

MODEL ADAPTIF *NEURO FUZZY INFERENCE SYSTEM* BERDASARKAN PH, TEMPERATUR DAN TSS UNTUK PREDIKSI NILAI COD

Wahyudi Harianto¹

¹ Teknik Informatika, Universitas Kanjuruhan Malang

¹ wh3210@gmail.ac.id

Abstrak— Tingkat pencemaran sungai setiap tahun mengalami peningkatan, hal ini menyebabkan kualitas air sungai semakin menurun yang disebabkan oleh buangan limbah industri dan limbah domestik. Untuk mendapatkan model estimasi *Cemical Oxygen Demand (COD)* maka perlu dilakukan analisa data di lingkungan sungai. Kemudian dilakukan pembentukan model estimasi untuk memprediksi *Cemical Oxygen Demand (COD)*. Untuk menyelesaikan permasalahan tersebut maka diperlukan suatu algoritma untuk estimasi dan prediksi *Cemical Oxygen Demand (COD)* untuk mengetahui gambaran umum terhadap tingkat *COD*. Adaptif *Neuro Fuzzy Inference System* adalah suatu algoritma untuk menyelesaikan permasalahan tersebut. Hasil penelitian menunjukkan menggunakan Adaptif *Neuro Fuzzy Inference System (ANFIS)* dapat diterapkan untuk membangun model estimasi untuk prediksi nilai *Cemical Oxygen Demand (COD)*. Hasil model estimasi yang dinilai paling baik dengan RMSE training 2,11993, RMSE testing 5,93532, MAE training 1,52225, MAE testing 4,2165 dengan persentase keberhasilan untuk training 94,7695 % dan testing 68,1839 %.

Kata kunci: Adaptif *Neuro Fuzzy Inference System (ANFIS)*, *Cemical Oxygen Demand (COD)*, Estimasi, Model, Kualitas Air Sungai

I. PENDAHULUAN

Kualitas air sungai sangat bergantung pada jenis kegiatan yang dilakukan manusia di sekitar daerah aliran sungai. Berkembangnya kegiatan penduduk di sekitar Sungai yang memanfaatkan bantaran sungai untuk pemukiman, kegiatan industri rumah tangga, dan industrialisasi merupakan sumber pencemaran sungai. Sementara itu, faktor kegiatan manusia dianggap berperan utama dalam menyumbangkan pencemaran sungai. Faktor manusia atau masyarakat seperti perkembangan pertanian, peningkatan populasi, urbanisasi, industrialisasi dan juga kegagalan kebijakan diidentifikasi sebagai akar penyebab pencemaran air (UNEP, 2006). Berdasarkan sumber-sumber tersebut

dapat disimpulkan bahwa secara umum penyebab terjadinya pencemaran sungai berasal dari limbah industri, limbah domestik, perilaku masyarakat dan kegagalan kebijakan.

Menurut Keputusan Menteri Negara Lingkungan Hidup Nomor 112 Tahun 2013 tentang Baku Mutu Air Limbah Domestik, air limbah domestik adalah air limbah yang berasal dari usaha dan atau kegiatan permukiman (real estate), rumah makan (restauran), perkantoran, perniagaan, apartemen dan asrama. Limbah domestik dapat berupa sampah, air kakus (*black water*), dan air buangan dari berbagai aktivitas domestik lainnya. Salah satu parameter kualitas limbah domestik adalah kebutuhan oksigen kimiawi atau lebih dikenal sebagai *COD (Chemical Oxygen Demand)*.

Dalam bidang matematika, Apriliani dan Masduqi (2008) menggunakan algoritma Kalman Filter dapat dilakukan estimasi kualitas air sungai Kali Surabaya dengan cukup akurat dan parameter yang digunakan adalah Keasaman (pH), Kadar Oksigen Terlarut (DO), Kebutuhan Oksigen Secara Biokimia (BOD), Kebutuhan Oksigen Secara Kimiawi (COD), Padatan Tersuspensi (TSS), Kadar Nitrat, dan Kadar Fosfat.

