

PREDIKSI KEJADIAN PETIR MENGGUNAKAN ARTIFICIAL NEURAL NETWORK METODE PERCEPTRON DENGAN INDEKS RADIOSONDE DI WILAYAH KABUPATEN KEPULAUAN TANIMBAR

THUNDERSTORM PREDICTIONS USING ARTIFICIAL NEURAL NETWORK PERCEPTRON METHOD WITH RADIOSONDE INDICES IN TANIMBAR ISLAND REGENCY AREA

Indra^{1*}

¹Stasiun Meteorologi Mathilda Batlayeri, Jl. Harapan Saumlaki, Kabupaten Kepulauan Tanimbar, Maluku

*E-mail: satinbrada@gmail.com

Naskah masuk: 1 Oktober 2023

Naskah diperbaiki: 15 Oktober 2023

Naskah diterima: 20 Oktober 2023

ABSTRAK

Berbagai penelitian diusahakan dalam menentukan metode prediksi kejadian petir, salah satunya dengan menggunakan data udara atas. Meskipun demikian, pemanfaatan nilai ambang batas stabilitas atmosfer sebagai patokan tidak selamanya berlaku sama untuk semua lokasi karena perbedaan karakteristik masing-masing wilayah. Dengan demikian, pendekatan yang lebih obyektif dan tepat diperlukan dalam melakukan prediksi kejadian petir, termasuk teknik penerapan jaringan syaraf tiruan (*artificial neural network / ANN*). Dalam penelitian ini, ANN digunakan untuk memprediksi kejadian petir di wilayah Kabupaten Kepulauan Tanimbar. ANN masukan tidak hanya menggunakan data mentah berupa nilai indeks labilitas atmosfer, tetapi juga menggunakan olahan seleksi fitur yang mereduksi dimensi input data multivariat dengan meminimalisir lenyapnya data masukan, sehingga informasi sebagai data input yang baru hanya berfokus pada informasi utama dan menghilangkan ketergantungan linier antar fitur. Teknik ini dikenal sebagai Principal Component Analysis (PCA). Hasil penelitian menunjukkan bahwa ANN dengan teknik PCA memiliki tingkat akurasi lebih besar dalam memprediksi kejadian petir di KKT.

Kata kunci: petir, akurasi, ANN, PCA

ABSTRACT

Various research efforts have been made to determine thunderstorm prediction methods, one of which involves using upper air data. However, the use of atmospheric stability threshold values as a reference does not always apply uniformly to all locations due to differences in the characteristics of each region. Therefore, a more objective and precise approach is needed in predicting thunderstorm events, including the application of artificial neural network (ANN) techniques. In this study, ANN method, is used to predict thunderstorm events in Tanimbar Island Regency Area. The ANN input not only relies on raw data in the form of atmospheric instability index values but also uses feature selection processing to reduce the dimensionality of multivariate input data, minimizing the loss of input data. This process focuses only on essential information and eliminates linear dependencies between features, a technique known as Principal Component Analysis (PCA). The research results indicate that ANN with PCA technique has a higher level of accuracy in predicting thunderstorm events in the Saumlaki region.

Keywords: *thunderstorm, accuracy, ANN, PCA*

1. Pendahuluan

Kepulauan Tanimbar secara geografis diapit oleh laut Banda dan laut Arafura, dimana kondisi ini menyebabkan pertumbuhan awan konvektif penghasil hujan di wilayah tersebut lebih cenderung dipengaruhi dari interaksi penguapan air laut terhadap fluida dinamis atmosfer. Hal ini menyebabkan wilayah tersebut rentan terkena bencana hidrometeorologi, karena pembentukan sel-sel badai cumulonimbus (Cb) di wilayah perairan laut lebih dominan mempengaruhi pembentukan cuaca berupa hujan dengan intensitas sedang hingga lebat terhadap Kepulauan Tanimbar [1].

Dampak yang ditimbulkan dari sel badai Cb dapat mengakibatkan hujan konvektif yang intens, banjir bandang, hingga angin kencang. Meskipun awan Cb tidak memiliki masa hidup yang lama, besarnya intensitas radiasi matahari yang membuat massa uap air mengalami penguapan lebih cepat di wilayah tropis disertai tingginya kandungan kelembaban relatif mendukung pembentukan sel badai baru yang dapat bertahan beberapa jam [2]. Kombinasi antara tingginya suhu dan kelembaban menciptakan kondisi yang mendukung pembentukan badai petir atau thunderstorm [3]. Kondisi ini menyebabkan badai berlangsung selama beberapa jam [4].

