

PREDIKSI KUALITAS UDARA BERDASARKAN PARAMETER CO DAN CO₂ MENGGUNAKAN ARTIFICIAL NEURAL NETWORK

Rosalinda Ellysa Putri^{a*}, Suprawikno^b

^a Teknik Elektro, STT Ronggolawe

^b Teknik Elektro, STT Ronggolawe

*Email: rosaalindarf@gmail.com

Diterima : 29-06-2025

- Direview : 30-06-2025

- Diterbitkan : 2-07-2025

Intisari

Penelitian ini bertujuan untuk memprediksi kadar karbon monoksida (CO) dan karbon dioksida (CO₂) sebagai indikator kualitas udara menggunakan metode *Artificial Neural Network* (ANN) dengan arsitektur 21-20-7. Data diperoleh selama 28 hari dari alat AQMSense, dengan 21 hari pertama sebagai data latih dan 7 hari berikutnya sebagai data uji. Hasil menunjukkan bahwa model ANN mampu mengenali pola data historis dengan baik, ditandai dengan nilai regresi mendekati 1. Tingkat akurasi prediksi mencapai 89,96% untuk CO dan 95,84% untuk CO₂, yang menunjukkan performa model cukup tinggi. ANN efektif digunakan dalam sistem prediksi kualitas udara harian dan berpotensi menjadi alat bantu mitigasi pencemaran udara.

Kata Kunci : *Artificial Neural Network*; Prediksi; Kualitas udara

Abstract

This study aims to predict carbon monoxide (CO) and carbon dioxide (CO₂) levels as indicators of air quality using the Artificial Neural Network (ANN) method with a 21-20-7 architecture. Data was collected over 28 days using the AQMSense device, with the first 21 days used for training and the remaining 7 days for testing. The results show that the ANN model effectively recognizes historical data patterns, indicated by a regression value close to 1. The prediction accuracy reached 89.96% for CO and 95.84% for CO₂, demonstrating strong model performance. ANN proves to be an effective tool for daily air quality prediction and holds potential as a decision-support system for air pollution mitigation

Keywords : *Artificial Neural Network*; Prediction; Air quality

1. Pendahuluan

Pencemaran udara merupakan masalah global yang semakin memprihatinkan, terutama di kawasan perkotaan dan kawasan industri. Salah satu komponen utama pencemaran udara adalah gas karbon monoksida (CO) dan karbon dioksida (CO₂). Kedua gas ini dihasilkan dari berbagai sumber, terutama pembakaran bahan bakar fosil seperti kendaraan bermotor, proses industri, dan aktivitas manusia lainnya (Bagye, 2020). Gas CO sangat berbahaya bagi kesehatan manusia karena dapat mengurangi kemampuan darah membawa oksigen. Paparan CO dalam konsentrasi tinggi dapat menyebabkan keracunan, kerusakan organ, bahkan kematian. Meskipun tidak beracun seperti CO, peningkatan kadar CO₂ di atmosfer berkontribusi terhadap efek rumah kaca dan perubahan iklim global. Perubahan iklim ini memiliki dampak luas terhadap lingkungan dan kehidupan manusia, seperti kenaikan permukaan air laut, cuaca ekstrem, dan gangguan ekosistem (Hakim, 2023).

Mengingat dampak negatif CO dan CO₂ yang signifikan, maka perlu untuk mengantisipasi kemungkinan untuk tujuh hari kedepan. Oleh karena itu, penelitian ini melakukan prediksi kadar gas tersebut. Prediksi yang akurat dapat membantu berbagai pihak dalam mengambil tindakan pencegahan dan mitigasi yang tepat. Untuk mendapatkan hasil peramalan yang akurat maka diperlukan perhitungan yang tepat (Hasan and Fatta, 2019).

2. Kerangka Teori

2.1. Prediksi

Prediksi merupakan usaha untuk memperkirakan sesuatu yang akan terjadi di waktu mendatang dengan mengumpulkan informasi yang relevan pada waktu-waktu sebelumnya (Farhan Fadilah, Agus Komarudin, 2024). Dalam penelitian ini, prediksi kadar CO dan CO₂ bertujuan untuk mengetahui konsentrasi gas-gas ini pada waktu mendatang berdasarkan pola atau tren yang telah terjadi sebelumnya.

