

Prediksi Kabut Bandar Udara di Indonesia Menggunakan Neural Network dan Radom Forest

Agustinus Kurniawan¹, RZ. Abdul Aziz^{2*}

¹Magister Teknik Informatika, IIB Darmajaya, Lampung, Indonesia

²Stasiun Meteorologi Radin Inten II Kelas I Lampung, Lampung, Indonesia

Email: ¹agustinus.2321211028p@mail.darmajaya.ac.id, ²rz_aziz@darmajaya.ac.id

Email Penulis Korespondensi: rz_aziz@darmajaya.ac.id

Submitted: 11/07/2024; Accepted: 08/09/2024; Published: 09/09/2024

Abstrak—Kabut di Bandara sangat mengganggu operasional penerbangan, yang membatasi jarak pandang sehingga berdampak signifikan terhadap operasi penerbangan seperti taxi, lepas landas, dan pendaratan. Prakiraan kabut yang akurat sangat penting untuk memastikan keselamatan penerbangan. Tantangan terbesar dalam prediksi kabut adalah kompleksitas proses atmosfer yang tidak konsisten dan kacau. Penelitian ini menggunakan algoritma Neural Network dan algoritma random forest untuk memprediksi kabut di Bandara Radin Inten II Lampung. Data yang digunakan dalam penelitian ini meliputi 14 atribut cuaca yang dikumpulkan setiap jam dari tahun 2020 hingga 2024. Variabel meteorologi yang dianalisis meliputi suhu bola kering, suhu bola basah, titik embun, kelembaban relatif, tekanan barometrik QFE dan QFF, dan kondisi cuaca terkait kabut. Model prediktif dioptimalkan dengan penyetelan hyperparameter termasuk pemilihan pengoptimal (SGD, Adam), kecepatan pembelajaran (0,001), dan jumlah epoch (300). Hasil penelitian menunjukkan bahwa model random forest dengan konfigurasi optimal memberikan akurasi tertinggi sebesar 69,44% dalam prediksi kabut. Neural Network Backpropagasi juga menunjukkan performa yang baik dengan akurasi 67,23%. Dengan menggunakan model ini, prediksi kabut dapat dibuat lebih akurat dan cepat, sehingga memberikan manfaat signifikan bagi keselamatan penerbangan. Penelitian ini menyoroti pentingnya penggunaan data yang beragam dan metode evaluasi yang ketat untuk menciptakan model prediksi cuaca yang handal dan efektif.

Kata Kunci: Kabut; Prakiraan Cuaca; Prediksi; Artificial Neural Network; Random Forest

Abstract— Fog at airports greatly disrupts flight operations, limiting visibility and thus having a significant impact on flight operations such as taxiing, takeoff and landing. The biggest challenge in fog prediction is the inconsistent and chaotic complexity of atmospheric processes. This research uses the Neural Network algorithm and random forest algorithm to predict fog at Radin Inten II Airport in Lampung. The data used in this study include 14 weather attributes collected hourly from 2020 to 2024. Meteorological variables analyzed include dry bulb temperature, wet bulb temperature, dew point, relative humidity, barometric pressure QFE and QFF, and fog-related weather conditions. The predictive model was optimized by hyperparameter tuning including optimizer selection (SGD, Adam), learning rate (0.001), and number of epochs (300). The research results show that the random forest model with optimal configuration provides the highest accuracy of 69.44% in fog prediction. The Backpropagasi Neural Network also shows good performance well with an accuracy of 67.23%. By using this model, fog predictions can be made more accurate and faster, providing significant benefits to aviation safety. This research highlights the importance of using diverse data and rigorous evaluation methods to create reliable and effective weather prediction models.

Keywords: Fog; Weather Forecast; Prediction; Artificial Neural Network; Random Forest

1. PENDAHULUAN

Karakteristik geografis bandara di Indonesia sangat dipengaruhi oleh letak negara yang terdiri dari ribuan pulau dengan topografi beragam. Topografi yang bervariasi, mulai dari pegunungan tinggi, dataran rendah, hingga wilayah pesisir, menentukan desain dan fasilitas bandara. Bandara di daerah pegunungan menghadapi tantangan seperti kabut tebal dan cuaca ekstrem. Penelitian ini menyoroti Bandara Radin Inten II di Lampung, yang berada di dataran rendah. Meskipun lebih stabil dan sederhana dalam desain serta operasional, bandara ini tetap menghadapi tantangan cuaca yang mempengaruhi operasional penerbangan. Fenomena kabut mengakibatkan berkurangnya jarak pandang baik secara horizontal maupun vertikal. Badan Meteorologi Dunia (WMO) menyatakan kabut merupakan suspensi tetapan air yang sangat kecil, biasanya mikroskopis di udara, sehingga mengurangi jarak pandang di permukaan bumi [1]. Jarak pandang sangat penting bagi pilot, terutama saat lepas landas dan mendarat, jarak pandang yang buruk karena kabut, hujan, atau kabut asap dapat menyulitkan pilot untuk melakukan navigasi dan mendaratkan pesawat dengan aman. Kabut dapat mempengaruhi penerbangan dalam berbagai cara terutama dalam operasi taxi, lepas landas dan pendaratan. Saat ini pada bandara modern sudah banyak dipasang peralatan instrumen landing system (ILS), meskipun demikian tetap saja pilot memerlukan referensi visual untuk melakukan pendaratan dengan aman. Jika pesawat sesaat sebelum mendarat memperoleh informasi dari pengatur lalu lintas (ATC) bahwa jarak pandang buruk, maka pilot harus mengambil keputusan *go-around* atau melakukan pendaratan di bandara terdekat dari bandara tujuan dikarenakan perhitungan jumlah bahan bakar yang dibawa sambil menunggu kondisi cuaca atau jarak pandang membaik.

Meskipun ada kemajuan dalam penelitian sains atmosfer, untuk memprediksi kabut dengan akurat masih sulit karena melibatkan berbagai proses fisik dan kimia serta banyak interaksi nonlinier. Akibatnya, pengembangan model prediksi yang komprehensif dan andal menjadi tantangan tersendiri. Dalam situasi ini, prakirawan cuaca menghadapi tantangan yang besar untuk membuat prakiraan kabut yang akurat untuk

keselamatan penerbangan. Peningkatan lebih lanjut dalam model prediksi cuaca numerik (NWP), platform dan jaringan observasi baru, serta kemampuan analisis yang diperluas melalui kecerdasan buatan dan algoritma pembelajaran mesin merupakan sumber perbaikan potensial untuk prakiraan kabut generasi berikutnya. Banyak peneliti telah mencoba melakukan perbaikan dalam model prediksi cuaca numerik (NWP) dalam hal resolusi vertikal dan horizontal [2][3]. Namun kabut masih sulit diprediksi karena skala lokal, terbatasnya resolusi model, dan terbatasnya pengetahuan tentang atmosfer yang sangat kompleks. Oleh karena itu, banyak faktor yang mengendalikan pembentukan kabut belum disimulasikan dengan baik dalam model NWP[4][5].

Dengan perkembangan kemajuan teknologi saat ini, prakiraan cuaca telah dikembangkan dengan memasukkan data *science* menggunakan *Artificial Intelligence (AI)*. Salah satu permasalahan tersulit dalam prakiraan kabut adalah proses atmosfer yang tidak menentu dari waktu ke waktu. Seringkali peneliti perlu membangun hubungan linier antara data masukan cuaca dan data keluaran, namun kenyataannya data cuaca bukanlah data linier, sehingga fokusnya beralih ke prediksi data cuaca nonlinier. Keunggulan jaringan syaraf tiruan (JST) dibandingkan metode prediksi lainnya adalah kemampuan JST untuk menggunakan algoritma yang berbeda untuk meminimalkan kesalahan dan memberikan nilai prediksi yang mendekati keadaan sebenarnya[6]. Sederhananya, JST adalah alat pemodelan data statistik nonlinier yang dapat digunakan untuk memodelkan hubungan kompleks antara input dan output serta menemukan pola dalam data. Dalam bentuknya yang paling sederhana, JST meniru otak manusia dengan kemampuan mempelajari hal-hal baru dan beradaptasi dengan lingkungan yang berubah. JST mampu memproses data dalam jumlah besar (big data) dan menemukan pola tertentu dari data dalam jumlah besar tersebut. Hal ini sangat berguna dalam prakiraan cuaca, di mana jumlah data yang harus dianalisis sangat besar dan kompleks. Dengan kemampuan ini, JST dapat meningkatkan akurasi prakiraan cuaca secara signifikan, termasuk prakiraan kabut, yang sebelumnya sulit diprediksi dengan model konvensional. Integrasi AI dalam prakiraan cuaca menawarkan harapan baru untuk meningkatkan keandalan dan ketepatan prediksi cuaca, memberikan manfaat besar bagi sektor penerbangan, pertanian, dan berbagai industri lainnya yang sangat bergantung pada informasi cuaca yang akurat.

