

Prediksi Konsentrasi Karbon Monoksida Menggunakan Metode *Artificial Neural Network*

Erniwati Halawa^{1,a)}, Aflah Zaharo^{1,b)}, Dian Fitrasari^{1,c)} dan Acep Purqon^{1,d)}

¹Laboratorium Fisika Bumi,
Kelompok Keilmuan Fisika Bumi dan Sistem Kompleks,
Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Bandung,
Jl. Ganesha No. 10 Bandung, Indonesia, 40132

^{a)}ernihalawa@gmail.com (corresponding author)

^{b)}aflahzaharo1@gmail.com

^{c)}dianfitrasari30@gmail.com

^{d)}acep@fi.itb.ac.id

Abstrak

Karbon monoksida merupakan salah satu zat pencemar udara yang sangat berbahaya bagi kehidupan manusia jika konsentrasinya di dalam udara melebihi batas baku mutu udara. Di Bandung, konsentrasi karbon monoksida untuk tiga tahun terakhir menunjukkan adanya kecenderungan peningkatan konsentrasi. Dengan demikian, perlu dilakukan pemantauan dan pengawasan terhadap konsentrasi karbon monoksida. Penelitian ini dilakukan untuk memprediksi konsentrasi karbon monoksida pada lima stasiun pemantau yang ada di kota Bandung, yaitu: Dago Pakar, Aria Graha, Tirtalega, Batununggal, dan Cisaranten. Untuk memprediksi konsentrasi karbon monoksida digunakan metoda ANN (*Artificial Neural Network*) dengan parameter masukan, yaitu konsentrasi zat pencemar per tiga menit setiap lima hari. Kemudian hasil yang didapatkan akan diolah sehingga keluaran yang dihasilkan dapat digunakan untuk memprediksi konsentrasi karbon monoksida untuk keesokan harinya. Hasil perhitungan konsentrasi karbon monoksida dengan metoda ANN memberikan hasil yang cukup baik. Tingkat kesalahan relatif dibandingkan dengan hasil eksperimen bernilai dibawah 10 %. Informasi ini bermanfaat untuk menjadi bahan pertimbangan dan perencanaan untuk Analisis Dampak Lingkungan (AMDAL), tata ruang kota dan kesehatan, dimana BPLH (Badan Pengelolaan Lingkungan Hidup) saat ini hanya menggunakan pengukuran secara langsung terhadap konsentrasi karbon monoksida sehingga publik hanya dapat mengetahui kondisi saat itu tanpa adanya prediksi mengenai konsentrasi polutan tersebut untuk esok hari.

Kata-kata kunci: Zat pencemar udara, karbon monoksida, Artificial Neural Network (ANN)

PENDAHULUAN

Udara merupakan faktor yang penting dalam kehidupan, namun dengan meningkatnya pembangunan fisik kota dan pusat-pusat industri, kualitas udara telah mengalami perubahan. Udara yang dulunya segar, kini kering dan kotor. Hadirnya unsur lain yang mudah bereaksi dengan oksigen akan menurunkan kadar oksigen di udara. Bagi makhluk hidup baik manusia, hewan maupun tumbuhan oksigen sangat dibutuhkan untuk proses pembakaran dan metabolisme tubuh [1].

Penurunan kadar oksigen pada batas tertentu sangat membahayakan bagi kelangsungan hidup makhluk hidup. Perubahan lingkungan udara pada umumnya disebabkan pencemaran udara, yaitu masuknya zat pencemar (berbentuk gas-gas dan partikel kecil/aerosol) ke dalam udara. Masuknya zat pencemar ke dalam udara dapat secara alamiah, misalnya asap kebakaran hutan, akibat gunung berapi, debu meteorit dan pancaran garam dari laut; juga sebagian besar disebabkan oleh kegiatan manusia, misalnya aktivitas transportasi, industri, pembuangan sampah, baik akibat proses dekomposisi ataupun pembakaran serta

kegiatan rumah tangga.