2.2. Kualitas Udara

Kualitas udara dipengaruhi oleh berbagai faktor, seperti kebakaran hutan, peningkatan jumlah kendaraan bermotor, perkembangan kawasan industri, pertumbuhan populasi, perubahan penggunaan lahan, dan faktor lainnya. Dalam Standar Internasional batas ISPU menggunakan satuan *part per million (ppm)* atau bagian per sejuta (Hakim, 2023).

2.3. Artificial Neural Network

Artificial Neural Network adalah metode pembelajaran mesin yang efektif dalam mengenali pola-pola kompleks dalam data yang arsitektur dan fungsinya didasarkan pada pengetahuan tentang sel saraf biologis di otak (Nurelasari *et al.*, 2022). *ANN* dapat digunakan untuk permasalahan yang sama dengan permasalahan statistika multivariat seperti *multiple regression*, analisa diskriminan, dan analisa kluster (Rahman *et al.*, 2017). Dalam konteks ini, *ANN* akan digunakan untuk mempelajari hubungan antara data CO dan CO₂ sebelumnya dan data CO dan CO₂ di masa depan.

Pada penelitian ini menggunakan jenis model *ANN backpropagation* untuk memperkecil tingkat eror dengan cara menyesuaikan bobot berdasarkan dari perbedaan *output* dan target yang diinginkan. Model ini paling umum digunakan karena efektif untuk menangani isu-isu yang rumit dan cocok untuk aplikasi yang memerlukan pengendalian karena proses pembelajarannya bergantung pada keterkaitan yang mudah dipahami (Kuncoro, 2024). *Backpropagation* terdiri dari *input layer*, *hidden layer*, dan *output layer* (Supriyanto, Sunardi, 2022).

2.4. Mean Square Error (MSE)

Mean Square Error (MSE) merupakan metode untuk mengevaluasi peramalan dengan menghitung rata-rata kesalahan prediksi yang dikuadratkan. Pendekatan ini mengatur kesalahan pada peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan (Ardianto, 2019). Kesalahan keluaran jaringan merupakan selisih antara keluaran sebenarnya dan keluaran yang diinginkan (Hasan and Fatta, 2019). Rumus untuk menghitung *MSE* menggunakan persamaan berikut (Farhana, 2025).

$$MSE = \frac{\sum_{i=1}^n (Y_t - \hat{Y}_t)^2}{n} \quad (1)$$

Dimana :

Y_t = nilai target

$\hat{Y}_t$ = nilai prediksi

n = jumlah data

2.5. Mean Absolute Percent Error (MAPE)

Mean Absolute Percent Error (MAPE) merupakan perhitungan dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu kemudian merata-rata kesalahan presentase absolut tersebut (Laili and Wijanarko, 2023). Rumus untuk menghitung *MAPE* menggunakan persamaan berikut (Laili and Wijanarko, 2023).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (2)$$

Dimana :

Y_t = nilai target

$\hat{Y}_t$ = nilai prediksi

n = jumlah data

2.6. Akurasi

Akurasi adalah matriks evaluasi yang mengukur seberapa sering model menghasilkan prediksi yang sangat baik untuk semua kelas. Matriks ini dihitung sebagai rasio angka yang benar terhadap total data yang diuji. Akurasi memberikan gambaran umum tentang performa model, terutama pada dataset yang memiliki distribusi kelas seimbang. Persamaan untuk menghitung akurasi adalah sebagai berikut (Laili and Wijanarko, 2023)

$$\text{Akurasi} = 100\% - \text{MAPE} \quad (2.3)$$

3. Metodologi

Penelitian ini dilakukan dalam beberapa tahapan yang sistematis. Pertama, dilakukan pengumpulan data menggunakan alat AQMSense yang ditempatkan di Jalan Ronggolawe, Cepu. Data dikumpulkan selama 28 hari berturut-turut dari pukul 06.30 hingga 17.00 WIB, dengan interval pencatatan setiap 30 menit, menghasilkan total 588 titik data untuk masing-masing parameter CO dan CO₂.

Tahap kedua adalah pra-pemrosesan data. Data yang telah dikumpulkan kemudian melalui tahap normalisasi menggunakan metode min-max normalization untuk memastikan nilai input berada pada rentang 0 hingga 1, sehingga mempercepat proses pelatihan model *ANN* dan menghindari dominasi nilai tertentu.