Teknik jaringan saraf digunakan untuk memprediksi kabut dengan menganalisis data cuaca historis seperti suhu, kelembapan, dan jarak pandang. Jaringan ini terdiri dari lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Melalui proses pembelajaran yang disebut backpropagation, jaringan saraf menyesuaikan bobot koneksi antar neuron untuk mengurangi kesalahan prediksi. Metode ini mampu mengenali pola kompleks dalam data, metode ini memberikan prediksi kabut yang lebih akurat dibandingkan metode tradisional. Sedangkan Metode Random Forest digunakan untuk memprediksi kabut dengan menggabungkan beberapa pohon keputusan yang dibangun dari kumpulan data cuaca historis seperti suhu, kelembapan, dan jarak pandang. Setiap pohon keputusan memberikan satu prediksi, dan hasil akhirnya ditentukan dari prediksi sebagian besar pohon. Metode ini menggunakan banyak pohon dan membuat rata-rata hasilnya, sehingga tahan terhadap overfitting dan meningkatkan akurasi prediksi. Random Forest dapat menangkap hubungan kompleks dalam data, sehingga memungkinkan membuat prediksi kabut yang lebih andal untuk mendukung sistem peringatan dini dan manajemen lalu lintas penerbangan di Bandara.

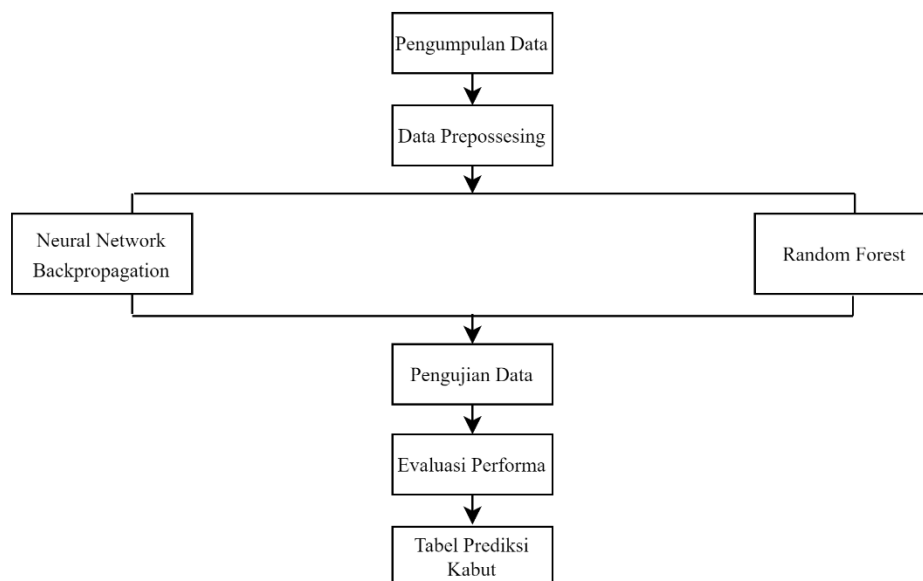
Penelitian lain telah mencoba menggunakan algoritma pohon keputusan dari data cuaca dalam model NWP untuk mengambil keputusan ketika membuat prediksi kabut[7]. Beberapa algoritma berbasis regresi telah diuji untuk menemukan algoritma prediksi visibilitas yang optimal. Prediksi visibilitas di bandara [8][9] dilakukan dengan membangun model regresi menggunakan algoritma deep learning menggunakan data observasi meteorologi sinoptik. Sebagai contoh, penelitian menggunakan pohon keputusan untuk prediksi cuaca, termasuk kabut, dengan hasil yang cukup akurat[10]. Analisis komparatif pada algoritma regresi untuk prediksi visibilitas, menemukan bahwa beberapa algoritma memiliki performa yang lebih baik dalam kondisi tertentu[11]. Menggunakan model deep learning untuk memprediksi visibilitas di bandara, menunjukkan bahwa pendekatan ini mampu menghasilkan prediksi yang lebih akurat dibandingkan metode tradisional[12]. Perbedaan penelitian ini dengan penelitian sebelumnya terletak pada lokasi penelitian dan keberagaman data inputan pelatihan serta pengujian yang digunakan. Dalam penelitian ini, data inputan untuk prediksi kabut tidak hanya menggunakan kelembapan, tetapi juga data suhu udara. Keberagaman data ini diharapkan dapat menghasilkan ide-ide baru yang melengkapi penelitian sebelumnya. Prakiraan kabut akan lebih informatif jika hasil yang diperoleh akurat. Keuntungan model peramalan kecerdasan buatan adalah objektivitasnya tidak bergantung pada subjektivitas peramal. Selain itu, proses pembuatan prediksi juga lebih cepat, memberikan manfaat signifikan bagi operasional penerbangan yang memerlukan keakuratan dan kecepatan dalam penyediaan layanan informasi cuaca.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Pada Gambar 1 adalah penjelasan tahapan penelitian yang dilakukan menggunakan algoritma Neural Network dan Random Forest untuk prediksi kabut di wilayah Bandara Radin Inten II Lampung, serta tahap penerapan metode dan metode pengujian yang digunakan untuk memperoleh hasil penelitian sesuai dengan yang diharapkan.

Langkah awal dalam penelitian ini adalah pengumpulan data meteorologi, termasuk informasi kabut, dll. Data ini dapat berasal dari sumber seperti stasiun observasi meteorologi atau sumber terpercaya lainnya. Data cuaca yang telah dikumpulkan, langkah selanjutnya adalah proses membersihkan data. Selama proses ini, dapat dilakukan tindakan seperti menghapus data yang tidak relevan, mengisi atau menghapus nilai yang hilang, dan membersihkan data yang tidak valid. Setelah itu mulai membangun model dengan menggunakan Neural network dengan metode backpropagation digunakan untuk membangun model prediksi kabut. Model ini dilatih menggunakan data yang telah diproses untuk memprediksi kemungkinan terjadinya kabut berdasarkan pola-pola dalam data historis. Sebagai metode pembandingan, algoritma Random Forest digunakan untuk membangun model prediksi yang berbeda. Random Forest adalah ensemble learning method yang menggabungkan beberapa pohon keputusan untuk meningkatkan akurasi prediksi. Model yang telah dibangun diuji menggunakan data uji untuk mengevaluasi performanya. Tahap ini melibatkan penggunaan data yang tidak digunakan selama pelatihan untuk melihat seberapa baik model dapat memprediksi kabut. Performa dari kedua model (Neural Network dan Random Forest) dievaluasi menggunakan metrik evaluasi yang sesuai, seperti akurasi, presisi, recall, dan F1-score. Perbandingan antara kedua model dilakukan untuk menentukan model mana yang lebih efektif dalam memprediksi kabut. Hasil prediksi dari kedua model disajikan dalam bentuk tabel prediksi kabut. Tabel ini menunjukkan hasil prediksi untuk data uji dan dapat digunakan untuk analisis lebih lanjut atau sebagai informasi yang bermanfaat bagi pengguna yang membutuhkan prediksi kabut.



