

**MODEL WAVELET NEURAL NETWORK UNTUK
PEMODELAN POLUSI UDARA DI KOTA MATARAM
LOMBOK NUSA TENGGARA BARAT INDONESIA**

Syamsul Bahri^{1*}, Syamsuddin¹, and Mustika Hadijati¹

¹Department of Mathematics, Faculty of Mathematics and Natural Science, Mataram University

Corresponding author: syamsul.math@unram.ac.id

Abstrak. Beragam metode dan teknik telah dilakukan dan dihasilkan untuk pemodelan pencemaran udara baik yang bersifat analitis, fisis, maupun numeris. Model pencemaran udara yang mutakhir adalah model dengan pendekatan soft-computing yaitu model neural network (NN). Namun dalam penerapannya, model NN yang digunakan masih berupa model NN standar belum dikombinasikan dengan metode wavelet atau teknik fuzzy (model hybrid). Karakteristik data meteorologi dan polusi yang termasuk tipe data *time series* dan *keunggulan* metode NN dan Wavelet secara parsial maupun hybrid mendasari penelitian ini. Pada penelitian ini akan dikembangkan model *feed forward wavelet* neural network (FF-WNN) yang berbasiskan pada keunggulan wavelet B-spline dan Morlet sebagai fungsi aktivasi pada model FFNN untuk memodelkan masalah pencemaran udara berdasarkan variabel data meteorologi dan parameter pencemaran udara itu sendiri. Penerapan model ini dalam memodelkan pencemaran udara di Kota Mataram-Lombok, Nusa Tenggara Barat-Indonesia memberikan hasil yang cukup signifikan berdasarkan indikator root of means square error (RMSE). Mengingat Pulau Lombok merupakan pulau kecil, model ini sekaligus dapat merepresentasikan pemodelan pencemaran udara untuk suatu kota dengan karakteristik sebagai kota pada pulau kecil.

Kata Kunci: *wavelet neural network*, polutan, pencemaran udara, prediksi *time series*, pulau kecil.

1 PENDAHULUAN

Perkembangan sains dan teknologi memicu tumbuhnya industri, dari skala kecil sampai besar. Kemajuan peradaban ini disatu sisi merupakan sesuatu yang menggembirakan, namun disisi lainnya membawa dampak buruk, khususnya pencemaran udara dan pemanasan global. Permasalahan pencemaran udara meliputi identifikasi dan pengukuran sumber polutan [1], efek dari pencemaran udara ([2] dan [3]), dan model pencemaran udara ([4]-[7]). Khusus penggunaan neural network (NN) dalam pemodelan pencemaran udara, antara lain [8], [9], dan [10] namun masih menggunakan model NN standar.

Pemodelan pencemaran udara merupakan salah satu permasalahan analisis time series. Model analisis time series klasik seperti metode Box-Jenkins, metode ARV, metode ARCH, dan metode GARCH memiliki keterbatasan dengan mensyaratkan data bersifat stasioner dan linier. Sedangkan data hasil penelitian/observasi umumnya bersifat nonlinier dan nonstasioner. Sejak tahun 1990, para peneliti telah mengembangkan metode berbasis soft computing untuk permasalahan analisis time series. Teknik soft computing dilandasi oleh beberapa metode yaitu fuzzy, neural network, algoritma genetik, wavelet, dan kombinasinya. Metode ini secara parsial maupun kombinasi, telah digunakan dan berhasil menyelesaikan permasalahan time series ([11] dan [12]).

Secara parsial, NN unggul karena memiliki kemampuan adaptif, learning algorithm by self, generalisasi, dan menyelesaikan masalah nonlinier yang kompleks dan rumit. Sedangkan wavelet unggul dalam proses de-noising, kompresi, dan multiresolusi. Kombinasi kedua metode ini merupakan metode yang relatif baru, dikenal dengan metode wavelet neural network (WNN). Berbagai permasalahan telah diselesaikan menggunakan metode WNN, seperti analisis time series nonlinear [13], image processing [14], dan desain model WNN serta aplikasinya untuk berbagai data ekonomi ([15] dan [16]).

Secara khusus keunggulan wavelet tipe Daubechies digunakan sebagai tools dalam pre-processing data dan keunggulan wavelet B-spline dan Morlet digunakan sebagai fungsi aktivasi pada model feed forward WNN yang diajukan pada penelitian ini. Model dirancang dengan memanfaatkan dua fungsi wavelet sebagai fungsi aktivasi yang di running secara paralel dan kemudian hasilnya dimultiplikasi sebagai output model WNN yang diajukan.

2 LANDASAN TEORI

2.1 Polusi Udara

Udara merupakan salah satu faktor penting dalam kehidupan mahluk hidup termasuk manusia. Sejalan dengan perkembangan teknologi dan peradaban manusia, kualitas udara pun mengalami penurunan yang disebabkan oleh terjadinya pencemaran udara. Beberapa polutan yang menjadi faktor pencemar udara diantaranya adalah Carbon Monoksida (CO), Hidro Carbon (HC), Sulfur Oksida (SO_x), Timbal (Pb), Nitrogen Oksida (NO_x), dan Partikulat (PM_x) [25]. Paparan langsung maupun tidak langsung dari polutan-polutan tersebut dapat menimbulkan efek negatif terhadap kesehatan manusia dan mahluk hidup pada umumnya.