Dalam situasi atmosfer dengan ketinggian per level lapisan dan diikuti dengan laju penurunan suhu Γ yang memenuhi $\Gamma_m < \Gamma < \Gamma_d$, dimana $\Gamma_d = 9.8 \text{ }^\circ\text{C.km}^{-1}$ dan $\Gamma_m = 6.5 \text{ }^\circ\text{C.km}^{-1}$ mewakili laju penurunan suhu adiabatik, parcel udara dijadikan acuan sebagai konsep yang merujuk pada suatu volume udara imajiner yang memiliki sifat-sifat tertentu, seperti suhu, tekanan, dan kelembaban [5]. Parcel ini berasal dari lapisan atmosfer yang berhubungan dengan permukaan bumi sekaligus mampu menjelaskan perubahan suhu dan kelembaban yang terjadi saat udara naik atau turun secara vertikal, dan berperan penting dalam perkembangan badai petir jika badai berkembang [5].

Selain itu, perubahan vertikal udara di atmosfer dipengaruhi oleh profil termodinamika suhu. Ketika suhu udara di lapisan atmosfer berbeda, udara yang lebih hangat karena pemanasan radiasi matahari cenderung naik karena menjadi lebih ringan daripada udara yang lebih dingin di sekitarnya. Inilah yang memicu pergerakan udara vertikal [6]. Sewaktu parcel dinaikkan vertikal, parcel mulai mendingin

karena masih dalam kondisi tidak jenuh dengan kelembaban.

Pada tahapan selanjutnya, suhu dalam parcel menjadi lebih rendah daripada lingkungannya. Saat parcel mencapai tingkat tertentu dan mengalami kondensasi, awan mulai terbentuk. Kondensasi ini menghasilkan pelepasan panas laten yang mempengaruhi suhu dan kondisi lingkungan sekitarnya. Parcel ini kemudian menjadi lebih hangat daripada lingkungannya, membuatnya menjadi lebih ringan dan naik dengan sendirinya. Kondisi ini dikenal sebagai ketidakstabilan bersyarat [5].

Kemudian, perlu diperhatikan jika terdapat faktor penting lainnya dalam pembentukan cuaca yaitu adveksi, proses perpindahan massa atau energi dalam fluida, seperti udara, yang terjadi bersamaan dengan aliran fluida itu sendiri. Dalam konteks cuaca, adveksi dapat mempengaruhi perubahan profil termodinamika antara awan (atau sistem cuaca) dan lingkungan sekitarnya. Ini berarti bahwa sifat-sifat seperti suhu dan kelembaban dapat berubah di daerah sekitar awan atau sistem cuaca karena perpindahan udara yang mengandung sifat-sifat tersebut, dan merupakan faktor kunci dalam proses terbentuknya badai petir [7].

Meninjau dari pernyataan-pernyataan tersebut, analisis terkait data indeks labilitas udara atas dari hasil pengamatan radiosonde menjadi hal utama dalam menjelaskan bagaimana kondisi cuaca di atmosfer, termasuk fenomena pembentukan badai petir. Berbagai indeks labilitas atmosfer yang sering digunakan sebagai acuan dalam memprediksi potensi terjadinya badai petir sebagian besar adalah parameter-parameter berupa KI, LI, SI, TT, CAPE menurut berbagai sumber referensi penelitian terkait indeks yang umum cenderung lebih banyak dipakai di wilayah Indonesia [6,8,9,10]. Selain itu, downdraft (angin yang bertiup turun dari awan badai) juga berpengaruh signifikan. Jika downdraft lemah, maka kondisi di atmosfer menjadi tidak stabil yang mendorong proses terbentuknya sel badai penghasil thunderstorm. Potensi hambatan untuk mengukur potensi energi yang digunakan udara panas dan lembab agar naik secara vertikal digunakan dalam pengukuran instabilitas atmosfer [11], yang merupakan kategori indeks dari parameter *convective inhibition* (CIN).