Gambar 1. Tahapan Penelitian

Dalam penelitian ini, beberapa input digunakan saat menjalankan Neural Network atau Random Forest yang sering disebut dengan istilah multivariate. Berbeda dengan pendekatan univariate yang hanya mengambil satu atribut sebagai masukan, pendekatan multivariate adalah metode statistik yang memungkinkan melakukan penelitian terhadap satu atau lebih dari dua variabel secara bersamaan. Dengan menggunakan data multivariate, model Neural Network atau Random Forest dapat mempelajari korelasi dan interaksi antara atribut-atribut tersebut. Selama proses pelatihan, model Neural Network atau Random Forest menggunakan data cuaca historis untuk menganalisis hubungan antar atribut cuaca dari waktu ke waktu. Misalnya, model tersebut mempelajari bahwa ketika suhu tinggi dan kelembapan rendah, kemungkinan tidak terjadinya kabut. Atau mungkin ada pola tertentu yang menunjukkan bahwa ketika tekanan udara turun dengan cepat, cenderung terjadi kabut. Pada tahap prediksi, model akan mengambil nilai aktual dari atribut saat ini dan menggunakan pengetahuan yang diperoleh selama proses pelatihan untuk memprediksi kabut yang akan mungkin terjadi.

2.2 Pengumpulan Data

Data yang digunakan seperti pada Tabel 1. Tabel Variable Input dalam penelitian ini adalah data pengamatan sinoptik per-Jam pada Stasiun Meteorologi Radin Inten II dengan periode Januari 2020 sampai Mei 2024. Variabel yang digunakan meliputi 14 unsur cuaca yaitu jam pengamatan, suhu bola kering (jam 09.00 dan 12.00), suhu bola basah (jam 09.00 dan 12.00), titik embun (jam 09.00 dan 12.00), dan kelembapan relatif (jam 09.00 dan 12.00, QFE (jam 09.00 dan 12.00, QFF (jam 09.00 dan 12.00), dan kondisi cuaca yang menunjukkan ada tidaknya kabut. Dalam penelitian ini, kejadian mist tetap dihitung sebagai kejadian kabut karena merupakan kabut renggang dan mengurangi jarak pandang hingga kurang dari 5 km yang berpotensi mengganggu operasional penerbangan. Jumlah data keseluruhan yang digunakan dalam penelitian ini adalah 1200 baris.

Variabel-variabel cuaca yang dipilih dalam penelitian ini dipertimbangkan dengan alasan tertentu. Variabel suhu bola kering, suhu bola basah, dan kelembapan relatif merupakan variabel yang saling berkaitan. Suhu bola basah dan bola kering digunakan untuk menghitung titik embun dan kelembapan relatif. Suhu bola kering dan titik embun yang saling berdekatan menunjukkan kelembapan relatif yang tinggi. Kejadian kabut dan mist ditandai dengan nilai kelembapan relatif yang tinggi yaitu antara 95% hingga 100%. Variabel kondisi cuaca dalam data penelitian ini dikategorikan menjadi 3 yaitu br (mist), haze, dan fog. Variabel jam pengamatan dimasukkan ke dalam model dengan pertimbangan kabut sering terjadi pada dini hari.

Tabel 1. Tabel Variable Input

No	Variable	Kode	Tipe Data	Satuan
1	Jam Pengamatan	Jam	Faktor	Jam
2	Bola Kering 09	bk09	Numeric	°C
3	Bola Kering 12	bk12	Numeric	°C
4	Bola Basah 09	bb09	Numeric	°C
5	Bola Basah 12	bb12	Numeric	°C
7	Titik Embun 09	td09	Numeric	°C
8	Titik Embun 12	td12	Numeric	°C
9	Kelembapan 09	rh09	Numeric	%
10	Kelembapan 09	rh12	Numeric	%
11	QFF (Q-Field Forecast) 09	qff09	Numeric	Mb
12	QFF (Q-Field Forecast) 12	qff12	Numeric	mb
13	QFE(Query Field Elevation) 09	qfe09	Numeric	mb
14	QFE(Query Field Elevation) 12	qfe12	Numeric	mb
15	Kondisi Cuaca	ww	actor	Br/Hz/Fg

2.3 Preprocessing Data

Preprocessing data adalah langkah penting dalam analisis data yang membersihkan, mengubah, dan mengurutkan data untuk meningkatkan kualitas dan kegunaannya sebelum digunakan dalam model prediktif. Proses ini melibatkan berbagai teknik, seperti menghapus data yang tidak relevan atau duplikat, menangani nilai yang hilang, normalisasi atau standarisasi nilai atribut, dan mengubah format data agar konsisten. Misalnya, penelitian prediksi cuaca memerlukan pemrosesan data cuaca mentah sehingga model dapat mendeteksi pola penting dan menghasilkan prakiraan yang akurat. Tanpa pra-pemrosesan yang tepat, gangguan dan ketidakkonsistenan dalam data cenderung menyebabkan model mengalami overfit atau memberikan hasil yang kurang akurat. Preprocessing yang efektif dapat meningkatkan performa model pembelajaran mesin secara signifikan, terutama dalam aplikasi kompleks seperti prakiraan cuaca [13].

2.4 Neural Network

Artificial Neural Network adalah jaringan saraf yang bisa mensimulasikan jaringan saraf biologis manusia kedalam arsitektur computer serta arsitektur algoritma baru terhadap computer konvensional. Hal ini memungkinkan Anda menggunakan operasi aritmatika yang sangat sederhana (penjumlahan, pengurangan, dan elemen logika dasar) untuk menyelesaikan masalah matematika, nonlinier, atau probabilistik yang kompleks [14]. Keuntungan utama jaringan saraf adalah kekuatan prediktif, kecepatan, dan ketahanan terhadap data yang hilang. Artificial Neural Network adalah suatu sistem pemroses data yang memiliki karakteristik menyerupai dengan jaringan saraf biologi yang ada pada manusia pada umumnya [15]. Jaringan saraf didefinisikan sebagai sistem komputer yang arsitektur dan fungsinya didasarkan pada pengetahuan tentang neuron biologis di otak manusia. Ini adalah representasi buatan dari otak manusia itu sendiri, yang terus-menerus berusaha merangsang proses pembelajaran otak manusia.

2.5 Random Forest

Random forest, mempunyai beberapa karakteristik penting. Artinya, menghasilkan hasil yang tahan terhadap overfitting, mampu menangani data yang hilang, kuat terhadap outlier, dan tetap dapat diandalkan bahkan ketika ada perubahan kecil pada data [16]. Random Forest juga memiliki kemampuan untuk menentukan pentingnya setiap variabel dalam prediksi, yang sangat membantu dalam memahami dan menafsirkan data. Keuntungan utama dari random forest adalah kekuatan prediktifnya, fleksibilitasnya untuk menangani berbagai jenis data (baik numerik maupun kategorikal), dan ketahanannya terhadap overfitting melalui penggunaan teknik ansambel. Random forest adalah algoritma pembelajaran mesin yang efisien dan efektif yang menggunakan kombinasi sederhana pohon keputusan untuk mencapai hasil prediksi yang tinggi dan stabil, sehingga dapat digunakan untuk klasifikasi, regresi, dan sangat populer untuk berbagai aplikasi seperti klasifikasi, regresi, dan pemilihan fitur [17].

2.6 Neural Network Backpropagation

Neural Network Backpropagation (NNBP), adalah metode pelatihan yang digunakan dalam jaringan saraf tiruan untuk mengoptimalkan bobot neuron melalui penurunan gradien[18][19]. Propagasi mundur menggunakan aturan rantai untuk menghitung kemiringan fungsi kesalahan (fungsi kerugian) untuk setiap bobot dan memperbarui bobot untuk meminimalkan kesalahan. Proses backpropagation terdiri dari dua fase utama yaitu forward pass dan backward pass[20]. Pada forward pass, masukan diproses oleh jaringan untuk menghasilkan keluaran yang diprediksi. Dalam backward pass, kesalahan dihitung sebagai selisih antara keluaran yang diprediksi dan yang diharapkan. Gradien kesalahan kemudian dihitung dan digunakan untuk memperbarui bobot jaringan dari lapisan keluaran kembali ke lapisan masukan. Keuntungan utama propagasi mundur adalah jaringan saraf multilayer dapat dilatih dengan efisiensi tinggi, memungkinkan jaringan mempelajari representasi kompleks dari data masukan. Backpropagation adalah dasar dari banyak algoritma deep learning modern karena efektivitasnya dalam mengoptimalkan jaringan saraf besar dengan banyak parameter[21].