Berdasarkan [24:4-5], CO merupakan polutan utama yang mencemari udara yang kadarnya hampir mencapai setengah dari seluruh polutan yang ada di udara yang berasal dari berbagai sumber. Gas CO yang terhisap ke dalam paru-paru akan ikut peredaran darah dan akan menghalangi masuknya oksigen yang dibutuhkan oleh tubuh manusia (mahluk hidup). Oleh karenanya, jika gas CO terhirup oleh manusia maka gas ini akan mengikat haemoglobin darah dan membentuk ikatan HbCO yang berakibat manusia kekurangan oksigen. Manusia yang menghirup gas CO walaupun dengan kadar yang sedikit dapat menyebabkan gejala keracunan dalam tubuh [23]. Hal serupa telah diungkapkan oleh Mukono [27] bahwa gejala keracunan yang diakibatkan oleh paparan gas CO antara lain mual, muntah, pusing, telinga berdengung, detak jantung meningkat, kesukaran bernapas, kelemahan otot-otot, tidak sadar dan bahkan bisa meninggal dunia.

Di pihak lain, polutan SO₂ merupakan salah satu gas buang yang larut dalam air yang dapat langsung terabsorbsi dalam hidung dan sebagian besar saluran ke paru-paru. Paparan langsung gas ini terhadap membran mukosa tubuh manusia (mahluk hidup) seperti mata, rongga hidung, dan paru-paru dapat menimbulkan iritasi, timbul reaksi alergi, nafas terengah-engah dan asma pada sebagian manusia ([21] and [25:212]).

Polutan lain yang sering menjadi perhatian adalah partikulat 10 mikrometer (PM₁₀). Partikel ini merupakan partikel halus yang berasal dari padatan atau cairan yang tersuspensi dalam udara yang merupakan campuran dari beberapa materi organik dan non-organik seperti asam sulfat, logam, partikel debu dan tanah. Partikel ini berukuran cukup kecil, yaitu 10 mikrometer atau lebih kecil ([28] and [26:27]). Dengan ukuran yang cukup kecil, jika partikel PM₁₀ terhisap ke dalam sistem pernapasan maka dapat menyebabkan gangguan pernapasan dan kerusakan pada paru-paru, menurunkan fungsi paru-paru pada anak-anak dan dapat memperparah kondisi penderita bronkhitis ([26:297-298] and [24:352]).

2.2 Neural Network

Neural network (NN) merupakan salah satu tools yang termasuk dalam kategori soft-computing yang pengembangannya dimotivasi oleh prinsip kerja otak manusia. Model ini awalnya dikembangkan oleh Warren McCulloch dan Walter Pitts pada tahun 1943 ([19]). Dalam perkembangannya, NN menjadi salah satu metode dalam analisis time series. Di antara alasan kenapa metode digunakan sebagai alat analisis time series karena NN memiliki proses perhitungan yang sederhana, tingkat interkoneksi yang tinggi, dan interaksi antara elemen-elemen dalam model yang bersifat adaptif [31].

Perbedaan dalam penerapan model NN ditentukan oleh beberapa indikator diantaranya model arsitektur, sifat pembelajarannya (apakah bersifat feed-forward, back-forward, atau bersifat recurrent), tipe pembelajarannya (supervised atau unsupervised learning), fungsi aktivasi yang digunakan, jumlah layer pada hidden layernya, jumlah neuron pada setiap layernya [18: 27-34].

2.3 Wavelet

Wavelet merupakan suatu kelas fungsi yang digunakan untuk melokalisasi suatu fungsi yang diberikan dalam dua hal yaitu posisi (waktu) dan skala (frekuensi). Kemampuan inilah yang menjadi alasan sehingga wavelet atau transformasi wavelet banyak diaplikasikan di dalam processing data seperti proses sinyal dan analisis *time series*.

Secara matematis, wavelet adalah keluarga fungsi yang dikonstruksi dari proses translasi dan dilatasi terhadap suatu fungsi, yang didefinisikan sebagai berikut [30]:

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right), \quad a, b \in \mathbf{R} \text{ and } a \neq 0, \quad (2.1)$$

dengan ψ menyatakan suatu mother wavelet, konstanta a dan b secara berturut-turut menyatakan parameter dilatasi (skala) dan parameter translasi (waktu).

Sejak tahun 1900-an, wavelet banyak digunakan sebagai analisis sinyal (signal processing) dan kemudian berkembang menjadi alat analisis time series. Metode ini menjadi alternatif analisis time series dibandingkan dengan metode statistika yang lebih dulu eksis karena keunggulannya dalam hal proses denoising, kompresi data, dan multiresolusi [32:1]. Karena keunggulan ini pulalah yang menjadi alasan para peneliti menggunakan wavelet atau transformasi wavelet sebagai alat untuk pre-processing data dan bahkan kemudian menjadi alternatif fungsi aktivasi pada model NN. Penerapan fungsi wavelet sebagai fungsi aktivasi pada model NN, dikenal model WNN, mampu meningkatkan akurasi model NN dalam hal pencocokan pola (pattern recognition) atau peramalan data time series ([16], [17], [20]).