Pada penelitian yang dilakukan Richard, prediksi probabilitas terjadinya thunderstorm dari data indeks rason diimplementasikan

dengan pendekatan jaringan syaraf tiruan [9]. Jaringan syaraf tiruan (*Artificial Neural Network / ANN*) adalah sebuah model komputasi yang terinspirasi oleh struktur dan fungsi otak manusia. Sedangkan, penelitian Ajina menjelaskan pemodelan dengan pendekatan ANN yang digunakan pada beberapa parameter cuaca terbukti dapat meningkatkan keakuratan hasil prediksi [12]. Salah satu pendekatan metode jaringan syaraf tiruan yang digunakannya yaitu metode Perceptron. Perceptron adalah salah satu bentuk dasar jaringan syaraf tiruan yang dipakai untuk memodelkan masalah klasifikasi biner (ada atau tidak terjadinya suatu event yang diprediksi) [5]. Merujuk dari keenam parameter indeks rason yang disebutkan sebelumnya, data indeks rason berupa KI, LI, SI, TT, CAPE, dan CIN akan digunakan dalam penelitian ini sebagai data masukan sekaligus data pelatihan untuk model ANNP (*Artificial Neural Network Perceptron*) untuk mendeteksi kemungkinan terjadi atau tidak terjadinya petir.

Dalam hal ini, data masukan untuk pelatihan ANNP tidak hanya menggunakan data mentah berupa nilai indeks labilitas atmosfer, tetapi juga menggunakan olahan seleksi fitur yang mereduksi dimensi input data multivariat dengan meminimalisir lenyapnya data masukan, sehingga informasi sebagai data input yang baru hanya berfokus pada informasi utama dan menghilangkan ketergantungan linier antar fitur. Teknik ini dikenal sebagai *Principal Component Analysis (PCA)* [2]. Dengan demikian, pendekatan lain yang bertujuan untuk bisa lebih memaksimalkan data hasil prediksi dari model ANN metode perceptron yakni melibatkan modifikasi terhadap metode ANNP menggunakan teknik PCA. Tujuan dari modifikasi ini adalah untuk menilai apakah penggunaan PCA dapat meningkatkan tingkat keakuratan prediksi cuaca ekstrim, khususnya dalam memprediksi thunderstorm, berdasarkan data indeks labilitas udara atas di area Kabupaten Kepulauan Tanimbar [2].

2. Metode Penelitian

Penelitian ini memanfaatkan data indeks labilitas udara yang diperoleh dari observasi udara atas Stasiun Meteorologi Mathilda Batlayeri yang berlokasi di kota Saumlaki, Kabupaten Kepulauan Tanimbar selama tiga tahun, yakni dari periode tahun 2020 hingga 2022 pada pukul 00 UTC dan 12 UTC. Menimbang data ini bersumber dari satu lokasi dalam wilayah Kabupaten Kepulauan Tanimbar dan dalam lain hal, pembacaan radiosonde

dapat mencakup wilayah dalam radius 100 km dari lokasi pelepasan balon radiosonde dan sampai ketinggian hingga lapisan troposfer, data radiosonde yang digunakan dalam penelitian ini merupakan representasi dari kondisi atmosferik dalam wilayah Kabupaten Kepulauan Tanimbar. Kemudian, pengumpulan data dilakukan secara otomatis menggunakan skrip Python yang mampu menghasilkan data indeks labilitas udara atas ke dalam bentuk dataframe dari website Wyoming, yang dapat diakses melalui: <http://weather.uwyo.edu/upperair/sounding.html> menggunakan WMO ID Stasiun Meteorologi Mathilda Batlayeri, 97900. Data-data indeks radiosonde yang diakses meliputi parameter indeks KI, LI, SI, TT, CAPE, dan CIN dari observasi data udara atas Stasiun Meteorologi Mathilda Batlayeri sebagai data pelatihan. Untuk lebih jelasnya, perhitungan dari masing-masing indeks parameter dapat dilihat sebagai berikut :

Indeks K (KI) adalah ukuran untuk memprediksi potensi awan badai atau awan Cumulonimbus [10]. Indeks K mengukur potensi peristiwa badai petir berdasarkan penyusutan suhu vertikal lingkungan, kandungan uap air yang terdapat dalam lapisan rendah, dan kandungan uap air yang merambat secara vertikal. Nilai KI dihitung berdasarkan nilai suhu lapisan 850, 700, dan 500 mb, serta titik embun untuk lapisan 850 dan 700 mb. Semakin tinggi kelembaban dan perbedaan suhu yang lebih besar dari 850 - 500, semakin tinggi KI dan potensi konveksinya. Selain untuk memprediksi peristiwa badai petir potensial, nilai indeks K juga penting untuk memprediksi peristiwa hujan deras. Nilai indeks K diwakili oleh persamaan :