Konsentrasi pencemaran udara di beberapa kota besar dan daerah industri Indonesia menyebabkan adanya gangguan pernapasan, iritasi pada mata dan telinga, serta timbulnya penyakit tertentu. Selain itu juga menyebabkan gangguan jarak pandang (visibilitas) yang sering menimbulkan kecelakaan lalu lintas (terutama lalu lintas di udara dan laut) [2].

Masalah pencemaran udara ini tentu saja tidak bisa dibiarkan karena merupakan ancaman bagi kelangsungan hidup. Berbagai usaha telah dilakukan untuk pemantauan maupun pengendalian, seperti yang dilakukan BPLH (Badan Pengelolaan Lingkungan Hidup) dengan mengadakan pengukuran konsentrasi pencemar langsung di lapangan. Tetapi pemantauan dan pengukuran konsentrasi zat pencemar udara saja tidak cukup sehingga perlu dilakukan suatu langkah yang efektif yang dapat memberikan informasi yang lebih lengkap, yaitu dengan memprediksi konsentrasi zat pencemar udara. Dalam hal ini diadakan penelitian terhadap konsentrasi karbon monoksida pada lima stasiun pemantau di kota Bandung, yaitu: stasiun pemantau Dago Pakar, Aria Graha, Tirtalega, Batununggal dan Cisaranten. Untuk memprediksi konsentrasi karbon monoksida digunakan metoda ANN (*Artificial Neural Network*) dengan parameter masukan, yaitu konsentrasi polutan per tiga menit setiap lima hari. Kemudian hasil yang didapatkan akan diolah sehingga keluaran yang dihasilkan dapat digunakan untuk memprediksi konsentrasi karbon monoksida untuk keesokan harinya.

ARTIFICIAL NEURAL NETWORK (ANN)

Artificial Neural Network (ANN) merupakan metode pengolahan informasi yang terinspirasi dari kemampuan sistem syaraf biologis. Pada sistem ini, elemen-elemen penyusun (neuron) sebagai pemroses informasi saling terhubung dalam menyelesaikan suatu masalah. Pohon dendrit berfungsi sebagai input dan akson berfungsi sebagai output. Sebuah sistem JST biasanya dirancang untuk tujuan tertentu, misalnya untuk *fitting* (prediksi dan estimasi), *pattern recognition* (misalnya *letter recognition* atau *speech recognition*) atau klasifikasi kelompok data (*clustering*).

Neuron buatan (elemen dari JST) merupakan perangkat yang terdiri dari beberapa input berbobot (pohon dendrit), pemroses input (*black box*), dan output (akson). Bagian *black box* biasanya merupakan suatu fungsi aktivasi. Beberapa input berbobot tersebut diproses dengan fungsi aktivasi menghasilkan output (Deyfus, 2004) atau seperti pada fungsi non-linear sederhana pada persamaan 1.

$$y = f_{act} \left(w_0 + \sum_{i=0}^n w_i x_i \right) \quad (1)$$


y merupakan output, f_{act} merupakan fungsi aktivasi, w_i adalah bobot ke i untuk setiap input x ke i, dan w_0 merupakan bias.

Terdapat tiga macam fungsi yang biasa digunakan, yaitu fungsi linear, fungsi threshold, dan fungsi sigmoid. Pada fungsi linear, aktifitas output sebanding dengan jumlah bobot. Pada fungsi threshold, output diatur satu dari dua tingkatan bergantung dari apakah jumlah input lebih besar atau lebih kecil dari nilai bias. Sedangkan pada fungsi sigmoid, nilai output terus menerus berubah-ubah tetapi tidak berbentuk linear. Jadi jumlah input dapat lebih banyak daripada jumlah output. Fungsi yang digunakan adalah fungsi sigmoid karena turunannya kontinyu dan memiliki nilai rentang 0 sampai 1. Fungsi sigmoid dan turunannya ditunjukkan oleh Persamaan 2 dan 3.