Dari berbagai keluarga fungsi wavelet, beberapa fungsi wavelet yang sering digunakan sebagai basis analisis adalah wavelet Daubechies, B-Spline, dan Morlet. Wavelet Daubechies merupakan salah satu jenis wavelet yang memiliki support yang kompak. Jenis wavelet ini dikembangkan oleh Inggrid Daubechies sekitar tahun 1990-an. Wavelet Daubechies merupakan keluarga fungsi yang disebut dengan Wavelet Daubechies orde N (DbN), untuk suatu N bilangan asli. Wavelet Daubechies orde N dibangun berdasarkan Polinomial Daubechies orde N-1 didefinisikan sebagai berikut:

$$P_{N-1}(x) = \sum_{k=0}^{N-1} \binom{2N-1}{k} x^k (1-x)^{N-1-k}. \quad (2.2)$$

Wavelet Daubechies yang dibangun oleh polinom Daubechies orde N pada Persamaan (2.2).

Tipe wavelet berikutnya adalah wavelet B-spline. Wavelet B-spline merupakan satu keluarga wavelet yang diperoleh secara rekursif dari hasil konvolusi fungsi skala Haar [29]. Untuk bilangan asli $n \geq 1$, *B-spline* orde-n didefinisikan sebagai berikut:

$$\begin{aligned}
 N_n(x) &= \left(\underbrace{N_1 * N_1 * \dots * N_1}_{n \text{ factors}} \right)(x) = (N_{n-1} * N_1)(x) \\
 &= \int_0^1 N_{n-1}(x-t) dt,
 \end{aligned} \tag{2.3}$$

dengan $N_1(x)$ merupakan fungsi scaling Haar,

$$N_1(t) = \begin{cases} 1, & 0 \leq t < 1 \\ 0, & \text{selainnya} \end{cases}. \tag{2.4}$$

Berdasarkan konvolusi tersebut, Persamaan (2.2) dapat ditulis sebagai berikut:

$$N_n(x) = \frac{1}{(n-1)!} \sum_{k=0}^n (-1)^k \binom{n}{k} (x-k)_+^{n-1}, \tag{2.5}$$

dengan $(x)_+^n = \max\{0, x\}^n$.

Untuk $n \geq 2$, turunan pertama dari $N_n(x)$ pada Persamaan (2.5) disebut wavelet B-spline orde $n-1$. Unser [22] dengan menggunakan aproksimasi fungsi Gabor (*cosine-modulated Gaussian*) telah menghasilkan rumusan untuk aproksimasi wavelet B-spline orde n pada Persamaan (2.5) sebagai berikut:

$$\psi^n(x) = \frac{4b^{n+1}}{\sqrt{2\pi(n+1)\sigma_w^2}} \cos(2\pi f_0(2x-1)) \exp\left(\frac{-(2x-1)^2}{2\sigma_w^2(n+1)}\right), \tag{2.6}$$

dengan n menyatakan orde wavelet B-spline, konstanta $b = 0.657066$, $f_0 = 0.409177$, dan $\sigma_w^2 = 0.561145$.

Wavelet B-Spline memiliki beberapa keunggulan yang dapat menjadi dasar pertimbangan memilih wavelet ini sebagai alat analisis diantaranya memiliki bentuk formula yang eksplisit dalam domain waktu dan frekuensi, memiliki bentuk yang simetri, memiliki support yang kompak, dan proses manipulasi yang sederhana [22].

Wavelet Morlet merupakan salah satu wavelet kontinu yang diturunkan secara proporsional dari fungsi cosinus dan fungsi densitas peluang (pdf) Gaussian yang diberikan oleh persamaan berikut:

$$\psi(x) = \exp(-x^2) \cos(5x) \tag{2.7}$$

Karakteristik dari fungsi wavelet Morlet yang diekpresikan pada Persamaan (2.7) adalah bersifat non-ortogonal, memiliki support yang infinit, dan energi maksimumnya berada disekitar titik asal [20].

3 DATA DAN METODOLOGI

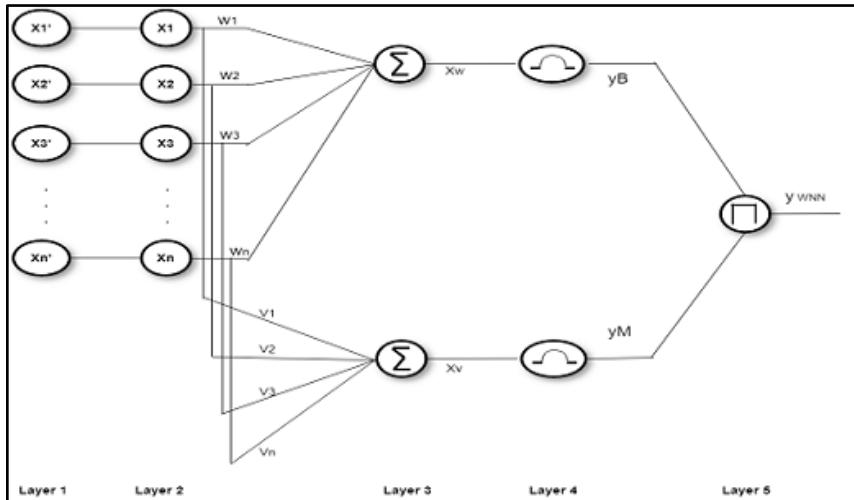
3.1 Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Dinas Lingkungan Hidup dan Kehutanan (DLHK) Provinsi Nusa Tenggara

Barat. Data yang dikumpulkan adalah data meteorologi dan parameter pencemaran udara periode Juni 2018 sampai dengan Mei 2019. Data meteorologi terdiri atas data rataan harian kecepatan angin (x_1), radiasi sinar matahari (x_2), temperatur udara (x_3), tekanan udara (x_4), dan kelembaban udara (x_5). Parameter pencemaran udara yang diamati adalah rataan harian konsentrasi Sulfur Dioksida- SO₂ (y_1) Carbon monoksida- CO (y_2) dan Partikulat PM10 (y_3).