Selanjutnya, pada tahap pembuatan model *ANN*, digunakan arsitektur jaringan 21-20-7. Sebanyak 21 neuron input merepresentasikan data parameter selama tiga hari terakhir (7 titik data per hari), 20 neuron digunakan pada *hidden layer* sebagai pemroses utama, dan 7 neuron *output* untuk memprediksi parameter selama satu minggu ke depan. Data dibagi menjadi data latih (21 hari pertama) dan data uji (7 hari terakhir).

Pelatihan model dilakukan menggunakan *software* Matlab R2015a dengan algoritma *Levenberg-Marquardt (trainlm)*, karena dikenal cepat dalam konvergensi pada data dengan jumlah sedang. Model dilatih untuk meminimalkan nilai eror dan meningkatkan akurasi prediksi berdasarkan perhitungan *loss function*.

Langkah terakhir adalah evaluasi model. Evaluasi dilakukan dengan melihat nilai *Mean Squared Error (MSE)*, nilai regresi (R) antara *output* dan target, serta grafik akurasi dan eror terhadap jumlah *epoch*. Selain itu, hasil prediksi dibandingkan dengan data aktual selama tujuh hari pengujian untuk menganalisis keakuratan model dalam memetakan tren dan fluktuasi data pencemaran udara.

4. Hasil dan Pembahasan


4.1. Hasil Prediksi CO

Setelah dilakukan proses normalisasi dan pemodelan menggunakan *Artificial Neural Network (ANN)*, langkah selanjutnya adalah melakukan pelatihan (*training*) dan pengujian (*testing*) terhadap model prediksi kadar karbon monoksida (CO) dan karbon dioksida (CO₂).




Gambar 1. Hasil Pelatihan CO model 21-20-7

Model yang digunakan memiliki arsitektur jaringan 21-20-7, yang terdiri dari 21 neuron pada *input layer*, 20 neuron pada *hidden layer*, dan 7 neuron pada *output layer*. Arsitektur ini dipilih berdasarkan kebutuhan prediksi selama tujuh hari ke depan menggunakan data historis 21 hari sebelumnya.




Gambar 2. Hasil MSE dari model arsitektur 21-20-7

Dari grafik tersebut terlihat bahwa proses pelatihan mencapai performa terbaik pada *epoch* ke-0 dengan nilai *MSE* validasi sebesar 0.004933. Setelah itu, nilai *MSE* pada data validasi dan pengujian cenderung stabil, sedangkan nilai *MSE* pada data pelatihan terus menurun hingga mencapai nilai minimum pada *epoch* ke-439. Hal ini menunjukkan bahwa jaringan belajar secara bertahap untuk meminimalkan kesalahan pada data pelatihan, namun kemampuan generalisasi terbaik terhadap data baru justru sudah tercapai pada awal pelatihan.


Gambar 3. Grafik regresi *output* dengan target

Gambar 3 menampilkan grafik regresi yang menunjukkan hubungan antara nilai target (aktual) dan nilai *output* (hasil prediksi) dari jaringan saraf tiruan (ANN) pada proses prediksi kadar karbon monoksida (CO). Grafik ini dibagi menjadi empat bagian, masing-masing mewakili performa jaringan pada data *training*, *validation*, *testing*, dan keseluruhan data (*all*). Setiap titik pada grafik merepresentasikan pasangan nilai target dan output, sedangkan garis solid menunjukkan garis regresi hasil pelatihan, dan garis putus-putus menunjukkan garis ideal di mana *output* sama persis dengan target ($Y = T$).



Gambar 4. Grafik target dan prediksi CO hari ke-22

Perbedaan grafik prediksi dan target terjadi pada pukul 08.30 hingga 09.30, 15.30 dan 16.30 di mana nilai prediksi CO lebih rendah dibanding nilai target. Meskipun begitu, sebagian besar titik lainnya memiliki jarak kesalahan yang relatif kecil, menunjukkan bahwa secara keseluruhan prediksi yang dihasilkan cukup akurat.




Gambar 5. Grafik target dan prediksi CO hari ke-23

Perbedaan grafik prediksi dan target terjadi pada pukul 08.30, 09.30, 15.30 dan 16.30 di mana nilai prediksi CO lebih rendah dibanding nilai target. Meskipun begitu, sebagian besar titik lainnya memiliki jarak kesalahan yang relatif kecil, menunjukkan bahwa secara keseluruhan prediksi yang dihasilkan cukup akurat.



