorikan:

```
x = data[features].values
y = data[target].values
```

Target (y) yang berbentuk kategori diubah menjadi format one-hot encoding agar model dapat memprosesnya dengan baik dalam prediksi kelas multi-kelas.

```
y_train_one_hot = to_categorical(y_train, num_classes=6)
y_test_one_hot = to_categorical(y_test, num_classes=6)
```

Pada penelitian ini Model back propagation yang dibangun adalah jaringan saraf feedforward dengan beberapa lapisan Dense (lapisan yang terhubung penuh) menggunakan fungsi aktivasi ReLU pada lapisan tersembunyi dan Softmax pada lapisan output untuk multi-class classification.

Model dikompilasi dengan optimisasi Adam dan fungsi kehilangan `categorical_crossentropy`, yang cocok untuk klasifikasi multi-kelas. Selain itu, beberapa metrik evaluasi juga ditentukan:

```
model.compile(
    optimizer=tf.keras.optimizers.Adam(learning_rate=0.001),
    loss='categorical_crossentropy', # Loss untuk multi-class
    metrics=['accuracy', 'mae'] # Metrik untuk evaluasi
```

Model dilatih selama beberapa epoch, dengan penghentian dini (early stopping) untuk menghindari overfitting jika tidak ada peningkatan validasi setelah sejumlah epoch tertentu. Setelah pelatihan, prediksi dilakukan pada data pelatihan dan pengujian, dan beberapa metrik evaluasi dihitung.

2.1.2 Convolutional Neural Network (CNN)

CNN adalah salah satu jenis Deep neural network yang merupakan pengembangan multilayer perseption dalam jaringan syaraf tiruan yang dirancang untuk pengolahan data 2 (dua) dimensi [22]. CNN mempunyai arsitektur yang unik dan efisien dalam menangani tugas yang berkaitan dengan pengenalan pola visual, seperti klasifikasi gambar, deteksi objek dan segmentasi gambar [23]. Lapisan konvolusi (Convolution Layer) untuk mengekstraksi fitur dari gambar dan lapisan pooling (Pooling Layer) untuk mengurangi dimensi. CNN diketahui dapat mengidentifikasi pola yang sangat beragam dalam data visual dan diterapkan di berbagai bidang seperti pengenalan gambar, deteksi objek dan bahkan dalam pemrosesan data non-gambar. Saat ini cukup banyak penelitian yang menggunakan CNN untuk text processing karena hasilnya yang baik dan tingkat akurasi optimal.

a. Convolutional layer

Convolutional layer merupakan lapisan pertama yang terdiri dari beberapa filter konvolusi yang disusun secara paralel untuk menghasilkan feature map. Operasi konvolusi dilakukan dengan mengalikan input dan kernel [22].

$$f \otimes g = \sum_m \sum_n f(m, n)g(x - m, y - n) \quad (1)$$

b. Pooling Layer

Pooling layer merupakan lapisan yang digunakan untuk mengurangi spasial fitur konvolusi yang berfungsi untuk mengurangi daya komputasi yang diperlukan untuk memproses data.

$$Poolij = \text{Max}(\text{Convi}, j, \text{Convi}+1, j, \text{Convi}, j+1, \text{Convi}+1, j+1) \quad (2)$$

c. ReLU (Rectified Linear Units)

ReLU adalah sebuah fungsi aktivasi untuk menghilangkan nilai negatif pada matriks gambar dengan menggantinya menjadi 0.

$$\text{ReLU} = \{ x, (x \geq 0) \ 0, (x < 0) \} \quad (3)$$

d. Fully Connected Layer

Lapisan terhubung penuh ini merupakan jenis lapisan untuk menggabungkan seluruh neuron aktif ke neuron selanjutnya yang mempertimbangkan bias, biasanya digunakan untuk mencari ciri klasifikasi yang mirip pada konvolusi terakhir.

$$y = \text{ReLU}(Wx + b) \quad (4)$$

Dalam pengolahan data di penelitian ini data Visibility diubah menjadi 5 kelas utama berdasarkan rentang nilai:

56 - 60 → Kelas 5

50 → Kelas 4

30 - 49 → Kelas 3

15 - 29 → Kelas 2

1 - 14 → Kelas 1

Lainnya → Kelas 0 (dihapus nanti karena dianggap tidak valid).