3.2 Arsitektur Wavelet Neural Network yang Diajukan

Penerapan wavelet neural network yang diajukan pada penelitian ini berdasarkan arsitektur yang digambarkan pada Gambar 3.1.



Gambar 3.1: Architecture of WNN proposed

Arsitektur dari WNN yang diajukan terdiri atas 5 layer (Gambar 3.1). Layer 1 merupakan input data original. Pre-processing data input pada layer 1 menggunakan dua tahapan pre-processing data, yaitu normalisasi data dan transformasi wavelet Daubechies orde-8 level 3. Adapun normalisasi data menggunakan formula berikut ini:

$$x_i' = \frac{x_i - x_{\min}'}{x_{\max}' - x_{\min}'} \quad (3.1)$$

dengan x_i' menyatakan data original ke- i , x_i hasil normalisasi dari data x_i' , $x_{\min}' = \min_{1 \leq i \leq n} \{x_i'\}$, dan $x_{\max}' = \max_{1 \leq i \leq n} \{x_i'\}$. Selanjutnya, data hasil normalisasi x_i ditransformasi dengan menggunakan transformasi wavelet Daubechies orde 8 level 3.

Pada layer 3, data hasil pre-processing secara paralel dijumlahkan dengan bobot w_i dan v_i untuk $i = 1, 2, \dots, n$,

$$Xw = \sum_{i=1}^n w_i x_i' \text{ dan } Xv = \sum_{i=1}^n v_i x_i'. \quad (3.2)$$

Selanjutnya, pada layer 4 nilai Xw dan Xv berturut-turut diaktifasi menggunakan wavelet B-spline orde 3 dan wavelet Morlet yang diberikan oleh

persamaan (2.6) dan (2.7). Pada layer 5, output model WNN diperoleh berdasarkan Persamaan (3.3) berikut ini.

$$y_{WNN} = \alpha \times yB^m(Xw) \times yM(Xv) + \beta \quad (3.3)$$

untuk suatu konstanta $\alpha, \beta \in \mathbf{R}$.

3.3 Parameter Pembelajaran dari WNN yang Diajukan

Model WNN yang diajukan pada penelitian ini adalah model feed forward WNN dengan proses pembelajaran menggunakan tipe supervised training, dilakukan untuk meminimumkan fungsi biaya berikut ini [20].

$$J = \frac{1}{2N} \sum_{i=1}^N (y_i - y_i^t)^2 \quad (3.4)$$

dengan N menyatakan banyaknya data set, $J_r = \max_{1 \leq i \leq N} \{y_i^t\} - \min_{1 \leq i \leq N} \{y_i^t\}$, y_i adalah output model WNN ke- i , dan y_i^t adalah data aktual (output target) ke- i . Optimasi parameter bobot w_i dan v_i , untuk $i = 1, 2, \dots, N$ dilakukan dengan menggunakan algoritma gradient descent with momentum (GDM). Updating parameters w_i dan v_i , untuk $i = 1, 2, \dots, N$ dilakukan berdasarkan Persamaan (3.5) dan (3.6).

$$w_i(t+1) = m_c w_i(t) + (1-m_c) \eta_w \frac{\partial J}{\partial w_i}, \quad (3.5)$$

$$v_i(t+1) = m_c v_i(t) + (1-m_c) \eta_v \frac{\partial J}{\partial v_i}, \quad (3.6)$$

dengan η_w dan η_v berturut-turut menyatakan parameter pembelajaran untuk bobot W dan V, m_c menyatakan koefisien momentum pada GDM, dan nilai turunan parsial $\frac{\partial J}{\partial w_i}$ dan $\frac{\partial J}{\partial v_i}$ diberikan oleh Persamaan (3.7) dan (3.8) berikut ini.

$$\frac{\partial J}{\partial w_i} = \frac{\partial J}{\partial y_{WNN}} \frac{\partial y_{WNN}}{\partial y_B} \frac{\partial y_B}{\partial Xw} \frac{\partial Xw}{\partial w_i}. \quad (3.7)$$

$$\frac{\partial J}{\partial v_i} = \frac{\partial J}{\partial y_{WNN}} \frac{\partial y_{WNN}}{\partial y_M} \frac{\partial y_M}{\partial Xv} \frac{\partial Xv}{\partial v_i}. \quad (3.8)$$

Pemilihan nilai η_w dan η_v untuk menjamin konvergensi dari model FF-WNN ditentukan berdasarkan hasil dari [20] sebagai berikut:

$$0 \leq \eta_\rho \leq \frac{2}{\max_t \left\{ \frac{\partial y(t)}{\partial \eta_\rho} \right\}}, \quad \rho = w \text{ dan } v. \quad (3.9)$$

4 HASIL DAN PEMBAHASAN

4.1 Organisasi Data

Pemodelan pencemaran udara didasarkan pada hubungan bahwa jumlah konsentrasi suatu polutan di udara dipengaruhi oleh variabel meteorologi dan konsentrasi polutan yang ada di udara, termasuk jenis polutan itu sendiri. Berdasarkan fakta ini maka dapat diformulasikan hubungan tersebut sebagai berikut:

$$y_j = f(x_1, x_2, x_3, x_4, x_5, y_1, y_2, y_3), \quad j = 1, 2, 3, \quad (4.1)$$

dengan x_i , $i = 1, 2, \dots, 5$ menyatakan variabel meteorologi ke- i dan y_j , $j = 1, 2, 3$ menyatakan jenis polutan ke- j . Di sisi lain, masing-masing variabel meteorologi secara time series dipengaruhi oleh data sejenis pada waktu sebelumnya yang berikan oleh persamaan berikut ini.