2.7 Prediksi Kabut

Keakuratan prediksi kabut menggunakan parameter tertentu sangat penting untuk menjadi acuan pada masa depan dalam memprediksi kejadian kabut. Akibat kejadian kabut yang terjadi dapat menyebabkan gangguan operasional penerbangan pada suatu bandara. Prediksi adalah formasi antara seni dan juga ilmu untuk memperkirakan keadaan di masa depan nantinya, dengan cara memproyeksikan data-data masa lampau ke masa yang akan datang dengan memakai contoh matematika maupun perkiraan yang subjektif[22]. Prediksi kabut dapat dikatakan menjadi seni serta ilmu untuk memprediksi keadaan kabut pada masa depan dengan cara mempelajari data kejadian kabut pada masa lalu lewat model matematika sehingga diperoleh sebuah formula yang nantinya dapat digunakan untuk membuat prediksi kabut di kemudian hari sehingga manfaatnya dapat dirasakan orang banyak.

2.8 Evaluasi

Evaluasi sangat penting untuk mengetahui kinerja serta mengidentifikasi kelebihan dan kekurangan metode sehingga dapat diperbaiki melalui penyesuaian dan modifikasi. Evaluasi metode menggunakan statistik menggunakan data yang tersedia dan analisis rentang variasi untuk menentukan kinerja metode. Teknik statistik yang biasa digunakan untuk melakukan evaluasi antara lain:

a. Root Mean Square Error (RMSE)

RMSE digunakan untuk menghitung jumlah kesalahan prediksi suatu metode, menghitung selisih antara nilai aktual dan yang diharapkan, membagi hasil total yang diperoleh dengan nilai prediksi, dan mengambil akar kuadrat [23].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{1}$$

b. Mean Absolute Error (MAE)

Mean Absolute Error digunakan dalam pengukuran tingkat keakuratan model prediksi. Nilai MAE menunjukkan rata-rata kesalahan absolut antara hasil prediksi dengan nilai riil[24].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{2}$$

c. Confusion Matrix

Confusion matrix merupakan hasil ringkasan kinerja proses klasifikasi relatif terhadap data uji. Mengukur performa memungkinkan Anda mengetahui seberapa baik performa model Anda. Proses klasifikasi matriks konfusi memiliki empat kategori: True Positive (TP), False Positive (FP), True Negatif (TN) dan False Negative (FN)[25].

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <small>Type I Error</small>
	0 (Negative)	FN (False Negative) <small>Type II Error</small>	TN (True Negative)

Gambar 2. Confusion Matrix

Hasil evaluation juga didasari pada Confusion Matrix seperti yang ada digambar 2. Evaluation dibutuhkan untuk melihat hasil dengan cara menampilkan accuracy, f1_score, precision, recall, dan. ROC AUG

1. Accuracy : menghitung keakuratan sebuah model dalam melakukan klasifikasi



$$Accuracy = \frac{TN+TP}{TN+TP+FP+FN} \tag{3}$$

2. Precision : menunjukkan tingkat akurasi antara data yang diminta dan hasil prediksi model. Artinya, rasio prediksi positif yang sebenarnya dibandingkan dengan seluruh hasil prediksi positif.

$$Precision = \frac{TP}{TP+FP} \tag{4}$$

3. Recall : menggambarkan keberhasilan sebuah model dalam pencarian informasi. Sehingga rasio prediksi benar positif terhadap semua prediksi benar-positif.

$$Recall = \frac{TP}{TP+FN} \tag{5}$$

4. F1-score menunjukkan perbandingan nilai precision dan recall yang telah dibobotkan

$$f1 - score = 2 \frac{Precision \times Recall}{Precision + Recall} \tag{6}$$

5. ROC AUC menggambarkan metrik evaluasi yang digunakan untuk mengukur performa model klasifikasi. Menghitung TPR dan FPR:

- a. TPR (True Positive Rate), juga dikenal sebagai sensitivitas atau recall, dihitung sebagai:

$$TPR = \frac{True\ Positive\ (TP)}{True\ Positive\ (TP) + False\ Negative\ (FN)} \tag{7}$$

- b. FPR (False Positive Rate), juga dikenal sebagai 1-specificity, dihitung sebagai:

$$FPR = \frac{False\ Positive\ (FP)}{False\ Positive\ (FP) + True\ Negative\ (TN)} \tag{8}$$

3. HASIL DAN PEMBAHASAN

3.1 Pengujian Data

Pengujian data dilakukan sebanyak 3 kali untuk model Neural Network Backpropagasi dan Random Forest. Proses ini merupakan proses untuk memperoleh hasil prediksi yang baik. Jumlah data yang digunakan berjumlah 12 data yang digunakan sebagai data pengujian dan 1 data sebagai target pengujian. Data ini akan diuji melewati proses pengujian data dari masing-masing konfigurasi pelatihan data untuk mendapatkan korelasi atau R pengujian dan juga proses perhitungan akurasi. Data pada Tabel 2. Tabel Data Pengujian digunakan sebagai data pengujian juga telah dipilih dengan secara acak agar didapatkan hasil prediksi kabut yang baik dengan mempelajari pola-pola dari parameter yang dipilih. Data tersebut untuk mengukur performa dari sistem yang dijalankan.

Tabel 2. Tabel Data Pengujian

bk09	bk12	bb09	bb12	td09	td12	rh09	rh12	qff09	qff12	qfe09	qfe12
22,4	24,7	22,4	24,1	22,4	23,8	0	95	1004,8	1007,1	994,8	997
30	27,9	24,8	23,6	22,2	21,4	63	68	1008,8	1009,2	998,7	999,6
24	23,9	22,7	23,1	22,1	22,7	89	93	1007,8	1009,1	997,6	998,8
29	27,2	25	25	23	23,9	70	82	1009	1010,8	998,8	1000,6
29	27,4	25,1	24,3	23,2	22,8	71	76	1005,4	1007,9	995,8	998,3
29,2	27	25,9	25,4	24,3	24,6	75	87	1007,1	1008,5	996,9	998,2
32,7	29,2	26,8	25,7	23,9	23,9	60	73	1005	1006,8	994,8	996,6
26,7	25,4	25	24,2	24,2	23,6	86	90	1008,7	1010,9	998,5	1000,6
26,4	24,8	23,8	23,5	22,5	22,9	79	89	1009,3	1010,8	999	1000,7
24,7	24,5	23,9	23,7	23,5	23,3	93	93	1009,5	1010,4	999,3	1000,2
30	27,9	25,8	25,4	23,7	24,1	69	80	1009,3	1010,5	999	1000,3
33,3	28,6	25,2	24,1	21,1	21,9	49	67	1009,1	1010,7	998,8	1000,5
29,5	25,3	26,2	23,6	24,6	22,8	75	86	1008,4	1011,9	998,3	1001,8
30,7	27,8	26,5	25,3	24,4	24	69	80	1007,7	1009,2	997,5	999
30,7	28,1	25,3	24,8	22,6	23,2	62	75	1009,4	1010,8	999,1	1000,5
30,6	26,5	24,7	24,4	21,7	23,4	59	83	1005,7	1007,7	995,5	997,5
28,5	26,6	24,5	23,1	22,5	21,4	70	73	1006,9	1008,6	997,3	998,9



Berdasarkan Tabel 3 hasil pengujian dan akurasi model neural network, hasil pengujian didapatkan nilai korelasi atau R menggunakan tiga konfigurasi model yang berbeda, konfigurasi 1 menunjukkan performa terbaik dengan 4 lapisan tersembunyi, 50 neuron, dan 300 epoch, mencapai akurasi 67,23 n dan diperoleh hasil pengujian yang baik. nilai yang ditunjukkan oleh R selisih -0,09. model ini mampu menangkap pola pada data pelatihan dan pengujian dengan sangat baik. Pada konfigurasi 2 hasilnya kurang memuaskan karena konfigurasi 2 yang mencakup 3 lapisan tersembunyi, 40 neuron, dan 200 epoch memiliki akurasi 61,02%, menunjukkan nilai R -0,10. Meskipun jumlah lapisan tersembunyi dan neuron sedikit lebih kecil, model ini gagal mempertahankan performa yang konsisten antara data pelatihan dan pengujian. Sedangkan Konfigurasi 3 dengan dua lapisan tersembunyi (30 neuron dan 100 epoch) memiliki akurasi 63,28%, namun memiliki nilai R -0,16 yang lebih tinggi, menunjukkan bahwa model terlalu banyak untuk menangkap kompleksitas data yang ditampilkan Secara keseluruhan, konfigurasi 1 memberikan hasil terbaik.. Proses penilaian akurasi ini diperoleh dari hasil output pengujian dibandingkan dengan target data pengujian yang telah disiapkan. Konfigurasi dengan nilai akurasi terbaik akan digunakan untuk maju ke proses selanjutnya yaitu proses prediksi kejadian kabut.