Fitur yang digunakan untuk prediksi adalah BK (tekanan udara), BB (kelembapan udara), TD (temperatur), RH (kelembapan relatif), Arah (arah angin), Kecepatan (kecepatan angin), QFF, QFE (tekanan udara permukaan) dan target adalah Visibility (jarak pandang). Data dilatih dan di uji kemudian dilakukan standarisasi agar semua data memiliki skala yang seragam. Pembangunan model CNN dalam penelitian ini terdiri dari beberapa layer dan model dikompilasi dengan Optimasi Adam untuk menyesuaikan bobot model.

Conv1D Layer (64 filter) → Mendeteksi pola dalam data.

MaxPooling Layer → Mengurangi dimensi data agar lebih ringan.

Conv1D Layer (32 filter) → Meningkatkan pemahaman pola.

MaxPooling Layer → Lagi-lagi untuk memperkecil dimensi.

Flatten Layer → Mengubah data menjadi format 1 dimensi.

Dense Layer (64 unit, ReLU) → Layer pemrosesan tambahan.

Dropout (20%) → Mencegah model terlalu "hafal" data pelatihan.

Dense Layer (32 unit, ReLU) → Layer pemrosesan tambahan.

Output Layer (Softmax, 6 kelas) → Menghasilkan prediksi kelas 0-5.

Model CNN dilatih dengan 100 epoch dan batch size 32 (dapat berhenti lebih awal jika tidak ada peningkatan). Early Stopping digunakan untuk menghentikan pelatihan jika model mulai terlalu hafal data (overfitting). Setelah model selesai dilatih, model diuji pada data training dan testing kemudian mengambil kelompok dengan peluang tertinggi sebagai prediksi.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Metode

Analisis model Backpropagation (BP) dan Convolutional Neural Network (CNN) dalam melakukan prediksi jarak pandang berdasarkan parameter cuaca, evaluasi dilakukan menggunakan berbagai metrik kinerja yang mencerminkan sejauh mana model mampu memprediksi data dengan akurat dan stabil. Pada Tabel 1, dari metrik yang diberikan kita dapat melakukan analisis terhadap hasil yang diperoleh dari metode Backpropagation dan CNN.

Tabel 1. Hasil Pengujian Data Model Back Propagation dan CNN

Metrik	Back Propagation	CNN
Accuracy (Train)	84%	84%
Accuracy (Test)	83%	83%
F1 Score (Test)	75%	75%
Precision (Test)	70%	71%
Recall (Test)	83%	83%
ROC AUC (Test)	85%	84%
RMSE (Train)	0.87	0.86
RMSE (Test)	0.90	0.90
MAE (Train)	0.33	0.33
MAE (Test)	0.35	0.35
Korelasi (Train)	0.08	0.02
Korelasi (Test)	0.18	0.20

Selisih Korelasi	0.10	0.18
Rata-Rata Error (Train)	0.33	-0.32
Hasil Uji	Baik	Baik

3.2 Pembahasan

Berikut adalah pembahasan mendalam dan penjelasan hasil evaluasi model Back Propagation dan CNN dari masing-masing metrik yang digunakan pada penelitian ini.

a. Akurasi Model

Akurasi kedua model hampir identik, baik pada data latih (train) maupun uji (test). Ini menunjukkan bahwa keduanya memiliki kemampuan yang setara dalam mengenali pola pada data dan melakukan prediksi.

1. Train Accuracy: Kedua model (Backpropagation dan CNN) memiliki accuracy 84% pada data pelatihan (train), yang menunjukkan bahwa model cukup baik dalam mengklasifikasikan data yang digunakan untuk pelatihan.
2. Test Accuracy: 83% pada data uji (test) untuk kedua model didapatkan hasil bahwa model tidak terjadi overfitting yang signifikan dan bisa menggeneralisasi dengan cukup baik.

b. F1 Score (Test)

Nilai 75% untuk keduanya dapat diartikan bahwa kedua model memiliki performa yang seimbang pada Precision dan Recall, yang penting dalam situasi di mana kita peduli terhadap keseimbangan antara menghindari false positives dan false negatives.


c. Precision (Test)

Model CNN sedikit lebih unggul dengan 71% dibandingkan dengan 70% pada Backpropagation yang artinya CNN sedikit lebih baik dalam menghindari prediksi yang salah positif. Precision mengukur ketepatan prediksi positif, artinya 71% dari kedua prediksi positif yang dilakukan oleh CNN adalah benar positif, sedikit lebih baik dibandingkan Backpropagation.

d. Recall (Test)

Kedua model memiliki Recall yang sangat mirip yaitu 83%. Hal ini berarti kedua model dapat mengidentifikasi kasus positif dengan baik.


e. ROC AUC (Test)