$$KI = (T_{850} - T_{500}) + (Td_{850} - \Delta_{700})$$

Di mana T_{850} adalah suhu pada level 850 mb ($^{\circ}\text{C}$); T_{500} adalah suhu pada level 500 mb ($^{\circ}\text{C}$); Td_{850} adalah suhu titik embun pada level 850 mb ($^{\circ}\text{C}$); Δ_{700} adalah perbedaan antara suhu udara dan suhu titik embun pada level 700 mb ($^{\circ}\text{C}$).

Lifted Index adalah nilai yang diperoleh dari selisih antara suhu parcel udara yang diangkat secara adiabatik dan suhu udara lingkungan pada lapisan 500 mb pada tinggi tekanan p dalam troposfer [6,8,9,10]. LI dapat dihitung dengan persamaan :

$$LI = T_{lp} - T_{gp}$$

Di mana T_{lp} adalah suhu udara lingkungan pada lapisan 500 hPa (dalam $^{\circ}\text{C}$) dan T_{gp}

adalah suhu parcel udara pada lapisan 500 hPa yang mengalami proses adiabatik jenuh (dalam °C).

Indeks Showalter digunakan untuk menggambarkan ketidakstabilan udara di troposfer tengah, yang berada antara tingkat 850 dan 500 hPa [6,8,9]. Nilai indeks didasarkan pada jumlah uap air dan energi yang terkandung dalam lapisan 850 dan 500 hPa. Indeks SI dituliskan dalam persamaan :

$$SI = T_{500} - T_X$$

Di mana T_{500} adalah suhu udara lingkungan pada lapisan 500 hPa (dalam °C), dan T_X adalah suhu parcel udara pada lapisan 500 hPa yang mengalami proses adiabatik jenuh (dalam °C). Nilai indeks negatif mengindikasikan stabilitas dan nilai indeks positif mengindikasikan ketidakstabilan.

Indeks Total-Totals digunakan untuk mengidentifikasi area potensial perkembangan badai petir. Total-Totals adalah jumlah Vertikal Total (VT) dan Cross Total (CT) [6, 9, 10]. VT menggambarkan laju penyusutan suhu antara dua permukaan tekanan konstan, yaitu selisih antara suhu pada lapisan 850 dan 500 hPa. CT menggambarkan kombinasi perhitungan antara kelembaban di lapisan bawah dan suhu, yaitu selisih antara suhu titik embun pada lapisan 850 hPa dan suhu pada lapisan 500 hPa. Indeks TT dapat ditentukan seperti dalam persamaan :

$$TT = (T_{850} - T_{500}) + (Td_{850} - T_{500})$$

Di mana T_{850} adalah suhu udara yang diukur oleh radiosonde pada ketinggian 850 hPa (°C); T_{500} adalah suhu udara yang diukur oleh radiosonde pada ketinggian 500 hPa (°C); Td_{850} adalah suhu titik embun pada ketinggian 850 hPa (°C)

CAPE (*Convective Available Potential Energy*) adalah energi total dari gaya apungan dalam kolom udara yang tersedia untuk mengangkat paket udara [9,10,11]. CAPE terkait dengan kecepatan vertikal potensial maksimum dalam updraft. Jadi CAPE cukup baik untuk menandai ketidakstabilan potensial atmosfer. Nilai CAPE dihitung dengan persamaan :

$$CAPE = \int_{z_f}^{z_n} g \left(\frac{T_{parcel} - T_{env}}{T_{env}} \right) dz$$

Di mana z_f adalah tingkat Konveksi Bebas (LFC) dalam meter (m) dan z_n adalah tingkat

keseimbangan dalam meter (m). T_{parcel} adalah suhu udara parcel (°C) dan T_{env} adalah suhu udara lingkungan (°C). g adalah gravitasi bumi (m/s^2) dan dz adalah selisih ketinggian (m).