Gambar 6. Grafik target dan prediksi CO hari ke-24

Secara umum, pola prediksi yang dihasilkan oleh model mengikuti tren utama dari nilai target. Puncak-puncak fluktuasi, seperti pada pukul 07.30, 10.00, 13.30, dan 14.30, berhasil diprediksi dengan cukup baik oleh model. Hal ini menunjukkan bahwa jaringan *ANN* mampu mengenali pola-pola peningkatan kadar CO yang cenderung konsisten pada jam-jam tertentu. Namun, terdapat beberapa perbedaan nilai yaitu pada pukul 08.30 - 09.30, 15.30, dan khususnya pada pukul 17.00 dimana nilai target mengalami lonjakan drastis, sedangkan nilai prediksi justru menurun tajam.




Gambar 7. Grafik target prediksi CO hari ke-25

Pada rentang waktu pukul 12.00 hingga 17.00, grafik menunjukkan fluktuasi kadar CO yang relatif kecil, dengan nilai target berkisar antara 0,2 hingga 0,3. Model *ANN* juga mampu menangkap fluktuasi ini dengan cukup akurat. Meskipun terdapat beberapa perbedaan kecil antara nilai prediksi dan target, pola naik-turun tetap terjaga dengan baik. Misalnya, perbedaan prediksi dan target pada pukul 15.30–16.30.




Gambar 8. Grafik target dan prediksi CO hari ke-26

Perbedaan grafik antara prediksi dan target yang terjadi pada pagi hari, tepatnya pukul 08.00 hingga 09.30, belum berhasil diprediksi dengan sangat dekat terhadap nilai aktual. Model mampu mengenali pola lonjakan ini, yang biasanya terkait dengan peningkatan aktivitas lalu lintas pagi hari. Pada rentang waktu siang hingga sore hari (12.30–17.00), kadar CO kembali menunjukkan fluktuasi yang meningkat, termasuk dua lonjakan signifikan pada pukul 16.00 dan 16.30, di mana kadar CO mendekati nilai 0,9. Model *ANN* mampu menangkap kedua lonjakan ini dengan baik, meskipun pada pukul 17.00 nilai prediksi lebih rendah dari target.



Gambar 9. Grafik target dan prediksi CO hari ke-27


Grafik di atas menunjukkan bahwa model *ANN* mampu menangkap pola tren fluktuasi kadar CO, namun pada hari ke-27 terlihat bahwa prediksi cenderung lebih agresif (*overestimate*) dibandingkan dengan nilai target actual yaitu pada pukul 08.30. Pada pukul 09.00, 15.30, 16.30, dan 17.00 terjadi perbedaan antara prediksi dan target, dimana nilai prediksi lebih rendah dibandingkan nilai target.



Gambar 10. Grafik target dan prediksi CO hari ke-28


Pola garis prediksi cenderung mengikuti tren garis target, terutama pada waktu-waktu seperti pukul 06.30 hingga 08.00, 10.00 hingga 15.00, yang menandakan bahwa model *ANN* cukup mampu mengenali pola dan fluktuasi data yang bersifat moderat. Namun, terdapat beberapa perbedaan mencolok antara nilai aktual dan hasil prediksi. Salah satu titik deviasi paling signifikan terjadi pada pukul 09.30, di mana nilai target mengalami lonjakan mendekati angka 1,0, sementara nilai prediksi tetap rendah. Hal serupa juga terlihat pada pukul 15.30, saat nilai aktual kembali meningkat tajam, tetapi tidak diikuti oleh model prediksi, sehingga menunjukkan adanya kelemahan model dalam menangkap perubahan ekstrem secara tiba-tiba.

4.1. Hasil Prediksi CO₂




Gambar 11. Hasil Pelatihan CO₂ model 21-20-7

Model arsitektur yang digunakan untuk CO₂ sama dengan model arsitektur CO yaitu 21-20-7. Arsitektur ini dipilih berdasarkan kebutuhan prediksi selama tujuh hari ke depan menggunakan data historis 21 hari sebelumnya.