Dalam *Journal of Hydrology 511*, Murat Ay, Ozgur Kisi (2014), mengusulkan integrasi metode *k-means clustering* dan *multi-layer perceptron (k-means-MLP)* dalam pemodelan kebutuhan oksigen kimia (*Chemical Oxygen Demand*). Metode ini diuji dengan menggunakan data harian dari padatan tersuspensi, pH, suhu, debit dan data konsentrasi Oksigen Kimiawi di hulu dari sistem pengolahan air limbah kota di provinsi Adapazari Turki. Kinerja metode *k-means-MLP* dibandingkan dengan regresi multi-linear, multi-layer perceptron, jaringan syaraf berbas radial, regresi jaringan saraf, dan dua adaptif yang berbeda teknik sistem inferensi *neuro-fuzzy* (pengelompokan subtraktif dan partisi grid). Ditemukan bahwa *k-means-MLP* lebih baik daripada teknik lain dalam memperkirakan Oksigen Kimiawi. Selain itu, *k-means* dikombinasikan dengan MLP dapat digunakan sebagai alat bantu dalam pemodelan konsentrasi Oksigen Kimiawi sehari-hari.

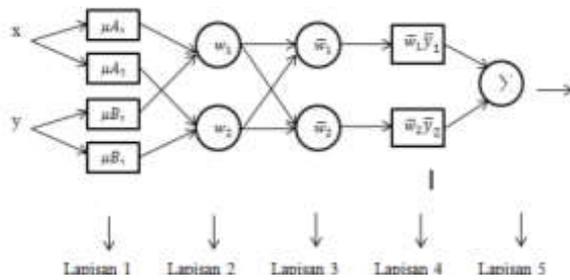
Chemical Oxygen Demand (COD) termasuk dalam karakteristik kimia zat organik dalam air limbah.

Chemical Oxygen Demand (COD) adalah jumlah oksigen (mg O₂) yang dibutuhkan untuk mengoksidasi zat-zat organis yang ada dalam 1 liter sampel air. Pengujian *Chemical Oxygen Demand* (COD) pada air limbah memiliki beberapa keunggulan dibandingkan pengujian *Biology Oxygen Demand* (BOD) yaitu : Sanggup menguji air limbah industri yang beracun yang tidak dapat diuji dengan *Biology Oxygen Demand* (BOD) karena bakteri akan mati dan waktu pengujian yang lebih singkat, kurang lebih hanya 3 jam. *Chemical Oxygen Demand* (COD) merupakan salah satu parameter untuk mengetahui adanya suatu pencemaran yang disebabkan oleh air limbah. Dengan parameter ini sebenarnya sudah cukup untuk mengetahui apakah air tersebut tercemar atau tidak.

Dalam penelitian ini diharapkan dengan penerapan metode *Adaptive Neuro Fuzzy Inference System* (ANFIS) didapatkan model untuk prediksi nilai COD

II. TINJAUAN PUSTAKA

Adaptive Neuro Fuzzy Inference System (ANFIS) memiliki arsitektur yang dapat terlihat dalam struktur dibawah ini. Dengan sistem inferensi fuzzy yang diterapkan adalah inferensi fuzzy model Takagi Sugeno Kang.



Gambar 2.1 Arsitektur Jaringan ANFIS

Fungsi dari setiap lapis adalah sebagai berikut:

Lapisan 1.

Semua simpul pada lapisan ini adalah simpul adaptif (parameter dapat berubah) tergantung pada fungsi keanggotaan yang digunakan. Berikut persamaan matematis dengan fungsi keanggotaan *gbell*:

$$\mu A_i(x) = \frac{1}{1 + |\frac{x-c}{a}|^{2b}}, \text{ untuk } i = 1,2$$

$$\mu B_i(y) = \frac{1}{1 + |\frac{y-c}{a}|^{2b}}, \text{ untuk } i = 3,4 \quad (2.1)$$

dengan x dan y adalah masukan pada simpul i, A_i atau B_i adalah fungsi keanggotaan masing-masing simpul. Simpul O_{1,i} berfungsi untuk menyatakan derajat keanggotaan tiap masukan terhadap himpunan fuzzy A dan B. Fungsi keanggotaan yang digunakan adalah *gaussian* dengan parameter *premis* dan dapat diketahui nilainya dari hasil pembelajaran ANFIS

Lapisan 2.