Untuk parcel udara yang memiliki CAPE positif, *Convective Inhibition* (CIN) mewakili area negatif pada diagram termodinamika. Area negatif ini biasanya muncul karena adanya penutup, atau jumlah energi kinetik yang harus ditambahkan pada parcel untuk memungkinkannya mencapai *Level of Free Convection* (LFC) [5,11]. Meskipun faktor lain mendukung perkembangan konveksi, jika hambatan konvektif cukup besar, konveksi dalam skala besar tidak akan terbentuk. Hambatan konvektif dinyatakan (analog dengan CAPE) sebagai berikut:

$$CIN = - \int_{p_i}^{p_f} Rd(T_{vp} - T_{ve}) d \ln p$$

Di mana p_i adalah tekanan pada tingkat di mana parcel berasal, p_f adalah tekanan pada LFC, Rd adalah konstanta gas khusus untuk udara kering, T_{vp} adalah suhu virtual parcel terangkat, dan T_{ve} adalah suhu virtual lingkungan. Diasumsikan bahwa lingkungan berada dalam keseimbangan hidrostatis dan tekanan parcel sama dengan tekanan lingkungan. Suhu virtual digunakan untuk parcel dan lingkungan untuk memperhitungkan efek kelembaban pada kerapatan udara.

Sebagai informasi, jaringan syaraf tiruan dengan pendekatan perceptron menerima input numerik dan menghasilkan output berdasarkan pembobotan input dan pengaktifan menggunakan fungsi tertentu, dengan perhitungan :

1. Perhitungan input bobot : Setiap input (x) dikalikan dengan bobot yang sesuai (w), kemudian hasilnya dijumlahkan untuk semua input. Ini memberikan nilai hasil penjumlahan yang akan digunakan untuk mengaktifkan fungsi aktivasi.

$$z = \sum_{i=1}^n (x_i \times w_i) + b$$

2. Fungsi aktivasi : Setelah menghitung nilai hasil penjumlahan, hasilnya diteruskan ke fungsi aktivasi (f) untuk menghasilkan output. Fungsi aktivasi mengubah nilai hasil

penjumlahan menjadi bentuk yang lebih terstruktur.

$$y = f(z)$$

Contoh fungsi aktivasi yang umum digunakan adalah fungsi sigmoid yang dinyatakan ke dalam bentuk persamaan :

$$f(z) = \frac{1}{1 + e^{-z}}$$

Fungsi Heaviside (Step Function) juga dapat digunakan sebagai fungsi aktivasi yang sederhana :

$$f(z) = \begin{cases} 1, & \text{jika } z > \text{ambang aktivasi} \\ 0, & \text{lainnya} \end{cases}$$

Selain itu, pengurangan dimensi fitur adalah langkah umum dalam pra-pemrosesan data untuk pengenalan pola, klasifikasi, dan kompresi. Salah satu metode terkenal dalam hal ini adalah Analisis Komponen Utama (*Principal Component Analysis / PCA*). Namun, PCA memiliki kelemahan karena menggunakan semua fitur dalam proyeksi ke ruang dimensi yang lebih rendah. Untuk mengatasi hal ini, diperkenalkanlah metode baru bernama Analisis Fitur Utama (*Principal Feature Analysis / PFA*), yang memilih subset fitur penting dengan kriteria serupa PCA. PFA digunakan dalam pemilihan fitur utama dari indeks Instabilitas Radiosonde di area tertentu. Dalam pemanfaatan matriks korelasi R dari vektor acak x berdimensi N, dimensi data bisa dikurangi menjadi M (dengan $M < N$) melalui enam langkah Analisis Komponen Utama. Dengan demikian, konsep pengurangan dimensi dalam pemrosesan data dapat diterapkan dalam pemodelan jaringan syaraf tiruan seperti perceptron dengan pendekatan yang lebih canggih seperti PCA atau PFA [2].

Dengan matriks korelasi R dari vektor acak x berdimensi N, dimensi bisa dikurangi menjadi M (dengan $M < N$) melalui enam langkah Analisis Komponen Utama :

1. Menghitung Mean : Hitung mean dari setiap fitur dalam dataset.

$$\mu = \frac{1}{N} \sum_{j=1}^N x_{ij}$$

2. Normalisasi Data : Normalisasi data dengan mengurangi nilai rata-rata dari setiap fitur, sehingga data memiliki mean nol.

$$x_{ij}^* = x_{ij} - \mu_i$$

3. Menghitung Matriks Kovariansi : Hitung matriks kovariansi dari data yang dinormalisasi. Matriks kovariansi memberikan informasi tentang hubungan antara setiap pasangan fitur.