Gambar 12. Hasil MSE dari model arsitektur 21-20-7

Dari grafik di atas terlihat bahwa proses pelatihan mencapai performa terbaik pada epoch ke-0 dengan nilai MSE validasi sebesar 0.0034041. Setelah itu, nilai MSE pada data validasi dan pengujian cenderung stabil, sedangkan nilai MSE pada data pelatihan terus menurun hingga mencapai nilai minimum pada epoch ke-497. Hal ini menunjukkan bahwa jaringan belajar secara bertahap untuk meminimalkan kesalahan pada data pelatihan, namun kemampuan generalisasi terbaik terhadap data baru justru sudah tercapai pada awal pelatihan.



Gambar 13. Grafik regresi output dan target

Pada grafik *Training* menunjukkan koefisien korelasi $R=0.96937$. Ini mengindikasikan bahwa jaringan cukup berhasil mengenali pola data pada tahap pelatihan, meskipun masih terdapat beberapa deviasi antara *output* dan target. Grafik *Validation* menunjukkan performa yang lebih baik dengan $R=0.97546$, yang berarti jaringan mampu melakukan generalisasi terhadap data validasi secara lebih akurat.



Gambar 14. Grafik target dan prediksi CO₂ hari ke-22

Secara umum, model ANN mampu memprediksi pola data dengan cukup baik, ditunjukkan oleh garis prediksi yang cenderung mengikuti alur data target. Pada beberapa titik waktu, seperti pukul 07.30 hingga 11.00, serta pada rentang waktu pukul 12.00 hingga 16.30, nilai prediksi cukup mendekati nilai aktual, yang mengindikasikan bahwa model memiliki performa yang baik pada kondisi data yang stabil. Namun demikian, terdapat beberapa momen di mana prediksi menunjukkan deviasi yang cukup signifikan dari nilai aktual. Salah satu perbedaan terbesar terjadi pada pukul 11.30, di mana nilai prediksi lebih rendah dari nilai target.



Gambar 15. Grafik target dan prediksi CO2 hari ke-23

Terdapat beberapa deviasi yang cukup mencolok. Salah satunya terjadi pada pukul 14.30, di mana nilai target tiba-tiba mengalami penurunan drastis hingga mendekati nilai 0, sedangkan model memprediksi nilai yang tetap tinggi, di atas 0,2. Sebaliknya, pada pukul 13.30, model berhasil memprediksi lonjakan nilai dengan cukup akurat, meskipun prediksi sedikit lebih rendah dibandingkan nilai aktual.


Pada sore hari, antara pukul 15.00 hingga 17.00, model kembali mampu mengikuti tren penurunan nilai target meskipun dengan sedikit pergeseran. Keseluruhan pola ini memperkuat temuan sebelumnya bahwa model *ANN* cukup efektif dalam menangkap tren data secara umum, tetapi masih memiliki kelemahan dalam menghadapi fluktuasi tajam atau data *outlier*, seperti yang terjadi pada pukul 14.00.



Gambar 16. Grafik target dan prediksi CO2 hari ke-24


Grafik menunjukkan bahwa model *ANN* memiliki performa prediksi yang cukup baik, terutama pada waktu pagi hari hingga menjelang siang, yakni dari pukul 06.30 hingga 11.00. Pada rentang waktu tersebut, nilai prediksi hampir identik dengan nilai target, yang menunjukkan bahwa model mampu menangkap pola stabil dengan sangat akurat.

Namun, perbedaan mulai terlihat setelah pukul 11.00, di mana nilai prediksi mengalami penurunan signifikan, sementara target tetap berada pada level tinggi. Setelah pukul 12.00, performa model kembali membaik. Ketika nilai target mulai meningkat kembali, model *ANN* mampu mengikuti tren dengan cukup baik, terutama pada puncak-puncak nilai antara pukul 13.30, 14.30, serta pukul 17.00. Meskipun terdapat sedikit keterlambatan dalam respons prediksi terhadap lonjakan nilai aktual, secara umum perbedaan antara keduanya relatif kecil.




Gambar 17. Grafik target dan prediksi CO2 hari ke-25

Akurasi tinggi pada periode ini menunjukkan bahwa model mampu mengenali pola peningkatan yang signifikan dengan baik, kemungkinan karena pola tersebut cukup representatif dalam data pelatihan. Pada siang hingga sore hari (sekitar pukul 12.00 hingga 17.00), data target cenderung stabil di kisaran 0,2 hingga 0,4. Model *ANN* tetap mampu mempertahankan prediksi yang mendekati nilai aktual, meskipun terjadi beberapa fluktuasi kecil yang tidak sepenuhnya sesuai.