Semua simpul pada lapisan ini adalah nonadaptif (parameter tetap). Fungsi simpul :

$$w_i = \mu A_i(x) \mu B_i(y), \quad i = 1,2 \quad (2.2)$$

Tiap keluaran simpul menyatakan derajat pengaktifan (*firing strength*) tiap aturan *fuzzy*. Fungsi ini dapat

diperluas apabila bagian premis memiliki lebih dari dua himpunan *fuzzy*. Banyaknya simpul pada lapisan ini menunjukkan banyaknya aturan yang dibentuk. Fungsi perkalian yang digunakan adalah interpretasi kata *hubung and* dengan menggunakan operator t-norm.

Lapisan 3

Setiap simpul pada lapisan ini adalah simpul nonadaptif yang menampilkan fungsi derajat pengaktifan ternormalisasi (*normalized firing strength*) yaitu rasio keluaran simpul ke-i pada lapisan sebelumnya terhadap seluruh keluaran lapisan sebelumnya, dengan bentuk fungsi simpul:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2 \quad (2.3)$$

Apabila dibentuk lebih dari dua aturan, fungsi dapat diperluas dengan membagi w_i dengan jumlah total w untuk semua aturan.

Lapisan 4.

Setiap node pada lapis ini adalah adaptif dengan fungsi node

$$\bar{w}_i \bar{y}_i = \bar{w}_i (p_i x_i + q_i x_i + r_i) \quad (2.4)$$

Dengan w_i: kuat penyulutan ternormalisasi dari lapisan 3, {p_i,q_i,r_i}: himpunan parameter dari node ini. Parameter pada lapis ini disebut parameter konsekuen.

Lapisan 5.

Pada lapisan ini hanya ada satu simpul tetap yang fungsinya untuk menjumlahkan semua masukan. Fungsi simpul :

$$\sum_i \bar{w}_i \bar{y}_i = \frac{\sum w_i \bar{y}_i}{\sum w_i} \quad (2.5)$$

Jaringan adaptif dengan lima lapisan tersebut ekuivalen dengan sistem inferensi fuzzy TSK.

III. METODE PENELITIAN

Data yang digunak adalah parameter TSS, pH, temperatur dan COD akan dibagi menjadi data *training*, *testing* dan *validasi*. Validasi model adalah proses dimana vektor masukan dari set data *input / output* yang FIS tidak terlatih , disajikan dengan model FIS dilatih, untuk melihat seberapa baik model FIS memprediksi data yang sesuai untuk menetapkan nilai-nilai *output*. Data yang dimasukkan harus berupa data matriks masukan dan target sekaligus.

x11	x21	x31	y1
x12	x22	x32	y2
x13	x23	x33	y3
.	.	.	.
.	.	.	.
.	.	.	.

Gambar 3.2 Matrik Data, a, b, c: Masukan, d:Target

Misalkan:

Parameter TSS={x11, x12, x13, ...}, parameter pH={x21, x22, x23,...}, parameter temperatur={x31, x32, x33, ...}, parameter COD={y1, y2, y3, ...}.

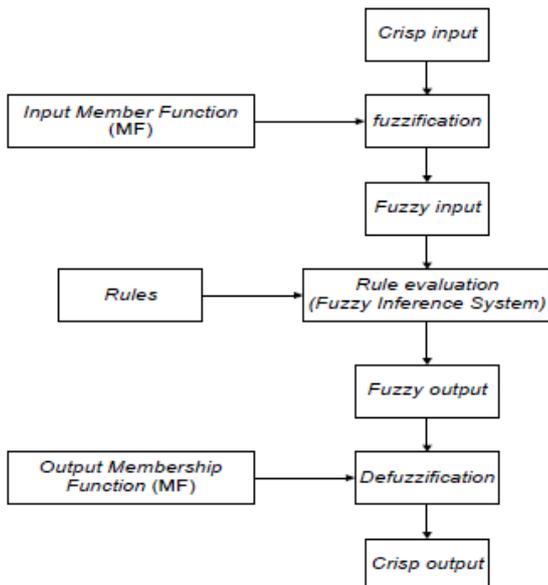
Masing-masing variabel indikator merupakan variabel yang dimasukkan datanya ke dalam *measurement model*, oleh karena itu variabel indikator ini haruslah jelas dan dapat diukur.