$$f_{act}(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

$$\frac{df(z)}{f(z)} = f(z) \times (1 - f(z)) \quad (3)$$

Struktur jaringan pada JST adalah *feed forward network* dimana hubungan antara neuron hanya satu arah (Gambar 1). Sinyal bergerak dari input kemudian melewati lapisan tersembunyi (*hidden layer*) dan akhirnya mencapai output (struktur perilaku yang stabil). Tipe jaringan *feed forward* mempunyai neuron yang tersusun dari beberapa lapisan. Lapisan tersembunyi dan lapisan output neuron terhubung satu sama lain dengan lapisan sebelumnya.



Gambar 1. Struktur *Feed Forward*

Untuk melatih sistem JST, diperlukan kumpulan data latihan (*training data set*). Kumpulan data ini terdiri dari nilai-nilai input (x_1 dan x_2) serta outputnya (hasil keluaran yang diharapkan, dilambangkan dengan z). Pelatihan JST merupakan proses iteratif, dimana setiap iterasi nilai bobot w akan dimodifikasi untuk memperoleh hasil yang lebih tepat. Satu kali pelatihan dinamakan *epoch*. Selanjutnya, sinyal output y yang diperoleh dibandingkan dengan output yang diharapkan (z). Dari sini kemudian digunakan metode propagasi balik (*backpropagation*).

HASIL PERHITUNGAN DAN PERBANDINGAN DENGAN DATA REFERENSI

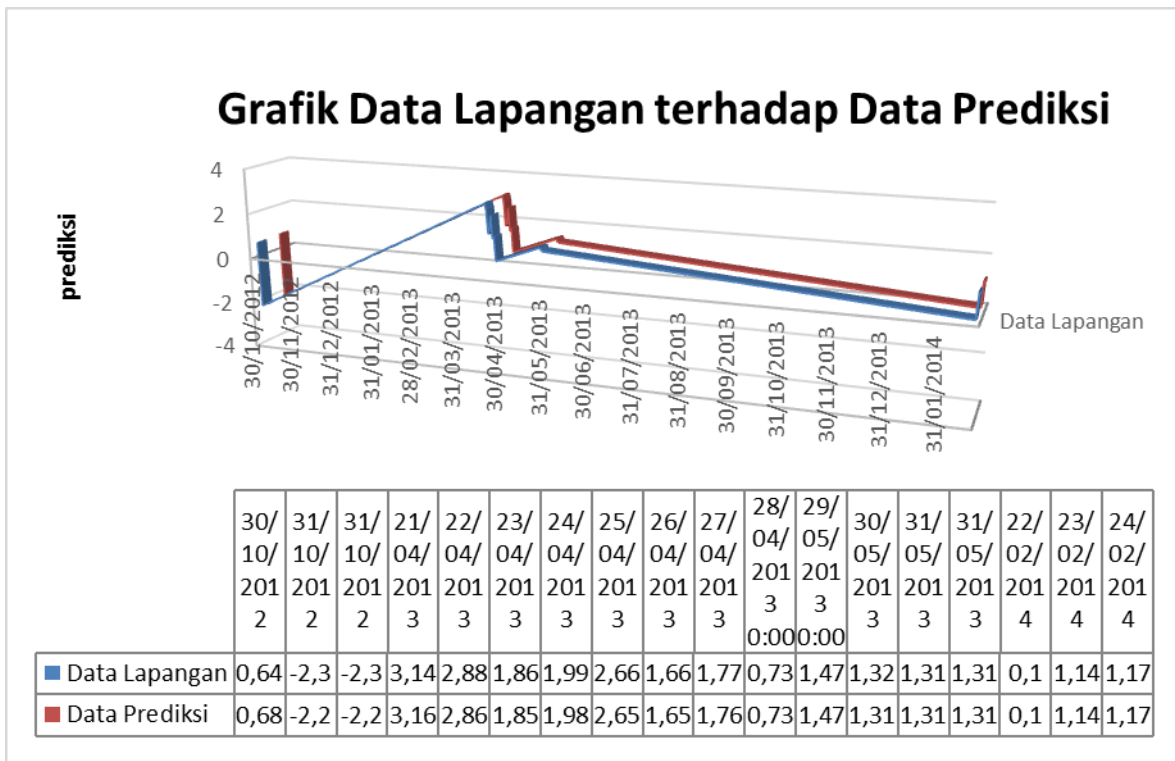
Prediksi konsentrasi CO dilakukan dengan menggunakan model ANFIS Sugeno dengan input konsentrasi CO per tiga menit dalam 24 jam setiap hari dan output prediksi konsentrasi CO. Prediksi dilakukan untuk jangka panjang (hari). Hasil identifikasi ANN memperlihatkan dua tahap yaitu: tahap pembelajaran (*training*) dan tahap pengujian (*checking*).