Gambar 18. Grafik target dan prediksi CO2 hari ke-26


Secara umum, performa model *ANN* pada hari ini dapat dikategorikan cukup akurat, ditandai dengan banyaknya titik waktu di mana garis prediksi berada sangat dekat dengan garis target. Kecocokan pola cukup konsisten, terutama pada pukul 07.30 hingga 15.30 serta pukul 16.30 hingga 17.00. Di rentang waktu tersebut, model mampu menangkap fluktuasi naik-turun kadar gas dengan baik, serta mengikuti puncak dan lembah data secara tepat. Perbedaan terjadi di pukul 07.00 dan 16.00 dimana nilai prediksi lebih rendah dibandingkan nilai target.



Gambar 19. Grafik target dan prediksi CO2 hari ke-27

Secara umum, model *ANN* menunjukkan performa prediksi yang cukup baik, ditandai dengan pola prediksi yang sangat mirip dengan tren nilai aktual. Hal ini terlihat jelas

pada rentang waktu pukul 08.30 hingga 09.30. Model berhasil mengikuti tren naik dan turun yang terjadi secara bertahap, serta mampu memetakan puncak dan lembah dengan akurasi tinggi, terutama menjelang sore hari ketika nilai aktual mendekati angka 0,9.



Gambar 20. Grafik target dan prediksi CO2 hari ke-28

Pada awal hari (sekitar pukul 06:30 hingga 09:00), prediksi dan target mengalami kenaikan bertahap, yang menandakan peningkatan kadar CO atau CO2 seiring meningkatnya aktivitas pagi. Puncak tertinggi pada grafik terlihat terjadi di sekitar pukul 09.30, di mana nilai target mencapai titik maksimum mendekati 1, sedangkan prediksi juga cukup mendekati nilai tersebut, meskipun tidak sepenuhnya sama. Setelah puncak ini, baik nilai target maupun prediksi menurun drastis sekitar pukul 12.00 dan tetap fluktuatif hingga sore hari. Fluktuasi antara nilai prediksi dan nilai target tampak selaras pada beberapa titik, menunjukkan bahwa model *ANN* berhasil memetakan tren data dengan cukup baik, terutama pada periode antara pukul 13.00 hingga 16.00.

Namun, masih terdapat beberapa deviasi, seperti pukul 11.30 dan 12.30, di mana prediksi menunjukkan lonjakan sementara target justru berada di titik rendah. Perbedaan signifikan ini diduga terjadi karena model *ANN* yang digunakan dalam penelitian ini bersifat statik, yaitu memproses setiap data secara independen tanpa mempertimbangkan urutan waktu atau konteks hari sebelumnya. Dengan kata lain, keberhasilan prediksi pada hari ke-27 tidak menjamin keberhasilan yang sama pada hari ke-28, terutama jika terdapat perbedaan pola input. Kemungkinan lainnya adalah bahwa pada hari ke-28 pukul 11.30, data masukan memiliki karakteristik yang tidak umum atau tidak terwakili dalam data pelatihan, seperti perubahan lingkungan secara tiba-tiba (misalnya peningkatan aktivitas kendaraan, pembakaran sampah, atau kondisi cuaca tertentu). Model *ANN* yang tidak pernah mempelajari pola tersebut selama proses pelatihan cenderung mengalami penurunan akurasi, terutama ketika menghadapi nilai ekstrem atau *outlier*. Selain itu, *ANN* cenderung mengikuti pola umum (*global trend*) dan memiliki keterbatasan dalam merespons perubahan lokal yang mendadak, sehingga model mungkin melakukan *overprediction* atau *underprediction* terhadap nilai aktual. Ketidaksesuaian ini juga memperkuat dugaan bahwa model mengalami *overfitting* terhadap pola dominan, sehingga kurang fleksibel dalam menghadapi variasi yang tidak lazim. Berdasarkan hal tersebut, dapat disimpulkan bahwa meskipun model *ANN* cukup efektif dalam menangani data dengan pola stabil, performanya dapat menurun secara

signifikan ketika menghadapi anomali atau kondisi yang jarang terjadi.