Penjelasan terkait definisi masing-masing variabel diuraikan sebagai berikut:

1. TSS
Total Suspended Solids atau padatan tersuspensi adalah padatan yang menyebabkan kekeruhan air, tidak terlarut, dan tidak dapat mengendap langsung. Padatan tersuspensi terdiri dari partikel-partikel yang ukuran maupun beratnya lebih kecil daripada sedimen, misalnya tanah liat, bahan-bahan organik tertentu, sel-sel mikroorganisme, dsb.
2. pH
Nilai pH air yang normal antara 6 – 8, sedangkan pH air terpolusi misalnya air buangan, berbeda-beda tergantung dari jenis buangannya.
3. Temperatur
Kenaikan suhu menimbulkan beberapa akibat antara lain menurunnya jumlah oksigen terlarut dalam air, meningkatkan kecepatan reaksi kimia serta terganggunya kehidupan ikan dan hewan air lainnya. Jika batas suhu yang mematikan terlampaui, ikan dan hewan air lainnya mungkin akan mati.
4. COD
Chemical Oxygen Demand atau kebutuhan oksigen kimia adalah jumlah oksigen yang diperlukan agar bahan buangan yang ada di dalam air dapat teroksidasi melalui reaksi kimia.

Langkah Pemodelan Fuzzy

Untuk melakukan proses *fuzzy*, dapat mengikuti langkah-langkah mulai dari *input* yang berbentuk *crisp* dirubah menjadi *input* yang berupa *fuzzy* untuk kemudian dimasukkan kedalam aturan-aturan yang telah dibuat untuk menghasilkan *output* yang diinginkan tetapi masih dalam bentuk *fuzzy output* yang harus dimasukkan dalam proses *defuzzifikasi* untuk dirubah ke dalam bentuk *crisp output*. Diagram pemodelan *fuzzy* seperti yang terlihat pada Gambar 3.2.



Gambar 3.2 Diagram Pemodelan Fuzzy

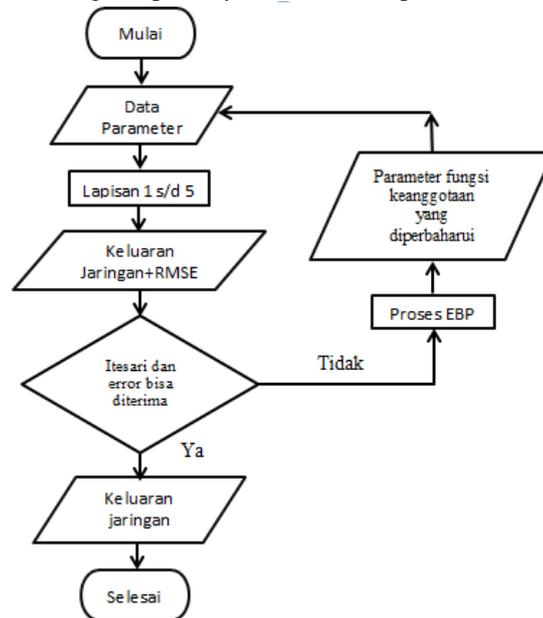
Alur Proses Pembelajaran

Di dalam alur proses pembelajaran terdapat proses alur maju yang terdiri dari lapisan 1 sampai

dengan lapisan 5. Alur proses pembelajaran dapat dilihat pada gambar 3.3.

Proses Alur Pembelajaran seperti pada Gambar 3.3 terdiri dari lapisan 1 sampai dengan lapisan 5. Lapisan 1 terdapat proses fuzzyfikasi, yaitu mengubah masukan nilai crisp (nilai aktual) menjadi nilai fuzzy dengan menggunakan fungsi keanggotaan bell. Lapisan 2 penerapan logika fuzzy AND yaitu memilih node yang terkecil dari node yang masuk. Lapisan 3 bentuk normalisasi. Lapisan 4 defuzzyfikasi dengan menggunakan metode LSE. Lapisan terakhir tahap maju merupakan keluaran jaringan.