Gambar 3. Perbandingan Kurva ROC CNN dan Back Propagation

ROC AUC mengukur seberapa baik model dapat membedakan antara kelas yang berbeda. Pada Gambar 3 menunjukkan perbandingan kurva ROC kedua model. Model Backpropagation memiliki AUC yang lebih tinggi (85%) dibandingkan CNN (84%), meskipun perbedaannya kecil. Ini menunjukkan bahwa BP memiliki sedikit keunggulan dalam membedakan kelas visibilitas dengan lebih baik.


f. RMSE (Train/Test)



Gambar 4. Perbandingan RMSE CNN dan Back Propagation

Pada Gambar 4 dapat kita lihat bahwa nilai RMSE di 0.87 (Train) dan 0.90 (Test) untuk Backpropagation serta 0.86 (Train) dan 0.90 (Test) untuk CNN dapat diartikan bahwa kedua model melakukan prediksi yang cukup baik, dengan nilai error yang relatif kecil. RMSE digunakan untuk mengukur perbedaan nilai yang diprediksi dengan nilai yang sesungguhnya.

g. MAE (Train/Test)



Gambar 5. Perbandingan MAE CNN dan Back Propagation

MAE yang hampir sama di kedua model (0.33 Train, 0.35 Test) pada Gambar 5 menunjukkan bahwa kesalahan absolut rata-rata antara nilai yang diprediksi dan nilai aktual sangat kecil pada kedua model.

h. Korelasi (Train/Test)

Korelasi antara prediksi model dan nilai aktual menunjukkan sejauh mana model dapat memahami hubungan dalam data. Nilai korelasi yang sedikit lebih tinggi pada data uji untuk CNN (0.20) dibandingkan dengan Backpropagation (0.18) menunjukkan bahwa model CNN sedikit lebih baik dalam menangkap hubungan antara prediksi dan nilai aktual. Perbedaan kecil juga terlihat pada data pelatihan, namun hasilnya masih sangat mendekati.


i. Selisih Korelasi

Selisih Korelasi 0.10 untuk Backpropagation dan 0.18 untuk CNN, menunjukkan bahwa CNN lebih stabil dalam membangun korelasi antara data pelatihan dan uji dibandingkan dengan Backpropagation. Namun CNN memiliki selisih korelasi yang lebih besar (0.18 vs. 0.10), yang mungkin menunjukkan bahwa model CNN mengalami sedikit overfitting dibanding BP.

j. Rata-Rata Error (Train)

Nilai positif pada BP menunjukkan bahwa model cenderung sedikit memprediksi lebih tinggi dari nilai aktual. Nilai negatif pada CNN menunjukkan bahwa model cenderung memprediksi lebih rendah dari nilai aktual. Perbedaan ini tidak besar, tetapi bisa berpengaruh dalam interpretasi hasil prediksi.

k. Hasil Uji



Gambar 6. Perbandingan Visualisasi Scatter Plot CNN dan Back Propagation

Pada Gambar 6 dapat kita lihat hasil uji kedua model menunjukkan "Baik", yang berarti keduanya memberikan hasil yang layak untuk diterapkan meskipun ada beberapa perbedaan kecil dalam performa mereka.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan dapat disimpulkan bahwa kedua model memiliki kinerja yang sangat mirip. Metode Backpropagation sedikit unggul pada beberapa metrik seperti Korelasi Train dan RMSE (Train). CNN, meskipun sedikit lebih unggul dalam Precision, keduanya menunjukkan hasil yang serupa dalam hal Accuracy, Recall, F1 Score dan ROC AUC. Kedua model tidak menunjukkan overfitting yang signifikan karena accuracy pada train dan test sangat mirip, yang menunjukkan bahwa keduanya berhasil menggeneralisasi data dengan baik. Meskipun CNN sedikit unggul dalam beberapa metrik (terutama Precision dan Korelasi Test), kedua model menunjukkan performa yang baik dan hampir setara dalam hal efektivitas. Pilihan antara keduanya bisa bergantung pada kebutuhan spesifik aplikasi, seperti interpretabilitas model (Backpropagation lebih sederhana dan lebih mudah dipahami) atau kemampuannya dalam menangkap fitur yang lebih kompleks dalam data (CNN lebih kuat dalam hal ini). Jika tujuannya adalah mendapatkan model yang lebih stabil dan tidak terlalu overfit, maka Backpropagation lebih direkomendasikan karena memiliki selisih korelasi lebih kecil dan ROC AUC lebih tinggi. Namun, jika yang dicari adalah model dengan prediksi yang lebih akurat dalam skenario nyata, maka CNN bisa menjadi pilihan lebih baik karena memiliki Precision lebih tinggi dan korelasi uji lebih baik. Karena perbedaannya tidak terlalu signifikan, pemilihan model bisa bergantung pada kebutuhan spesifik dalam implementasi. Untuk penelitian selanjutnya dapat dipertimbangkan untuk menambah jumlah data dan parameter lain atau dilakukan pengujian di lokasi bandar udara yang berbeda untuk memastikan model bekerja efektif di seluruh kondisi cuaca dan geografi. Selain itu dapat juga dilakukan penelitian dengan algoritma machine learning atau deep learning lain, seperti Recurrent Neural Networks (RNN) yang lebih kuat dalam menangani data urutan waktu (time-series) atau dinamika kondisi cuaca yang berubah seiring waktu untuk meningkatkan kinerja model estimasi jarak pandang yang lebih akurat dan membantu meningkatkan keselamatan penerbangan.