$$C = \frac{1}{N-1} X^* X^{*T}$$

4. Menghitung Nilai Eigen dan Vektor Eigen : Hitung nilai eigen (nilai yang mengukur variasi) dan vektor eigen (arah dari variasi) dari matriks kovariansi. Nilai eigen menggambarkan seberapa besar variasi yang dijelaskan oleh setiap komponen utama.

$$C v_i = \lambda_i v_i$$

5. Pilih Komponen Utama : Pilih M komponen utama dengan nilai eigen terbesar. Ini akan memungkinkan pemeliharaan sebagian besar variasi dalam dataset asli dengan dimensi yang lebih rendah.

$$\text{Variansi} = \frac{\lambda_i}{\sum_{i=1}^M \lambda_i}$$

6. Proyeksi Data : Proyeksikan data ke ruang yang didefinisikan oleh komponen utama yang dipilih. Ini melibatkan perhitungan produk skalar antara data dan vektor eigen.

$$y_{ij} = x_{ij}^* \cdot v_i$$

Dimana N adalah jumlah sampel dalam dataset; M adalah jumlah komponen utama yang dipilih; x_{ij} adalah nilai fitur ke-i dari sampel ke-j; μ_i adalah rata-rata dari nilai fitur ke- i dalam seluruh dataset; x_{ij}^* adalah nilai fitur yang dinormalisasi ke-i dari sampel ke-j; C adalah matriks kovariansi dari data yang dinormalisasi; v_i adalah vektor eigen ke-i dari matriks kovariansi; λ_i adalah nilai eigen ke-i yang mengukur variasi yang dijelaskan oleh komponen eigen tersebut; dan y_{ij} adalah nilai fitur terproyeksi ke-i dari sampel ke-j dalam ruang komponen utama.

PCA membantu dalam mengurangi dimensi data dan mengidentifikasi pola-pola penting dalam data dengan menghitung nilai eigen dan vektor eigen dari matriks kovariansi. Variabel dan rumus di atas digunakan dalam perhitungan PCA untuk menghasilkan komponen utama yang menggambarkan variasi dalam data.

Masuk pada tahapan selanjutnya, data yang dikumpulkan akan tersimpan ke dalam format file Excel, yang nantinya digunakan sebagai data input dan data pelatihan dalam model ANNP. Pembentukan model ANNP melibatkan pendekatan perhitungan perceptron, dimana skrip penyusunan model telah terintegrasi dengan metode PCA dan menggunakan enam komponen analisis sesuai jumlah parameter indeks yang diperlatih dengan data target thunderstorm sesuai waktu kejadian. Model ANNP ini menggunakan Python versi 3.11, dengan melibatkan algoritma skrip untuk pelatihan data, serta memanfaatkan library `sklearn` `decompose` PCA sebagai perbandingan antara data tunggal dengan data yang dimodifikasi menggunakan metode PCA.

Mengacu pada pembacaan data pada pukul 00 dan 12 UTC, pengelompokan data terbagi dua, merujuk pada penelitian yang dilakukan oleh Habib dan Bhattacharya, jaringan saraf tiruan telah digunakan untuk mendeteksi probabilitas terjadinya badai petir (thunderstorm) berdasarkan data indeks labilitas udara dari radiosonde untuk jangka waktu 10 hingga 12 jam ke depan [4,8]. Kedua bagian menjalani proses perhitungan ANNP dan ANNP-PCA (ANNP yang sudah dimodifikasi pelatihan data trainingnya dengan teknik PCA). Setelah melalui fase pelatihan data training, pendekatan yang sama diterapkan untuk menguji akurasi data selama tiga bulan di tahun terakhir (Oktober sampai Desember tahun 2020), baik pada pembagian ANNP maupun ANNP-PCA. Tingkat akurasi data akan dianalisis guna menilai sejauh mana persentase keakuratan ANNP dan ANNP-PCA dalam mendeteksi keberadaan dan ketiadaan thunderstorm.

Dari berbagai penjelasan yang telah dibahas, perumusan masalah dalam penelitian ini mencakup dua aspek yang berfokus pada evaluasi dan perbaikan prediksi cuaca ekstrem berupa kejadian thunderstorm di wilayah Kabupaten Kepulauan Tanimbar. Pertama, masalah terkait sejauh mana tingkat akurasi model ANNP dengan data indeks radiosonde terhadap kejadian thunderstorm di wilayah Kabupaten Kepulauan Tanimbar. Kedua, bagaimana perbandingan tingkat akurasi antara ANNP tunggal dan modifikasi ANNP-PCA dalam memprediksi data indeks radiosonde di wilayah Kabupaten Kepulauan Tanimbar. Dengan demikian, tujuan penelitian adalah untuk mendapatkan pemahaman yang lebih baik tentang potensi peningkatan prediksi cuaca ekstrem dengan menerapkan modifikasi teknik analisis pada metode prediksi yang ada.