Tabel 3. Hasil pengujian dan akurasi model neural network

Konfigurasi	Jumlah Hidden Layer	Jumlah Neuron	Epoch	R Latih	R Uji	Selisih R	Error	Akurasi (%)	Hasil Uji
1	4	50	300	0.37	0.28	-0.09	0.43	67.23	Baik
2	3	40	200	0.36	0.26	-0.10	0.43	61.02	Kurang Baik
3	2	30	100	0.38	0.23	-0.16	0.42	63.28	Kurang Baik

Berdasarkan Tabel 4. Hasil pengujian dan akurasi model random forest, hasil pengujian didapatkan nilai korelasi atau R menggunakan tiga konfigurasi model dengan jumlah estimator, max depth, min samples split, dan min samples leaf yang berbeda, konfigurasi 2 dan 3 memiliki akurasi tertinggi yaitu sebesar 69,4%, walaupun memiliki karakteristik kinerja yang berbeda. Konfigurasi 2 dengan jumlah estimator 200, kedalaman maksimum 20, pemisahan sampel minimum 5, dan lembar sampel minimum 2 menunjukkan kinerja yang baik dengan nilai R pelatihan sebesar 0,97, nilai R uji sebesar 0,45, dan selisih R sebesar 0,51 , menunjukkan hasil performa yang baik. Konfigurasi 3 menggunakan 300 estimator, maksimum depth 30, minimum sampling split 10, minimum sampling leaf 4, dan menunjukkan nilai training R sebesar 0,87 dan nilai R test sebesar 0,42, dengan selisih R sebesar 0,45 yang berarti juga menunjukkan nilai R. Namun, ini lebih rendah dari konfigurasi 2. Konfigurasi 1 dengan 100 estimator, kedalaman maksimum 10, pemisahan sampel minimum 2 dan lembar sampel minimum 1 mempunyai akurasi sebesar 66,7%, R latih 0,95, R uji 0, 43, dan R selisih 0,52, dengan R lebih menunjukkan nilai R yang signifikan dibandingkan dengan konfigurasi lainnya. Namun seluruh konfigurasi menunjukkan performa yang baik dengan nilai akurasi di atas 66%.

Tabel 4. Hasil pengujian dan akurasi model random forest

Konfigurasi	Jumlah Estimators	Max Depth	Min Samples Split	Min Samples Leaf	R Latih	R Uji	Selisih R	Error	Akurasi (%)	Hasil Uji
1	100	10	2	1	0.95	0.43	0.52	0.03	66.7	Baik
2	200	20	5	2	0.97	0.45	0.51	0.02	69.4	Baik
3	300	30	10	4	0.87	0.42	0.45	0.06	69.4	Baik

3.2 Evaluasi Model Prediksi Kabut

Berdasarkan data Tabel 5 Hasil evaluasi model prediksi kabut, performa dua model machine learning yang berbeda, yaitu Neural Network Backpropagation dan Random Forest, hasil analisis perbandingan performa yang berdasarkan pada beberapa metrik evaluasi.

Tabel 5. Hasil Evaluasi Model Prediksi Kabut

Model	Accuracy (%)	F1 score (%)	Precision (%)	Recall (%)	ROC AUC (%)	RMSE (%)	MAE (%)
Neural Network Backpropagation	67.23	75.42	65.93	88.12	65.19	0.48	0.45
Random Forest	69.44	68.87	69.52	68.22	75.74	0.45	0.41

Dari segi akurasi dapat dilihat pada Rumus (3), random forest (69.44%).lebih baik daripada neural network (67.23%). Akurasi yang cukup tinggi (69.44%) menunjukkan bahwa model Random Forst cenderung memberikan prediksi yang benar secara keseluruhan. Dalam konteks jurnal, ini menunjukkan keandalan dan efektivitas model dalam mengklasifikasikan kondisi kabut. Akurasi yang Cukup Baik dari Neural Network,



meskipun akurasi (67.23%) sedikit lebih rendah daripada Random Forest, tetapi masih menunjukkan tingkat keandalan model dalam mengklasifikasikan data.

Dalam hal F1 score dapat dilihat pada Rumus (6) , neural network (75.42%) juga sedikit lebih baik daripada random forest (68.78%), menunjukkan keseimbangan antara precision dan recall yang lebih baik. F1 Score yang seimbang ditunjukkan dari ketiga model Neural Network, F1 score yang tinggi (75.43%) menunjukkan bahwa model neural network mencapai keseimbangan yang baik antara presisi (ketepatan prediksi positif) dan recall (ketepatan menemukan semua instance positif). Ini penting dalam konteks jurnal karena menunjukkan bahwa model dapat memberikan prediksi yang konsisten dan tidak terlalu memihak pada salah satu kelas. F1 Score yang wajar diperoleh model Radon Forest dengan score (68.78%) yang cukup tinggi menunjukkan bahwa model random forest juga mampu mencapai keseimbangan antara presisi dan recall.

Untuk Precision dan recall dapat dilihat pada Rumus (4)(5) untuk neural network (65.93%), (88.12%) lebih baik daripada random forest (69.52%, 68.22%) secara berturut-turut. Ini menunjukkan bahwa neural network memiliki kecenderungan lebih baik dalam mengidentifikasi kasus positif (kabut) secara tepat dan dalam mengambil seluruh kasus positif. Precision yang relatif tinggi (69.52%) menunjukkan bahwa dari semua prediksi yang diklasifikasikan sebagai kabut oleh model, sebagian besar di antaranya memang benar-benar kabut. Hal ini penting dalam konteks jurnal karena membuktikan kemampuan model dalam mengidentifikasi kondisi kabut secara akurat. Recall yang tinggi (100%) menunjukkan bahwa model mampu menemukan sebagian besar kasus kabut yang sebenarnya. Dalam konteks jurnal, hal ini menunjukkan kehandalan model dalam mengidentifikasi kasus kabut, yang penting untuk tujuan pemantauan lingkungan. Untuk Random Forest Precision dan Recall Seimbang: Precision (65.93%) dan recall (68.22%) yang cukup seimbang menunjukkan kemampuan model dalam mengidentifikasi kasus kabut tanpa terlalu banyak mengorbankan salah satu metrik yang lain. Meskipun ROC AUC dapat dilihat pada Rumus (7)(8) untuk random forest (75.74%) sedikit lebih tinggi daripada neural network (65.19%), perbedaannya tidak signifikan.

Nilai RMSE dapat dilihat pada Rumus (1) dari kedua arsitektur model yang terbaik adalah Random Forest dengan nilai 0.45 sedangkan nilai neural network 0.48 dari arsitektur model. Nilai RMSE dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat. Nilai MAE dapat dilihat pada Rumus (2), pada random forest sebesar 0.45 sedangkan nilai neural network 0.48 dari arsitektur model. Menunjukkan bahwa nilai MAE Random Forest lebih baik dibandingkan Neural network yang menandakan bahwa tingkat keakuratan lebih baik model dalam melakukan suatu prediksi.