$$x_i(t) = g(x_i(t-k_i)), \quad (4.2)$$

untuk setiap $i = 1, 2, \dots, 5$ dan untuk suatu bilangan asli k_i . Hal serupa juga berlaku untuk suatu konsentrasi polutan di udara, dimana konsentrasi suatu polutan dipengaruhi oleh konsentrasi polutan itu sendiri dan konsentrasi polutan lain pada waktu-waktu sebelumnya yang dapat ditulis dalam hubungan sebagai berikut:

$$y_j(t) = h(y_l(t-p_j)), \quad l = 1, 2, 3. \quad (4.3)$$

untuk suatu bilangan asli p_j dan setiap $j = 1, 2, 3$. Berdasarkan Persamaan (4.2) dan (4.3) maka Persamaan (4.1) dapat ditulis kembali menjadi:

$$y_j = f(g(x_i(t-k_i)), h(y_l(t-p_j))), \quad i = 1, 2, \dots, 5; j, l = 1, 2, 3. \quad (4.4)$$

Berdasarkan Persamaan (4.2) dan analisis autocorrelation pada setiap variabel meteorologi diperoleh fakta bahwa:

$$x_1(t) = g(x_1(t-1), x_1(t-2)). \quad (4.5)$$

$$x_2(t) = g(x_2(t-1)). \quad (4.6)$$

$$x_3(t) = g(x_3(t-1), x_3(t-5), x_3(t-7)). \quad (4.7)$$

$$x_4(t) = g(x_4(t-1)). \quad (4.8)$$

$$x_5(t) = g(x_5(t-1), x_5(t-3)). \quad (4.9)$$

Sedangkan Berdasarkan Persamaan (4.3), analisis auto-correlation dan cross-correlation pada setiap jenis polutan diperoleh fakta bahwa:

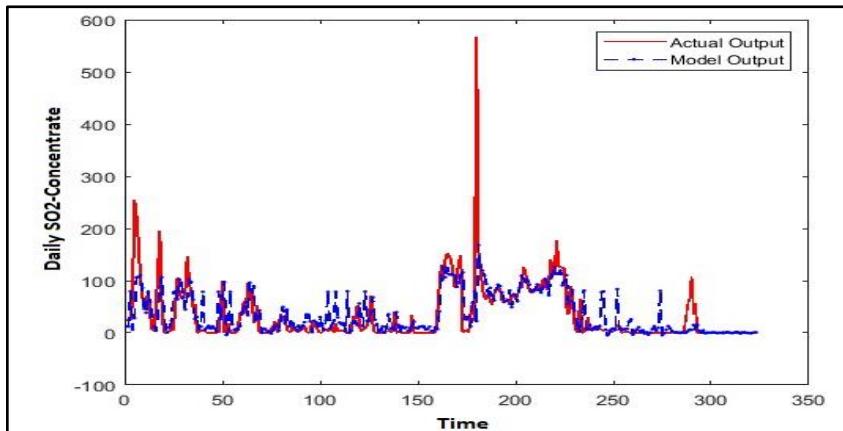
$$y_1(t) = h(y_1(t-1), y_1(t-7), y_2(t-1), y_3(t-1), y_3(t-2), y_3(t-3)). \quad (4.10)$$

$$y_2(t) = h(y_1(t-1), y_1(t-7), y_2(t-1), y_3(t-1)). \quad (4.11)$$

$$y_3(t) = h(y_1(t-1), y_1(t-2), y_1(t-3), y_2(t-1), y_2(t-2), y_2(t-3), y_3(t-1)). \quad (4.12)$$

4.2 Model Polutan SO₂

Penerapan model WNN yang diajukan untuk pemodelan polutan SO₂, didasarkan pada Persamaan (4.4) dan fakta yang diberikan oleh Persamaan (4.10) dan Persamaan (4.5) – (4.9). Pembelajaran sebanyak 10000 iterasi terhadap 280 data time series rataan harian konsentrasi SO₂ dan kemudian diuji terhadap 43 data testing memberikan hasil seperti pada Gambar 4.1.



Gambar 4.1: Perbandingan pola grafik antara output model WNN yang diajukan (biru) dan data aktual (merah) untuk polutan SO₂.

Akurasi model WNN yang diajukan untuk memodelkan polutan SO₂ dan beberapa indikator statistik diberikan oleh Tabel 4.1.

Tabel 4.1. Performa Model WNN yang diajukan untuk Pemodelan SO₂.