Untuk jangka ppanjang (hari), data *training* mulai dari data 1 sampai 605, sedangkan untuk data *checking* dari dari 605 sampai 700. Prediksi yang dihasilkan dapat dilihat pada tabel berikut.

Tabel 1. Prediksi konsentrasi CO

HARI/TANGGAL	DATA LAPANGAN	DATA PREDIKSI
10/30/2012	0.639898	0.6791
10/31/2012	-2.27306	-2.2487
10/31/2012	-2.26884	-2.2293
4/21/2013	3.144587	3.1612
4/22/2013	2.877353	2.8578
4/23/2013	1.863275	1.8525
4/24/2013	1.993788	1.9849
4/25/2013	2.65827	2.6493
4/26/2013	1.658628	1.6515
4/27/2013	1.770321	1.7649
4/28/2013	0.7336	0.7305
5/29/2013	1.466	1.4657
5/30/2013	1.319441	1.314
5/31/2013	1.314151	1.3115
5/31/2013	1.313116	1.3097
2/22/2014	0.098904	0.0995
2/23/2014	1.141003	1.1425
2/24/2014	1.174895	1.1721

Pada tabel 1 ditunjukkan nilai *checking error* hamper sama *training error*, karena data *training* merupakan data hasil pengamatan yang nilainya sudah diketahui, sedangkan data *checking* merupakan hasil prediksi.



Gambar 2. Grafik prediksi konsentrasi CO jangka pendek

Berdasarkan grafik yang terlihat nilai prediksi hampir mendekati nilai lapangan. Nilai prediksi didapatkan setelah pelatihan berulang pada data latih. Kemudian hasil script yang diujikan pada data latih dicobakan pada data uji, sehingga dihasilkan nilai seperti yang tertera pada tabel.

KESIMPULAN

Metoda *artificial neural network* memberikan alternatif metode yang sederhana namun cukup akurat dalam melakukan proses prediksi konsentrasi karbon moksida per hari. Hasil perhitungan konsentrasi karbon monoksida dengan metoda matriks ANN memberikan hasil yang cukup baik. Tingkat kesalahan relatif dibandingkan dengan hasil eksperimen bernilai dibawah 10 %.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada berbagai pihak yang telah membantu dalam penulisan makalah ini, terlebih dana bantuan yang diberikan melalui Jurusan Fisika FMIPA ITB

REFERENSI

1. Sheehy, J. P., *Handbook of Air Pollution*, PHS Publication AP-44 (PB 190-247), 1968.
2. Wark K. & Warne C. F., *Air Pollution Its Origin and Control*, New York, 1981.
3. Soenarmo, S. H., *Meteorologi Pencemaran Udara*, ITB, Bandung, 1999.
4. Soedomo, M., *Pencemaran Udara*, ITB, Bandung, 2001.
5. Jang, J.S.R., C.T. Sun. & Mizutani, E., *Neuro Fuzzy and Soft Computing*, Prentice-Hall, Inc. New Jersey, USA, 1997.
6. Kusumadewi, S., *Analisis dan Desain Sistem Fuzzy*, Edisi Pertama, Graha Ilmu, Yogyakarta, 2002.
7. Jang, J.S.R., *Adaptive Network Based Fuzzy Inference System*, IEEE Trans. On System, Man and