3.3 Analisis Prediksi Kabut/Tidak Kabut

Kita menguji metrik untuk memutuskan model mana yang lebih baik dari yang lain., metrik diurutkan berdasarkan Accuracy, F1 score, Precision, Recall, ROC AUC, RMSE, dan MAE. Model terbaik ditemukan yaitu Random Forest yang menghasilkan performa terbaiknya diantara model lainnya. Setelah model prediksi terbaik diperoleh melalui proses tersebut, langkah selanjutnya adalah menguji model tersebut. Confusion matrix adalah metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi. Berdasarkan nilai error pada kolom total, kita dapat mengetahui keakuratan model prediksi yang dibangun.

Tabel 6. Confusion Matrix with Error (%): BPPN

	FOG	NO FOG	ERROR %	
FOG	30	46	39.47	60.53
NO FOG	12	89	11.88	88.12
TOTAL	42	135		

Berdasarkan hasil analisis Tabel 6. Confusion Matrix with Error (%): BPPN , model tersebut menunjukkan performa yang berbeda dalam mendeteksi kondisi kabut (FOG) dan kondisi tanpa kabut (NO FOG). Untuk kondisi kabut, model berhasil memprediksi dengan benar sebanyak 30 kasus dari total 76 kasus yang teridentifikasi sebagai kabut, yang menghasilkan tingkat akurasi sebesar 39.47% dan tingkat kesalahan sebesar 60.53%. Sedangkan untuk kondisi tanpa kabut, model berhasil memprediksi dengan benar sebanyak 89 kasus dari total 101 kasus yang teridentifikasi sebagai tanpa kabut, menghasilkan tingkat akurasi sebesar 88.12% dan tingkat kesalahan sebesar 11.88%.

Tabel 7. Confusion Matrix with Error (%): Random Forest

	FOG	NO FOG	ERROR %	
FOG	77	32	70.64	29.63
NO FOG	34	73	31.78	68.22
TOTAL	111	105		



Kemudian untuk Tabel 4. Confusion Matrix with Error (%): Random Forest, model menunjukkan performa yang bervariasi dalam mendeteksi kondisi kabut (FOG) dan kondisi tanpa kabut (NO FOG). Dari confusion matrix, terlihat bahwa model berhasil memprediksi dengan benar 77 dari 109 kasus kabut, menghasilkan tingkat akurasi sebesar 70.64% dan tingkat kesalahan sebesar 29.63% untuk kondisi kabut. Untuk kondisi tanpa kabut, model berhasil memprediksi dengan benar 73 dari 107 kasus, dengan tingkat akurasi sebesar 68.22% dan tingkat kesalahan sebesar 31.78%. Analisis ini menunjukkan bahwa model Random Forest memiliki kinerja yang cukup baik dalam mendeteksi kondisi kabut, dengan akurasi yang sedikit lebih tinggi untuk kabut dibandingkan tanpa kabut.

Berdasarkan analisis yang telah dilakukan pada berbagai model prediksi kabut, terlihat bahwa setiap model memiliki kelebihan dan kekurangan dalam mendeteksi kondisi kabut dan tanpa kabut. Neural Network Backpropagation menunjukkan tingkat akurasi keseluruhan sebesar 67.23%, dengan sensitivitas yang rendah untuk kondisi kabut (11.88%) dan spesifisitas yang tinggi untuk kondisi tanpa kabut (88.12%). Model Random Forest memiliki performa yang lebih seimbang, dengan akurasi 69.44% untuk kabut dan 68.22% untuk kondisi tanpa kabut.

Dari kedua model yang dianalisis, Random Forest menunjukkan performa yang paling seimbang dan relatif lebih tinggi dalam mendeteksi kondisi kabut dibandingkan model lainnya, dengan akurasi 69.44% untuk kabut dan 66.36% untuk kondisi tanpa kabut. Neural Network Backpropagation menunjukkan performa yang cukup baik dalam mendeteksi kondisi tanpa kabut tetapi kurang efektif dalam mendeteksi kondisi kabut.

3.4 Prediksi Kabut

Berdasarkan data prediksi kabut pada Tabel 8. Tabel prediksi kabut Neural Network Backpropagasi yang berisi berbagai data variabel meteorologi yaitu suhu udara (bk09 dan bk12), kelembaban udara (rh09 dan rh12), dan tekanan udara (qff09, qff12, qfe09, dan qfe12), dapat diambil sebuah kesimpulan bahwa suhu udara berkisar antara 24-34°C dan kelembaban udara berkisar antara 44-100%, dan tekanan udara menunjukkan variasi yang signifikan. Prediksi kejadian kabut, yang dinyatakan dalam persentase, menunjukkan variasi yang menggambarkan kondisi cuaca yang berbeda. Data menunjukkan bahwa suhu dan kelembaban memiliki pengaruh signifikan terhadap prediksi kabut. Pada suhu lebih rendah, sekitar 24-26°C, dengan kelembaban tinggi (80-100%), prediksi kabut cenderung lebih tinggi, mencapai hingga 80%. Sebaliknya, pada suhu lebih tinggi, sekitar 30-34°C, dengan kelembaban rendah (44-68%), prediksi kabut menurun drastis, sering kali di bawah 40%. Tekanan udara juga menunjukkan korelasi dengan kejadian kabut, dimana tekanan yang lebih stabil dan sedikit fluktuasi mendukung prediksi kabut yang lebih tinggi. Secara keseluruhan, data ini menunjukkan bahwa kombinasi suhu udara yang lebih rendah dan kelembaban tinggi lebih mendukung pembentukan kabut, sedangkan suhu tinggi dengan kelembaban rendah cenderung mengurangi kemungkinan terjadinya kabut.

Tabel 8. Tabel prediksi kabut Neural Network Backpropagasi

bk09	bk12	bb09	bb12	td09	td12	rh09	rh12	qff09	qff12	qfe09	qfe12	Prediksi (%)
31.3	29.3	26.3	26.4	23.8	25.0	65	78	1000.7	1009.6	998.2	1000.0	57
31.7	28.7	26.5	26.1	23.9	24.8	64	80	1006.1	1008.8	996.6	999.2	59
31.5	29.4	27.0	26.9	24.8	25.7	68	81	1006.4	1008.6	996.9	999.0	66
28.3	24.0	25.4	23.9	40.0	23.9	78	100	1008.6	1011.7	999.0	1001.9	31
31.6	26.8	26.8	24.9	24.4	24.0	66	85	1007.3	1010.3	997.7	1000.5	67
30.7	28.2	26.6	25.9	24.5	24.7	70	82	1006.9	1010.0	997.4	1000.3	68
24.6	25.1	24.4	25.0	24.3	25.0	99	100	1008.8	1010.5	999.1	1000.7	80
25.6	24.8	24.7	24.5	24.3	24.4	93	98	1000.9	1010.7	999.5	1000.9	56
31.5	27.3	26.8	25.3	24.5	24.3	67	84	1000.6	1009.0	996.8	999.2	57
27.2	27.4	25.2	25.8	24.2	24.9	84	87	1007.2	1008.7	997.5	999.0	69
29.7	28.3	27.1	24.8	25.8	23.1	80	74	1007.1	1010.0	997.5	1000.3	42
29.3	27.8	25.8	25.1	24.1	23.7	74	79	1007.8	1009.2	998.2	999.5	72
28.3	26.7	24.8	24.1	23.1	22.9	74	80	1008.1	1009.7	998.5	1000.0	69
30.0	29.6	26.5	26.7	24.6	25.3	72	78	1006.8	1008.9	997.2	999.2	67
30.3	27.1	26.3	24.9	24.3	23.9	71	83	1006.8	1009.2	997.2	999.5	72
29.1	26.2	25.5	25.1	23.7	24.5	73	91	1008.0	1008.5	997.9	998.8	73
30.3	28.5	26.3	25.5	24.3	24.0	71	77	1007.0	1008.4	997.4	998.7	70