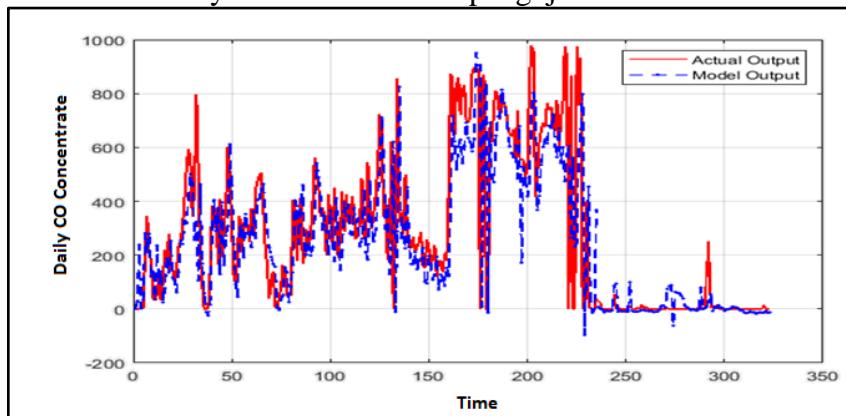
| Data | Indikator Statistik | | | | | | Performa (RMSE) | |
|-----------|---------------------|--------|---------|---------|-----------|----------|-----------------|--|
| | Data Min | | Rataan | | Data Maks | | | |
| | Model | Aktual | Model | Aktual | Model | Aktual | | |
| Pelatihan | -4.7295 | 0 | 41.5246 | 38.5050 | 168.2065 | 567.3958 | 46.3129 | |
| Pengujian | -1.3673 | 0 | 1.6387 | 8.3525 | 15.0341 | 108.3750 | 21.8532 | |

Secara umum, berdasarkan Gambar 4.1 terlihat bahwa pemodelan dengan model WNN yang diajukan telah memperlihatkan pola yang sudah benar. Namun, data aktual polutan SO₂ sepanjang periode pelatihan memiliki lonjakan pada data ke-180 yang cukup tinggi atau secara statistika dapat dipandang sebagai outlier. Selain data ke 180, terdapat sekitar 5 data target yang memiliki selisih cukup lebar dengan output model, yaitu data ke-5, 6, 7, 18, dan 32 dan sekitar tiga output model yang jauh lebih tinggi dari data aktualnya. Akumulasi dari selisih-selisih tersebut memberikan kontribusi terhadap besarnya RMSE data pelatihan yang diperlihatkan pada Tabel 4.1. Sedangkan pada data pengujian, besarnya nilai RMSE didominasi oleh pengaruh data ke-287 sampai dengan 292.

4.3 Model Polutan CO

Penerapan model WNN yang diajukan untuk pemodelan polutan CO, didasarkan pada Persamaan (4.4) dan fakta yang diberikan oleh Persamaan (4.11) dan Persamaan (4.5) – (4.9). Pembelajaran sebanyak 10000 iterasi terhadap 280 data time series rataan harian konsentrat CO dan kemudian diuji terhadap 42 data testing memberikan hasil seperti pada Gambar 4.2.

Serupa dengan kasus polutan SO₂, Gambar 4.2 memperlihatkan bahwa pola output model WNN sudah cukup baik. Namun, selisih yang cukup besar pada beberapa data yaitu data ke 32-33, 161-165, 201-203, dan 232-234 dimana output model jauh lebih kecil dari data aktualnya dan nilai perkiraan output model lebih besar dari data aktualnya terjadi data ke 217 – 229. Akumulasi dari selisih-selisih ini memberikan kontribusi terhadap besarnya nilai RMSE data pelatihan. Sedangkan pada data pengujian, nilai output model WNN lebih tinggi dari data aktualnya dengan selisih yang cukup besar terjadi pada data ke 291 dan 292. Nilai ini mendominasi besarnya nilai RMSE data pengujian.



Gambar 4.2: Perbandingan pola grafik antara output model WNN yang diajukan (biru) dan data aktual (merah) untuk polutan CO.

Akurasi model WNN yang diajukan untuk memodelkan polutan CO dan beberapa indikator statistik diberikan oleh Tabel 4.2.

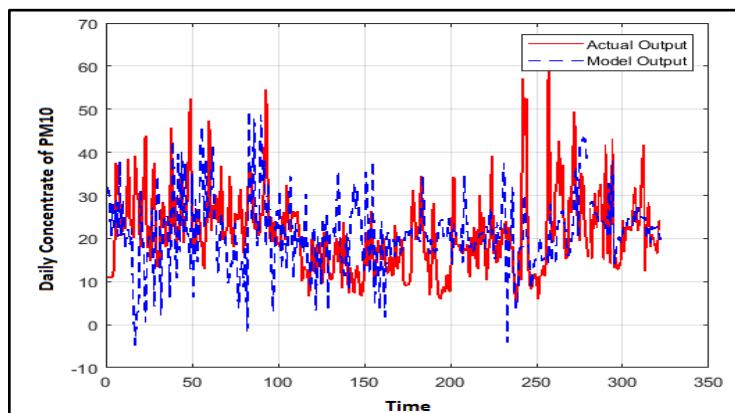
Tabel 4.2: Performa Model WNN yang diajukan untuk Pemodelan CO.

| Data | Indikator Statistik | | | | | | Performa (RMSE) | |
|-----------|---------------------|---------|----------|----------|-----------|----------|-----------------|--|
| | Data Min | | Rataan | | Data Maks | | | |
| | Model | Aktual | Model | Aktual | Model | Aktual | | |
| Pelatihan | 96.7481 | 0 | 343.1558 | 382.0286 | 950.4266 | 977.5000 | 217,3298 | |
| Pengujian | -62.0910 | -0.0217 | 6.5118 | 7.4230 | 99.1299 | 249.6552 | 39,859 | |

4.4 Model Polutan PM₁₀

Penerapan model WNN yang diajukan untuk pemodelan polutan PM₁₀, didasarkan pada Persamaan (4.4) dan fakta yang diberikan oleh Persamaan (4.12) dan Persamaan (4.5) – (4.9). Pembelajaran sebanyak 10000 iterasi terhadap 280

data time series rataan harian konsentrat PM₁₀ dan kemudian diuji terhadap 42 data testing memberikan hasil seperti pada Gambar 4.3.