3. Hasil dan Pembahasan

Tabel 1. Perbandingan Tingkat Akurasi Performa ANNP dan ANNP-PCA

	ANNP	ANNP-PCA
00 UTC	46.9697 %	78.7879 %
12 UTC	86.7647 %	57.3529 %
Overall	66.8672 %	68.0704 %

Sumber : data diolah

Berdasarkan analisis hasil perhitungan keluaran dari model ANNP dan ANNP-PCA pada jam 00 UTC dan 12 UTC dalam menentukan probabilitas terjadinya atau tidak terjadinya petir pada tabel di atas, terlihat bahwa hasil pembacaan ANNP yang dimodifikasi dengan PCA (ANNP-PCA) menunjukkan tingkat akurasi yang lebih unggul dibandingkan dengan model ANNP tunggal. Meskipun selisih akurasi tidak sangat mencolok, namun pada rentang persentase akurasi antara 66 hingga 68%, ANNP-PCA berhasil menunjukkan performa lebih baik.

Dalam konteks yang lebih spesifik, ketika merujuk pada pembacaan ANNP pada jam 00 UTC, tingkat akurasi hanya mencapai 47%, sedangkan ANNP-PCA mencapai 79%. Namun, pola ini memiliki hubungan yang berbanding terbalik pada jam 12 UTC, dimana ANNP tunggal memiliki akurasi sebesar 87%, sedangkan ANNP-PCA memiliki akurasi 57%. Secara sekilas, terlihat bahwa pendekatan modifikasi ANNP-PCA lebih efektif saat diterapkan pada waktu pagi, sedangkan ANNP tunggal lebih cocok digunakan pada malam hari. Informasi lebih rinci tentang klasifikasi kejadian terjadinya atau tidak terjadinya petir pada tiap jam akan diulas lebih mendalam melalui tabel yang akan disajikan berikut ini :

Tabel 2. Perbandingan Tingkat Akurasi Berdasarkan Klasifikasi Terjadi atau Tidak Terjadinya Petir pada Performa ANNP dan ANNP-PCA

		ANNP	ANNP-PCA
00 UTC	Ada TS	66.6667 %	6.6667 %
	Tanpa TS	41.1764 %	100 %
12 UTC	Ada TS	0 %	66.6667 %
	Tanpa TS	100 %	55.9322 %

Sumber : data diolah

Ketika melihat hasil pada jam 00 UTC, terungkap bahwa model ANNP tunggal mampu memprediksi terjadinya petir dengan akurasi hingga 67%. Di sisi lain, model ANNP-PCA memiliki tingkat akurasi yang jauh lebih rendah hanya sebesar 6 hingga 7 % dalam memprediksi terjadinya petir, tetapi berhasil mencapai akurasi 100% dalam memprediksi ketiadaan petir, masih lebih tinggi dibandingkan

ANNP tunggal yang persentase akurasi lebih rendah senilai 42%.

Namun, hasil pada jam 12 UTC menunjukkan hubungan yang berbanding terbalik dengan data output pada jam 00 UTC sebelumnya. ANNP-PCA mencapai tingkat akurasi hingga 67% dalam memprediksi terjadinya petir, sementara ANNP biasa tidak mampu menunjukkan potensi terjadinya petir. Dalam memprediksi ketiadaan petir, ANNP menunjukkan akurasi yang lebih besar hingga 100%, dibandingkan ANNP-PCA dengan tingkat akurasi 56%.

4. Kesimpulan

Dari perbandingan performa antara model Artificial Neural Network Perceptron (ANNP) dan model ANNP yang dimodifikasi dengan Principal Component Analysis (ANNP-PCA), dapat disimpulkan bahwa di wilayah Kabupaten Kepulauan Tanimbar pada pagi hari, ANNP-PCA menunjukkan performa yang lebih baik dalam memprediksi ketiadaan terjadinya petir daripada ANNP, meskipun ANNP biasa lebih baik digunakan untuk memprediksi terjadinya petir dengan tingkat akurasi yang jauh lebih signifikan dibandingkan ANNP-PCA.