- Cybernetic, 23(3),665-685, 1993.
8. Zhu, Y., *ANFIS: Adaptive Neuro Fuzzy Inference System*, EE Dept, University of Missouri, Rolla, 2000.
 9. Shapiro, A.F., *From Neural network, Fuzzy Logic, and Genetic Algorithms to ANFIS and Beyond*, A Proposal for the American Risk and Insurance Association 2002 Annual Meeting, University Park, USA, 2002.
 10. Riyanto, B. & Wicaksana, S., *Application of Adaptive Neuro Fuzzy Inference System (ANFIS) To Active noise Control*, 2nd IFAC-CIGR Workshop on Intelligent Control for Agricultural Applications, Bali, Indonesia, 2001.
 11. Siang J.J., *Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan Matlab*, Andi, Yogyakarta, 2005.
 12. Devries, P.L., *A First Course in Computational Physics*, Miami University Oxford Ohio, John Wiley & Sonc Inc, 1994.
 13. Vinay I.K., *Digital Signal Processing using Matlab V.4*, Northeastern University, 1990.
 14. Thomopoulos N.T., *Applied Forecasting Methods*, Illinois Institute of Technology, 1992.
 15. Chai, T., Draxler, R. R., & Prediction, C. (2014). *Root mean square error (RMSE) or mean absolute error (MAE) – Arguments against avoiding RMSE in the literature*, (2005), 1247–1250. <http://doi.org/10.5194/gmd-7-1247-2014>
 16. Demuth, H. (n.d.). *Neural Network Toolbox*.
 17. Deyfus, G. (2004). *Neural Networks*. New York: Springer Berlin Heidelberg.
 18. Ghaderi, A., Abbasi, S., Motevali, A., & Minaei, S. (2012). *Comparison Of Mathematical Models And Artificial Neural Networks For Prediction Of Drying Kinetics Of Mushroom In Microwave – Vacuum*, 18(2), 283–293.
 19. Momenzadeh, L., Zomorodian, a., & Mowla, D. (2012). *Applying Artificial Neural network for drying time prediction of green pea in a microwave assisted fluidized Bed dryer*. *Journal of Agricultural Science and Technology*, 14(3), 513–522.
 20. Mousavi, M., & Javan, S. (2009). *Modeling and Simulation of Apple Drying , Using Artificial Neural Network and Neuro -Taguch s Method*, 11, 559–571.
 21. Poonnoy, P., Tansakul, A., & Chinnan, M. (2007). *Artificial neural network modeling for temperature and moisture content prediction in tomato slices undergoing microwave-vacuum drying*. *Journal of Food Science*, 72(1), 2–7. <http://doi.org/10.1111/j.1750-3841.2006.00220.x>
 22. Pradasari, N. I., Triyanto, D., Komputer, J. S., Elektro, J. T., Teknik, F., & Tanjungpura, U. (n.d.). *Aplikasi jaringan syaraf tiruan untuk memprediksi penyakit saluran pernafasan dengan metode backpropagation*, 1–9.
 23. Singh, N. J., & Pandey, R. K. (2011). *Neural network approaches for prediction of drying kinetics during drying of sweet potato*. *Agricultural Engineering International: CIGR Journal*, 13(1), 1–12.
 24. Yaghoubi, M., Askari, B., Mokhtarian, M., Tavakolipour, H., Elhamirad, A. H., Jafarpour, A., & Heidarian, S. (2013). *Possibility of using neural networks for moisture ratio prediction in dried potatoes by means of different drying methods and evaluating physicochemical properties*, 15(4), 258–269.