Gambar 4.3: Perbandingan pola grafik antara output model WNN yang diajukan (biru) dan data aktual (merah) untuk polutan PM₁₀.

Akurasi model WNN yang diajukan untuk memodelkan polutan PM₁₀ dan beberapa indikator statistik diberikan oleh Tabel 4.3.

Tabel 4.3: Performa Model WNN yang diajukan untuk Pemodelan PM₁₀.

| Data | Indikator Statistik | | | | | | Performa Model (RMSE) | |
|-----------|---------------------|---------|---------|---------|-----------|---------|-----------------------|--|
| | Data Min | | Rataan | | Data Maks | | | |
| | Model | Aktual | Model | Aktual | Model | Aktual | | |
| Pelatihan | -4.7537 | 4.7708 | 21.1047 | 20.9286 | 49.5866 | 62.7234 | 12,7327 | |
| Pengujian | 14.1340 | 12.5000 | 23.5749 | 23.4139 | 38.1323 | 43.1212 | 6,5486 | |

Berdasarkan Gambar 4.3, perbandingan grafik output model WNN dengan data aktual polutan PM₁₀ telah memperlihatkan pola yang baik sebagai model prediksi terutama pada data pengujian. Secara umum, output model WNN memiliki nilai yang lebih kecil dibandingkan dengan data aktualnya (under estimate).

Secara teori, salah satu faktor yang mempengaruhi konsentrasi polutan di udara juga ditentukan oleh curah hujan. Curah hujan yang tinggi dapat mengurangi dan atau membersihkan konsentrasi polutan di udara terutama polutan yang berupa partikel. Pada studi kasus yang dibicarakan, belum melibatkan variabel curah hujan sebagai faktor yang mempengaruhi konsentrasi polutan di udara dan faktor ini patut diduga menjadi salah satu penyebab belum maksimalnya akurasi model WNN yang diajukan sebagai model polusi udara. Pada penelitian selanjutnya, akurasi model WNN juga akan diperbaiki dengan memasukkan inferensi fuzzy pada arsitektur WNN yang diajukan untuk mengantisipasi karakteristik ketidakpastian dari faktor meteorologi.

5 KESIMPULAN

Pemodelan masalah pencemaran udara pada penelitian ini berbasiskan model hybrid Neural Network dengan metode wavelet. Berdasarkan indikator RMSE, penerapan model FF-WNN yang dikembangkan pada penelitian memberikan hasil yang cukup baik, terlihat pada pola grafik output model (SO₂, CO dan PM₁₀) dibandingkan dengan data target terutama pada bagian data in-sample. Kekurangakuratan model yang dikembangkan dalam pemodelan masalah

pencemaran udara diduga dipengaruhi oleh faktor curah hujan yang belum dimasukan sebagai variabel independent pada model. Oleh karenanya, pada penelitian selanjutnya kami akan mengoptimalkan pemodelan pencemaran udara dengan memasukan faktor curah hujan sebagai variabel independent pada model dan mengantisipasi masalah ketidakpastian data meteorologi dan parameter pencemaran udara dengan mengakomodasi inferensi fuzzy pada model FF-WNN yang telah dikembangkan.

DAFTAR PUSTAKA

- [1] Tiwary, A. and Colls J., 2010, *Air Pollution: Measurement, modelling and mitigation*, Third Edition, Routledge - Taylor and Francis Group, London.
- [2] Huang, J., Pan, X., Guo, X., and Li, G., 2018, Impacts of air pollution wave on years of life lost: A crucial way to communicate the health risks of air pollution to the public, *Environment International*, Vol. 113, p.:42–49.
- [3] Lee, S., Yoo, H., and Nam, M., 2018, Impact of the Clean Air Act on air pollution and infant health: Evidence from South Korea, *Economics Letters*, DOI: <https://doi.org/10.1016/j.econlet.2018.04.010>.
- [4] Migual, JPM., de Blas, CS., and Sipols, AEG., 2017, A forecast air pollution model applied to a hypothetical urban road pricing scheme: An empirical study in Madrid, *Transportation Research, Part D*, Vol. 55, p.: 21–38.
- [5] Chalabi, Z., Milojevic, A., Doherty, RM., Stevenson, DS., MacKenzie, IA., Milner, J., Vieno, M., Williams, M., and Wilkinson, P., 2017, Applying air pollution modelling within a multi- criteria decision analysis framework to evaluate UK air quality policies, *Atmospheric Environment*, Vol. 167, p.: 466-475.
- [6] Vitolo, C., Scutari, M., Ghalienny, M., Tucker, A., and Russell, A., 2018, Modeling Air Pollution, Climate, and Health Data Using Bayesian Networks: A Case Study of the English Regions, *Earth and Space Science*, Vol. 5, p.:76–88 (<https://doi.org/10.1002/2017EA000326>).
- [7] Gomez-Losada, A., Pires, JCM., and Pino-Mejías, R, 2018, Modelling background air pollution exposure in urban environments: Implications for epidemiological research, *Environmental Modelling & Software* xxx, p.:1-9.
- [8] Rynkiewicz, J., Dutot A. L., and Steiner, F., 2002, Ozone Modeling in an Urban Atmosphere Using Artificial Neural Network Hybrid Hidden Markov Model/Multi-Layer Perceptron the NEUROZONE Model, *Proceedings Second Conference on Air Pollution Modelling and Simulation*, APMS' 01 Champs-sur-Marne, April 9-12,2001 Edited by B. Sportisse, Berlin Heidelberg: Springer-Verlag.
- [9] Nunnari, G. and Nucifora, A., 2002, A Neural Prediction Model for the Maximum Daily Ozone Concentration, *Proceedings Second Conference on Air Pollution Modelling and Simulation*, APMS' 01 Champs-sur-Marne, April 9-12,2001 Edited by B. Sportisse, Berlin Heidelberg: Springer-Verlag.
- [10] Krajny, E., Osrodko, L., and Wojtylak, M., 2002, Application of Artificial Neural Network in Forecasting of Air Pollution in Large Industrial Urban Area, *Proceedings Second Conference on Air Pollution Modelling and Simulation*, APMS' 01 Champs-sur-Marne, April 9-12,2001 Edited by B. Sportisse, Berlin Heidelberg: Springer-Verlag.