Selain itu, sewaktu malam hari, model ANNP-PCA dianggap lebih mampu menunjukkan keunggulan dalam memprediksi terjadinya petir dibandingkan kemampuan ANNP tunggal yang bahkan sama sekali tidak mampu menunjukkan potensi terjadinya petir, dengan kemampuan ANNP yang masih mengungguli ANNP-PCA dalam penentuan tidak terjadinya petir. Namun, penting mempertimbangkan faktor-faktor lainnya, baik skala lokal dan regional yang memengaruhi proses atmosferik dalam pembentukan kondisi cuaca di Kepulauan Tanimbar guna meningkatkan akurasi prediksi petir dan peluang keberhasilan yang lebih baik.

Daftar Pustaka

- [1] Indra. (2019). *Analisis Dampak Siklon Tropis Lili pada Kondisi Cuaca di Saumlaki selama 07 – 11 Mei 2019*. Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Jakarta.
- [2] Putra, A. W., & Lursinsap, C. (2014). *Cumulonimbus Prediction using Artificial Neural Network Back Propagation with Radiosonde Indeces*. Prosiding Seminar Nasional Penginderaan Jauh (pp. 153-165). Jakarta
- [3] Ferdous, J., Quadir, D. A., Alam, M. S., Panda, S. K., Das, S., Ahasan, M. N., Rabbani, K. M. G., & Shuvo, S. D. (2021). Prediction of Thunderstorms based on Atmospheric Instability Indices over Bangladesh using WRF-ARW Model. *Jalawaayu*, 1(2), 21–37. doi.org/10.3126/jalawaayu.v1i2.41008

- [4] Bhattacharya, S., & Bhattacharyya, H. C. (2023). A comparative study of severe thunderstorm among statistical and ANN methodologies. *Scientific Reports* 13 (1), 12038. doi.org/10.1038/s41598-023-38736-z
- [5] Collins, W. G., & Tissot, P. (2015). *Thunderstorm Predictions Using Artificial Neural Networks*. Sao Paulo, Brazil : Artificial Neural Networks - Models and Applications doi.org/10.5772/63542
- [6] Agroho, F. L., Syahreza, S., & Sugiyanto, D. (2021). Analysis of the rainfall event in 2018-2019 using the air stability index method at the Meteorological Station of Sultan Iskandar Muda Banda Aceh. *Journal of Physics: Conference Series*, 1882 (2021) 012023 doi:10.1088/1742-6596/1882/1/012023
- [7] Savre, J. (2020). Formation and maintenance of subsiding shells around non-precipitating and precipitating cumulus clouds. *Quarterly Journal of the Royal Meteorological Society*, 147(735), 728-745. doi.org/10.1002/qj.3942
- [8] Habib, A.H.A., Bangalino, E., & Ryan, M. (2021). *Rancang Bangun Model Artificial Neural Network untuk Prediksi Probabilistik Kejadian Thunderstorm di Wilayah Manado*. Prosiding Seminar Nasional Sains Atmosfer 2020 Retrieved from <https://www.researchgate.net/publication/353654961>
- [9] Putra et al. (2021). *Cumulonimbus cloud prediction based on machine learning approach using radiosonde data in Surabaya, Indonesia*. The 5th Internasional Conference on Climate Change 2020, IOP Conf. Series:Earth Environmental Science 724(2021), 012047. doi.org/10.1088/1755-1315/724/1/012047
- [10] Yasa, I. M. T., Yuliara, I. M., & Sumaja, K. (2023). Correlation of Atmospheric Lability Index to Vertikal Wind Shear at I Gusti Ngurah Rai Airport. *Indonesian Physical Review*, 6(1), 124–131. doi.org/10.29303/ipr.v6i1.188
- [11] Market, P., Grempler, K., Sumrall, P., & Henson, C. (2019). Analysis of Severe Elevated Thunderstorms over Frontal Surfaces Using DCIN and DCAPE. *Atmosphere*, 10(8), 449. doi.org/10.3390/atmos10080449
- [12] Ajina, A., Christiyan, J., Bhat, D., & Saxena, K. (2023). Prediction of weather forecasting using artificial neural networks. *Journal of Applied Research and Technology*, 21(2), 205-211. doi.org/10.22201/icat.24486736e.2023. 21.2.1698