29.8	29.1	26.0	25.9	24.1	24.3	72	76	1006.7	1008.2	997.1	998.6	59
25.7	25.5	25.3	24.9	25.1	24.5	97	95	1008.9	1010.6	999.1	1000.8	79
33.9	30.3	25.2	24.3	20.9	21.3	47	59	1007.2	1009.4	997.8	999.9	35
31.7	30.3	26.0	25.4	23.1	22.9	61	65	1007.9	1010.1	998.1	1000.4	39
34.4	30.5	25.0	23.3	20.0	19.7	44	53	1008.5	1010.8	999.1	1001.2	29
34.1	30.8	25.9	24.0	21.8	20.6	49	55	1009.2	1010.2	999.1	1000.6	35
29.6	27.8	25.2	24.2	23.0	22.4	68	73	1010.0	1010.3	1000.4	1000.6	76
32.5	30.4	27.5	25.9	25.0	23.7	65	68	1010.5	1012.5	1000.4	1002.4	69
32.4	27.9	26.9	25.2	24.1	23.8	62	79	1010.3	1011.7	1000.8	1002.0	69
29.3	27.0	25.7	25.9	23.9	25.3	73	91	1010.3	1012.4	1000.7	1002.7	73
29.6	27.0	25.7	25.2	23.7	24.2	71	86	1010.1	1011.9	1000.5	1002.1	73

Berdasarkan data prediksi kabut pada Tabel 9. Tabel prediksi kabut Random Forest yang berisi berbagai data variabel meteorologi yaitu suhu udara (bk09 dan bk12), kelembaban udara (rh09 dan rh12), dan tekanan udara (qff09, qff12, qfe09, qfe12), dapat disimpulkan bahwa suhu udara berkisar antara 25-33°C, kelembaban udara berkisar antara 64-100%, dan tekanan udara menunjukkan variasi yang signifikan antara 996.0 hingga 1012.6 hPa. Prediksi kejadian kabut, dinyatakan dalam persentase, menunjukkan variasi yang menggambarkan kondisi cuaca yang berbeda. Suhu udara lebih rendah dengan kelembaban tinggi (seperti 25.2°C dengan 100% kelembaban) cenderung memberikan prediksi kabut yang tinggi hingga 89%. Sebaliknya, pada suhu lebih tinggi dengan kelembaban lebih rendah (seperti 32.0°C dengan 85% kelembaban), prediksi kabut menurun hingga 49%. Tekanan udara yang lebih stabil dan sedikit fluktuasi mendukung prediksi kabut yang lebih tinggi, seperti terlihat pada prediksi kabut sebesar 77% dengan tekanan 1006.0-1008.5 hPa. Secara keseluruhan, data ini menunjukkan bahwa kombinasi suhu udara yang lebih rendah dan kelembaban tinggi lebih mendukung pembentukan kabut, sementara suhu yang lebih tinggi dengan kelembaban yang lebih rendah cenderung mengurangi kemungkinannya kabut.

Tabel 9. Tabel prediksi kabut Random Forest

bk09	bk12	bb09	bb12	td09	td12	rh09	rh12	qff09	qff12	qfe09	qfe12	Prediksi (%)
30.9	29.8	27.5	26.9	25.8	25.4	75	78	1007.0	1009.0	997.5	999.4	75
27.8	27.7	25.6	26.2	24.5	25.4	83	88	1008.4	1009.5	998.7	999.8	62
31.0	24.6	27.0	24.5	25.0	24.5	71	100	1009.7	1012.6	1000.1	1002.8	82
26.0	26.4	25.1	26.1	24.7	26.0	93	98	1008.9	1010.8	999.1	1001.0	76
32.4	29.4	28.0	26.5	26.2	25.1	74	78	1008.9	1011.3	999.3	1001.6	74
31.2	28.9	29.4	28.0	26.1	24.8	75	79	1009.0	1011.1	999.4	1001.4	76
28.5	28.5	27.0	26.5	26.2	25.4	88	84	1007.4	1009.5	997.8	999.9	77
31.3	29.0	27.5	26.0	25.5	24.5	72	77	1006.9	1009.6	997.3	999.9	69
31.5	27.7	27.9	26.3	26.0	25.6	72	89	1006.0	1008.8	997.0	999.1	77
25.2	25.0	25.1	24.9	25.1	24.9	100	100	1007.1	1008.3	997.4	998.6	81
27.2	24.7	26.4	24.6	26.0	24.6	94	100	1007.1	1008.8	997.4	999.0	89
27.1	27.3	26.7	27.1	26.5	27.0	97	99	1005.7	1008.0	996.0	998.3	60
28.8	26.1	27.3	25.6	26.5	25.3	88	96	1007.3	1009.5	997.7	999.7	91
25.7	27.3	25.6	26.4	25.6	26.0	100	93	1007.1	1008.9	997.3	999.3	75
27.4	26.6	26.4	25.8	25.9	25.5	92	94	1006.6	1008.9	996.9	999.2	82
26.4	26.2	26.1	26.1	26.0	26.1	98	100	1008.4	1010.1	998.3	1000.4	81
30.6	28.8	27.4	26.7	25.8	25.7	76	85	1008.9	1009.7	998.8	1000.1	80
32.0	29.0	26.8	27.1	24.2	26.1	64	85	1006.7	1008.3	997.2	998.6	49
32.9	26.3	28.0	25.7	25.6	25.3	68	95	1006.7	1009.1	997.2	999.4	79
29.7	28.2	27.8	27.7	26.8	27.4	85	96	1006.0	1008.5	996.4	998.9	77
29.7	27.3	26.7	26.3	25.1	25.8	77	92	1005.8	1006.9	996.3	997.3	70
27.7	27.5	26.6	26.9	26.0	26.5	91	95	1005.7	1008.2	996.1	998.3	57
31.0	25.8	27.9	25.7	26.4	25.7	77	100	1006.3	1008.1	997.1	998.4	80



30.1	29.7	28.2	28.0	27.2	27.2	85	87	1005.9	1006.9	996.4	997.3	84
28.3	27.3	26.5	26.6	35.6	26.2	86	95	1005.8	1007.9	996.2	998.2	39
27.9	27.0	27.0	26.2	26.6	25.8	93	94	1005.7	1007.8	996.1	998.0	73
29.3	27.7	27.6	27.4	26.8	27.3	87	98	1007.5	1009.1	997.9	999.5	80
29.1	26.7	27.6	26.4	26.8	26.3	88	98	1006.3	1008.9	996.7	998.9	46
29.4	29.3	27.3	27.6	26.3	26.8	84	87	1005.7	1007.1	996.1	997.5	80

Dari kedua tabel diatas yaitu tabel 8. Tabel prediksi kabut Neural Network Backpropagasi dan Tabel 9. Tabel prediksi kabut Random Forest, prediksi kabut dapat disimpulkan bahwa kedua model menunjukkan bahwa kombinasi suhu udara yang lebih rendah dan kelembaban tinggi cenderung meningkatkan prediksi kejadian kabut. Model Neural Network Backpropagation menunjukkan prediksi kabut yang tinggi pada suhu sekitar 24-26°C dengan kelembaban antara 80-100%, namun mengalami penurunan akurasi pada suhu dan kelembaban yang lebih tinggi. Sementara itu, model Random Forest menunjukkan prediksi kabut yang lebih stabil dan akurat pada berbagai kondisi suhu dan kelembaban, dengan prediksi kabut mencapai hingga 89% pada suhu 25.2°C dengan 100% kelembaban, dan lebih konsisten pada variasi tekanan udara. Kesimpulannya, model Random Forest lebih baik dalam memprediksi kejadian kabut karena menunjukkan akurasi yang lebih tinggi dan stabilitas yang lebih baik di berbagai kondisi cuaca dibandingkan dengan model Neural Network Backpropagation.