REFERENCES

- [1] P. RI, "Peraturan Pemerintah Republik Indonesia Nomor 32 Tahun 2021 Tentang Penyelenggaraan Bidang Penerbangan," *Peratur. Pemerintah Republik Indones.*, no. 086085, pp. 1–110, 2021, [Online]. Available: https://jdih.setkab.go.id/PUUdoc/176355/PP_Nomor_32_Tahun_2021.pdf
- [2] Y. Dermadi, S. D. Lukitasari, and A. Nurhayati, "Weather Analysis of Flight Delay at Husein Sastranegara Airport," *ITEJ (Information Technol. Eng. Journals)*, vol. 4, no. 2, pp. 89–98, 2019, doi: 10.24235/itej.v4i2.31.
- [3] International Civil Aviation Organization, "Doc 9817 Manual on Low-level Wind Shear," pp. 1–213, 2005, Access Date 20 Feb 2025, [Online]. Available: <https://standart.aero/en/icao/book/doc-9817-manual-on-low-level-wind-shear-en-cons>
- [4] A. Luthfiarta, A. Febriyanto, H. Lestawan, and W. Wicaksono, "Analisa Prakiraan Cuaca dengan Parameter Suhu, Kelembaban, Tekanan Udara, dan Kecepatan Angin Menggunakan Regresi Linear Berganda," *JOINS (Journal Inf. Syst.)*, vol. 5, no. 1, pp. 10–17, 2020, doi: 10.33633/joins.v5i1.2760.
- [5] Direktorat Jenderal Perhubungan Udara, "PR 26 TAHUN 2022 Tentang Pedoman Teknis Operasional Keselamatan Penerbangan Sipil Bagian 139-27 (Advisory CASR Part 139-27) Pedoman Pengoperasian dan Pemeliharaan Peralatan Pendaratan Visual," Kemenhub, Access Date 20 Feb 2025, [Online]. Available: <https://jdih.kemenhub.go.id/site/index>
- [6] Kementerian Perhubungan Republik Indonesia, "Keputusan Menteri Perhubungan Nomor KM 41 Tahun 2001 Tentang Peraturan Keselamatan Penerbangan Sipil Bagian 91," Kemenhub, Access Date 20 Feb 2025, [Online]. Available: <https://jdih.kemenhub.go.id/site/index>
- [7] A. Kurniawan and R. Z. A. Aziz, "Prediksi Kabut Bandar Udara di Indonesia Menggunakan Neural Network dan Radom Forest," *Build. Informatics, Technol. Sci.*, vol. 6, no. 2, pp. 746–757, 2024, doi: 10.47065/bits.v6i2.5544.
- [8] M. Fauzi *et al.*, "Implementasi Machine Learning Untuk Memprediksi Cuaca Menggunakan Support Vector Machine," *J. Ilm. Komputasi*, vol. 23, no. 1, pp. 45–50, 2024, doi: 10.32409/jikstik.23.1.3499.
- [9] R. Nulpambudi and R. A. Aziz, "Prediksi Kejadian Banjir Di Wilayah Kota Bandar Lampung Dengan Metode Artificial Neural Network," *Prosiding Semin. Nas. Has. Penelit. dan Pengabd.*, pp. 93–104, 2022, [Online]. Available: <https://jurnal.darmajaya.ac.id/index.php/PSND/article/view/3254>
- [10] D. R. Rochmawati, "Prediksi Cuaca Dengan Jaringan Syaraf Tiruan Menggunakan Python," *J. Teknol. Komput. dan Inform.*, vol. 2, no. 2, pp. 162–171, 2024, doi: 10.59820/tekomin.v2i2.228.
- [11] D. A. H. Panggabean, F. M. Sihombing, and N. M. Aruan, "Prediksi Tinggi Curah Hujan Dan Kecepatan Angin Berdasarkan Data Cuaca Dengan Penerapan Algoritma Artificial Neural Network (Ann)," *Seminastika*, vol. 3, no. 1, pp. 1–7, 2021, doi: 10.47002/seminastika.v3i1.237.
- [12] W. L. Lo, M. Zhu, and H. Fu, "Meteorology visibility estimation by using multi-support vector regression method," *J. Adv. Inf. Technol.*, vol. 11, no. 2, pp. 40–47, 2020, doi: 10.12720/jait.11.2.40-47.
- [13] V. R. Duddu, S. S. Pulugurtha, A. S. Mane, and C. Godfrey, "Back-propagation neural network model to predict visibility at a road link-level," *Transp. Res. Interdiscip. Perspect.*, vol. 8, no. September, p. 100250, 2020, doi: 10.1016/j.trip.2020.100250.
- [14] L. S. M. B, B. B. Harianto, and A. Musadek, "Airport Visibility Prediction System to Improve Aviation Safety", *Proceedings of the International Conference on Advance Transportation, Engineering, and Applied Science (ICATEAS 2022)*, vol. 1. Atlantis Press International BV, 2023. doi: 10.2991/978-94-6463-092-3.
- [15] A. Saputra, S. R. Sulistiyanti, R. Marjunus, Y. Yuliant, J. Junaidi, and A. Surtono, "Penerapan Jaringan Saraf Tiruan / JST (Backpropagation) untuk Prakiraan Cuaca di Bandar Udara Radin Inten II Lampung," *J. Teor. dan Apl. Fis.*, vol. 11, no. 01, pp. 63–72, 2023, doi: 10.23960/jtaf.v11i1.3164.
- [16] F. M. Madjid, "Perbandingan prediksi visibility menggunakan LSTM dan MLP di Bandara Sultan Mahmud Badaruddin II Palembang," *JSI J. Sist. Inf.*, vol. 14, no. 1, pp. 2497–2507, 2022, doi: 10.18495/jsi.v14i1.16798.
- [17] Krisnawaty, P. Sari Ramadhan, and F. Rizky, "Penerapan Jaringan Saraf Tiruan Memprediksi Curah Hujan Harian