4.1. Hasil Akurasi

Evaluasi akurasi dilakukan untuk mengukur sejauh mana model prediksi yang dibangun mampu menghasilkan nilai yang mendekati data aktual. Akurasi dihitung berdasarkan nilai *Mean Absolute Percentage Error (MAPE)* dengan rumus (3). Berdasarkan hasil perhitungan, model prediksi kadar **karbon monoksida (CO)** memiliki tingkat akurasi sebesar **89,96%**, sedangkan untuk kadar **karbon dioksida (CO₂)** diperoleh akurasi sebesar **95,84%**.

5. Simpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa prediksi kadar gas CO dan CO₂ berhasil dilakukan dengan menggunakan model *Artificial Neural Network (ANN)* arsitektur 21-20-7, yang terdiri dari 21 neuron *input layer*, 20 neuron *hidden layer*, dan 7 neuron *output layer* untuk prediksi 7 hari ke depan.

Model *ANN* mampu mempelajari pola historis data dengan baik, yang ditunjukkan dengan nilai regresi (*R*) mendekati 1, baik pada tahap pelatihan, validasi, maupun pengujian.

Tingkat akurasi yang diperoleh dalam memprediksi kadar gas CO sebesar 89,96%, dan kadar CO₂ sebesar 95,84%, menunjukkan bahwa model *ANN* cukup andal dalam memprediksi kualitas udara berdasarkan parameter tersebut.

Daftar Pustaka

- Ardianto, D. (2019) 'PERAMALAN DAYA LISTRIK JANGKA SANGAT PENDEK PEMBANGKIT TERMAL BERDASARKAN DATA METEOROLOGI MENGGUNAKAN METODE k-NEAREST NEIGHBOR- ARTIFICIAL NEURAL NETWORK Dwi Ardianto Unit Three Kartini .', *Jurnal Teknik Elektro*, 8, pp. 101–109.
- Bagye, W. (2020) 'Klasifikasi Kualitas Udara Dengan Metode Support Vector', *JIRE (Jurnal Informatika & Rekayasa Elektronika)*, 3(2), pp. 187–199.
- Farhan Fadilah, Agus Komarudin, M. (2024) 'PREDIKSI PENJUALAN OBAT BERBASIS ARTIFICIAL NEURAL NETWORK(ANN)', *Jurnal Informatika Teknologi dan Sains (JINTEKS)*, 6, pp. 521–531.
- Farhana, R. (2025) *PEMODELAN PREDIKSI CUACA MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERBASIS INTERNET OF THINGS (IoT) FAKULTAS SAINS DAN TEKNOLOGI UNIVERSITAS ISLAM NEGERI AR-RANIRY BANDA ACEH 2025 M / 1446 H PEMODELAN PREDIKSI CUACA MENGGUNAKAN ARTIFICIAL NEURAL NE*. UIN Ar-Raniry.
- Hakim, F.L. (2023) 'Rancang Bangun Sistem Alat Monitoring Kualitas Udara', pp. 6–20.
- Hasan, N.F. and Fatta, H. Al (2019) 'Peramalan Jumlah Penjualan Menggunakan Jaringan Syaraf Tiruan Backpropagation Pada Perusahaan Air Minum Dalam Kemasan', *Jurnal Teknik Elektro*, 5, pp. 179–188.
- Kuncoro, B.T. (2024) 'INOVASI DALAM ENERGI TERBARUKAN : JARINGAN SYARAF TIRUAN UNTUK', (November).
- Laili, B.S. and Wijanarko, D. (2023) 'Implementasi Metode Backpropagation Neural Network Dalam Memprediksi Hasil Produksi Kedelai', *Jurnal Teknologi Informasi dan Terapan (J-TIT)*, 10(1), pp. 1–6.
- Nurelasari, E. et al. (2022) 'Air Quality Index Classification Using Neural

Network Algorithms', 4(3), pp. 473–481.

Rahman, M.F. *et al.* (2017) 'Klasifikasi Untuk Diagnosa Diabetes Menggunakan Metode Bayesian Regularization Neural Network (RBNN)', *Jurnal Informatika*, 11(1), p. 36. Available at: <https://doi.org/10.26555/jifo.v11i1.a5452>.

Supriyanto, Sunardi, dan I.R. (2022) 'Pengaruh nilai hidden layer dan learning rate terhadap kecepatan pelatihan jaringan syaraf tiruan backpropagation', 6(1), pp. 27–33.