4. KESIMPULAN

Dari analisis yang telah dilakukan terhadap dua model prediksi kabut, yaitu Neural Network Backpropagation dan Random Forest, dapat disimpulkan bahwa kedua model menunjukkan bahwa kombinasi suhu udara yang lebih rendah dan kelembaban tinggi cenderung meningkatkan prediksi kejadian kabut. Model Neural Network Backpropagation menunjukkan prediksi kabut yang tinggi pada suhu sekitar 24-26°C dengan kelembaban antara 80-100%, namun mengalami penurunan akurasi pada suhu dan kelembaban yang lebih tinggi. Sebaliknya, model Random Forest menunjukkan prediksi kabut yang lebih stabil dan akurat pada berbagai kondisi suhu dan kelembaban, dengan prediksi kabut mencapai hingga 89% pada suhu 25.2°C dengan 100% kelembaban, serta lebih konsisten pada variasi tekanan udara. Berdasarkan evaluasi metrik performa, model Random Forest memiliki akurasi yang lebih tinggi dan stabilitas yang lebih baik di berbagai kondisi cuaca dibandingkan dengan model Neural Network Backpropagation, menjadikannya pilihan yang lebih unggul untuk prediksi kabut di Bandara Radin Inten II. Penelitian selanjutnya mungkin mempertimbangkan untuk meningkatkan jumlah data, menambahkan fitur seperti penguapan atau kondisi cuaca lainnya, menggunakan model yang lebih kompleks seperti CNN dengan arsitektur yang dioptimalkan, dan meningkatkan jumlah periode pelatihan. Dengan mengikuti saran-saran tersebut, diharapkan penelitian di masa depan dapat memberikan prediksi kabut yang lebih akurat dan membantu meningkatkan keselamatan penerbangan.

UCAPAN TERIMAKASIH

Terimakasih penulis ucapkan kepada BMKG (Badan Meteorologi Klimatologi dan Geofisika) atas kesediaan data-data pendukung untuk kelancaran dalam penelitian ini.

REFERENCES

- [1] WMO, “No Title.” [Online]. Available: <https://cloudatlas.wmo.int/en/fog.html>
- [2] P. Pithani *et al.*, “WRF Model Prediction of a Dense Fog Event Occurred During the Winter Fog Experiment (WIFEX),” *Pure Appl. Geophys.*, vol. 176, no. 4, pp. 1827–1846, 2019, doi: 10.1007/s00024-018-2053-0.
- [3] P. Yadav *et al.*, “Understanding the genesis of a dense fog event over Delhi using observations and high-resolution model experiments,” *Model. Earth Syst. Environ.*, vol. 8, no. 4, pp. 5011–5022, 2022, doi: 10.1007/s40808-022-01463-x.
- [4] H. J. S. Fernando *et al.*, “C-FOG life of coastal fog,” *Bull. Am. Meteorol. Soc.*, vol. 102, no. 2, pp. E244–E272, 2021, doi: 10.1175/BAMS-D-19-0070.1.
- [5] D. Bari, T. Bergot, and R. Tardif, “Fog Decision Support Systems: A Review of the Current Perspectives,” *Atmosphere (Basel)*, vol. 14, no. 8, pp. 1–13, 2023, doi: 10.3390/atmos14081314.
- [6] K. YuvaPrasath and I. Sudha, “Accurate Weather Prediction on Sunny Days Using Back Propagation Algorithm Compared with Artificial Neural Networks,” in *2023 Intelligent Computing and Control for Engineering and Business Systems (ICCEBS)*, Dec. 2023, pp. 1–4. doi: 10.1109/ICCEBS58601.2023.10448882.



- [7] A. Shankar and B. C. Sahana, “Early warning of low visibility using the ensembling of machine learning approaches for aviation services at Jay Prakash Narayan International (JPNI) Airport Patna,” *SN Appl. Sci.*, vol. 5, no. 5, 2023, doi: 10.1007/s42452-023-05350-7.
- [8] S. H. Arun *et al.*, “A study to improve the fog/visibility forecast at IGI Airport, New Delhi during the winter season 2020–2021,” *J. Earth Syst. Sci.*, vol. 131, no. 2, p. 124, 2022, doi: 10.1007/s12040-022-01874-5.
- [9] N. Penov and G. Guerova, “Sofia Airport Visibility Estimation with Two Machine-Learning Techniques,” *Remote Sens.*, vol. 15, no. 19, pp. 1–17, 2023, doi: 10.3390/rs15194799.
- [10] A. Noeman, D. Handayani, and A. Hiswara, “Decision Tree-Based Weather Prediction,” *PIKSEL Penelit. Ilmu Komput. Sist. Embed. Log.*, vol. 10, pp. 67–78, Jul. 2022, doi: 10.33558/piksel.v10i1.4418.
- [11] H. Qin and H. Qin, “An End-to-End Traffic Visibility Regression Algorithm,” *IEEE Access*, vol. 10, pp. 25448–25454, 2022, doi: 10.1109/ACCESS.2021.3101323.
- [12] S. Saha and D. Valles, “Forecast Analysis of Visibility for Airport Operations with Deep Learning Techniques,” in *2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)*, 2023, pp. 553–558. doi: 10.1109/CCWC57344.2023.10099100.
- [13] P. Hewage, M. Trovati, E. Pereira, and A. Behera, “Deep learning-based effective fine-grained weather forecasting model,” *Pattern Anal. Appl.*, vol. 24, no. 1, pp. 343–366, 2021, doi: 10.1007/s10044-020-00898-1.
- [14] G. Montavon, “Introduction to Neural Networks BT - Machine Learning Meets Quantum Physics,” K. T. Schütt, S. Chmiela, O. A. von Lilienfeld, A. Tkatchenko, K. Tsuda, and K.-R. Müller, Eds., Cham: Springer International Publishing, 2020, pp. 37–62. doi: 10.1007/978-3-030-40245-7_4.
- [15] V. Y. Zulfian Azmi, *Pengantar Jaringan Saraf Tiruan: (Pengantar Jaringan Syaraf Tiruan)*. Mitra Wacana Media, 2021. [Online]. Available: <https://www.mitrawacanamedia.com/pengantar-jaringan-saraf-tiruan>
- [16] E. Izquierdo-Verdiguier and R. Zurita-Milla, “An evaluation of Guided Regularized Random Forest for classification and regression tasks in remote sensing,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 88, p. 102051, 2020, doi: <https://doi.org/10.1016/j.jag.2020.102051>.
- [17] Sriyanto and A. Ria Supriyatna, “Prediksi Penyakit Diabetes Menggunakan Algoritma Random Forest,” *Ijccs*, vol. 17 No. 1, no. x, pp. 1–5, 2023.
- [18] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, “Deep Learning dan Penerapannya dalam Pembelajaran,” *JiIP - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258–3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [19] A. Zulfiani and C. Fauzi, “Penerapan Algoritma Backpropagation Untuk Prakiraan Cuaca Harian Dibandingkan Dengan Support Vector Machine dan Logistic Regression,” *J. Media Inform. Budidarma*, vol. 7, no. 3, pp. 1229–1237, 2023, doi: 10.30865/mib.v7i3.6173.
- [20] A. Zaras, N. Passalis, and A. Tefas, “Chapter 2 - Neural networks and backpropagation,” in *Deep Learning for Robot Perception and Cognition*, A. Iosifidis and A. Tefas, Eds., Academic Press, 2022, pp. 17–34. doi: <https://doi.org/10.1016/B978-0-32-385787-1.00007-5>.
- [21] B. Sullivan, “Charniak, E. An Introduction to Deep Learning,” *Perception*, vol. 48, no. 8, pp. 759–761, 2019, doi: 10.1177/0301006619857273.
- [22] R. Nurpambudi, E. S. P. Wulandari, and R. A. Aziz, “Prediction of flood events in the city of Bandar Lampung using the artificial neural network,” *J. Infotel*, vol. 15, no. 1, pp. 34–45, 2023, doi: 10.20895/infotel.v15i1.878.
- [23] T. O. Hodson, “Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not,” *Geosci. Model Dev.*, vol. 15, no. 14, pp. 5481–5487, 2022, doi: 10.5194/gmd-15-5481-2022.
- [24] A. A. Suryanto, “Penerapan Metode Mean Absolute Error (Mea) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi,” *Saintekbu*, vol. 11, no. 1, pp. 78–83, 2019, doi: 10.32764/saintekbu.v11i1.298.
- [25] F. Demir, “14 - Deep autoencoder-based automated brain tumor detection from MRI data,” V. Bajaj and G. R. B. T.-A. I.-B. B.-C. I. Sinha, Eds., Academic Press, 2022, pp. 317–351. doi: <https://doi.org/10.1016/B978-0-323-91197-9.00013-8>.