- Menggunakan Metode Backpropagation,” *J. CyberTech*, vol. 3, no. 7, pp. 1297–1306, 2020, [Online]. Available: <https://ojs.trigunadharma.ac.id/>
- [18] M. D. A. Carnegie and C. Chairani, “Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan,” *J. Media Inform. Budidarma*, vol. 7, no. 3, p. 1022, 2023, doi: 10.30865/mib.v7i3.6213.
- [19] E. S. P. Wulandari and R. A. Aziz, “Model Prediksi Dengan Artificial Neural Network Untuk,” *Semin. Nas. Has. Penelit. dan Pengabd. Masy.*, vol. 1, no. 1, pp. 77–84, 2022, [Online]. Available: <https://jurnal.darmajaya.ac.id/index.php/PSND/article/view/3253>
- [20] S. Sunardi, A. Yudhana, and G. Z. Muflih, “Sistem Prediksi Curah Hujan Bulanan Menggunakan Jaringan Saraf Tiruan Backpropagation,” *J. Sist. Inf. Bisnis*, vol. 10, no. 2, pp. 155–162, 2020, doi: 10.21456/vol10iss2pp155-162.
- [21] L. Vinet and A. Zhedanov, “A missing family of classical orthogonal polynomials”, *Journal of Physics A: Mathematical and Theoretical*, vol. 44, no. 8. 2011. doi: 10.1088/1751-8113/44/8/085201.
- [22] N. Hernandoko, P. W. Laksono, and N. Rosyidi, “Penerapan Sistem Kontrol Kualitas Dengan Menggunakan Model CNN Transfer Learning VGG 19 Pada Inspeksi Kain di Industri Tekstil,” *Performa*, vol. 23, no. 2, pp. 166–170, 2024, doi: 10.20961/performa.23.2.86589.
- [23] E. Setia Budi, A. Nofriyaldi Chan, P. Priscillia Alda, and M. Arif Fauzi Idris, “Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network,” *RESOLUSI Rekayasa Tek. Inform. dan Inf.*, vol. 4, no. 5, p. 509, 2024, [Online]. Available: <https://djournals.com/resolusi>