- [11] Mendivil, SG., Castillo, O., and Melin P., 2008, Optimization of Artificial Neural Network Architectures for Time Series Prediction using Parallel Genetic Algorithms, *Soft Computing for Hybrid Intel. Systems*, SCI. 154, pp. 387-399.
- [12] Lineesh, M. C., K. K. Minu, and C.J. John, 2010, Analysis of Nonstationary Nonlinear Economics Time series of Gold Price A Comparative Study. *International Mathematical Forum*, 5, no. 34, 1673 – 16.
- [13] Minu, K. K., M. C. Lineesh and C.J. John, 2010, Wavelet Neural Networks for Nonlinear Time series Analysis, Jounal of Applied Mathematical Sciences, Vol. 4, no. 50, 2485 – 2495.
- [14] Amar, C. Ben and O. Jemai, 2007, Wavelet Networks Approach for Image Compression, GVIP Special Issue on Image Compression.
- [15] Brzudka, J., 2004, Wavelet vs. Spectral Analysis of an Economic Process, *Dynamic Econometric Models*. Vol. 6 – Nicolaus Copernicus University – Toruń – 2004.
- [16] Bahri, S., Widodo, and Subanar, 2016a, Applied Multiresolution B-Spline Wavelet to Neural Network Model and Its Application to Predict some Economics Data, *International Journal of Applied Mathematics and Statistics*, Int. J. Appl. Math. Stats.; Vol. 54; Issue No. 1.
- [17] Bahri, S., Widodo, and Subanar, 2016b, Optimization of Wavelet Neural Networks Model by Setting the Weighted Value of Output Through Fuzzy Rules Takagi–Sugeno–Kang (TSK) Type as A Fixed Parameter, *Global Journal of Pure and Applied Mathematics*, GJPAM, Vol. 12, Num. 3, pp. :2591-2603.
- [18] Bahri, S., 2017, Desain and Evaluasi Performa Model Wavelet Neural Network untuk PemodelanTime Series, Disertasi, Jurusan Matematika-FMIPA UGM.
- [19] Fausett, L., 1994, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice Hall, USA.
- [20] Banakar, A., and Azeem, M.F., 2006, Artificial Wavelet Neural Network and Its Application in Neuro Fuzzy Models, *Applied Soft Computing*, Vol. 8, pp. 1463-1485.
- [21] Seinfeld, J.H. and Pandis, S.N., 2006, *Atmospheric Chemistry and Physics: From Air Pollution to Climate Change*, Second Edition, John Willey & Sons, Inc, USA.
- [22] Unser, M., 1997, Ten Good Reasons for Using Spline Wavelets, *Proc. SPIE*, Vol. 3169, Wavelets Applications in Signal and Image Processing, pp. 422-431
- [23] Kulshreshtha, Priyanka, 2019, Impact of Air Pollution on Human Health, in: Saxena, P. and Naik, V. (Editors), *Proceeding of The CAB International*, Air Pollution: Sources, Impacts and Controls, Boston, United Kingdom, pp. 135-150.
- [24] Lazaridis, Mihalis, 2011, *First Principles of Meteorology and Air Pollutions*, Springer, New York.
- [25] Vallero, Daniel, 2014, *Fundamentals of Air Pollution*, Fifth Edition, Academic Press, USA.

- [26] Gurjar, B.R., Molina, L.T., and Ojha, C.S.P., 2010, *Air Pollution: Health and Environmental Impacts*, CRC Press, USA.
- [27] Mukono, H. J., 2008, Pencemaran Udara dan Pengaruhnya Terhadap Gangguan Saluran Pernapasan, Airlangga University Press, Surabaya-Indonesia.
- [28] EPA, 2015, Environments and Contaminants: Criteria Air Pollutants, *America's Children and The Environment*, Third Edition, USA.
- [29] Tang, Y. Y., Yang, L. H., Liu, J., and Ma, H., 2000, *Wavelet Theory and Its Application to Pattern Recognition*, World Scientific Publishing Co. Pte. Ltd., Singapore.
- [30] Debnath, L., 2002, *Wavelet Transforms and Their Applications*, Birkhauser, Boston.
- [31] Smith, L., 1996, An Introduction to Neural Network, A talk given at the NSYN meeting in Edinburgh, Scotland, on 28 February 1996.
- [32] Walker, J. S., 2008, *A Primer on Wavelets and Their Scientific Applications*, Second Edition, Chapman & Hall/CRC, USA.