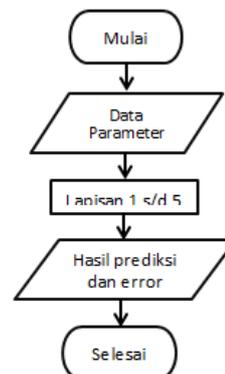
Jika parameter fungsi keanggotaan yang baru sudah diperoleh, maka iterasi dilanjutkan dengan proses maju seperti yang telah dijelaskan. Jika telah diperoleh keluaran jaringan maka sinyal kesalahannya diperiksa lagi. Selanjutnya sinyal kesalahan ini dipropagasi balik sampai lapisan ke-1 untuk diperoleh lagi parameter keanggotaan yang baru. Demikian seterusnya, proses ini berulang sampai sinyal kesalahan dapat diterima



Gambar 3.3 Alur Pembelajaran

Alur Proses Uji Coba

Pada alur proses uji coba hanya terdapat proses maju (lapisan 1 sampai dengan lapisan 5) tetapi parameter premis yang digunakan adalah parameter premis hasil belajar.



Gambar 3.4 Alur Uji Coba

IV. HASIL DAN PEMBAHASAN

Variabel

Variabel yang digunakan dalam penelitian ini adalah variabel TSS, pH, Temperatur dan COD. Dari variabel tersebut data yang digunakan sebagai inputan adalah variabel TSS, pH, Temperatur sedangkan untuk outputnya adalah variabel COD.

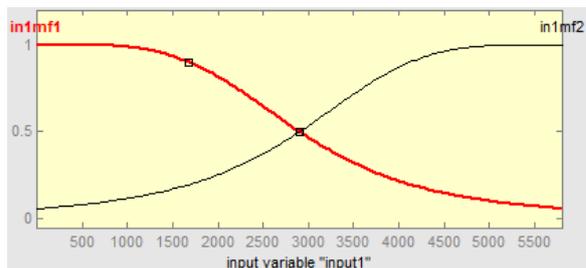
Data sebagai masukan adalah data input dan target sekaligus yang berupa matrik. Kolom pertama, kedua dan ketiga dalam hal ini adalah TSS, pH, Temperatur dan kolom keempat sebagai target, jumlah baris menyatakan jumlah data yang akan dilatih.

Tabel 4.1 Pembagian variabel *Input* dan Target

Input			Target
X ₁	X ₂	X ₃	Y(t)
TSS	pH	Temperatur	COD

Fungsi Keanggotaan Input

Setelah ditentukan variabel *input* yang akan menghasilkan *output* yang diinginkan maka akan dibuat fungsi keanggotaan dari variabel tersebut. Sebelumnya harus ditentukan tipe dari *Fuzzy Inference System*. Model Sugeno digunakan untuk membangun pendekatan sistematis untuk meng-*generate* aturan *fuzzy* dari dataset *input* – *output* yang diberikan.



Gambar 4.1 Fungsi Keanggotaan Variabel TSS

Bell ($x; a, b, c$)

dengan :

$x = \text{input (TSS)}$

$a = \text{lebar MF}$

$b = \text{pengendalian slopes untuk titik crossover}$

$c = \text{pusat MF}$

Persamaan fungsi keanggotaannya adalah :

TSS

in1mf1: gbellmf,[2897.20000482059
2.00858394292998 5.60001562077578]

in1mf2: gbellmf,[2897.20003826425
1.95538943714666 5799.99998572413]

pH

in2mf1: gbellmf,[0.659115653107299
2.03125038410258 6.82807698118502]

in2mf2: gbellmf,[0.501192370120729
2.04366228214328 8.37323957184075]

TEMPERATUR

in3mf1: gbellmf,[126.400000286857
1.99998726822089 27.2000000998964]

in3mf2: gbellmf,[126.400271067972
1.99397666886392 279.999817916577]

{ a_i, b_i dan c_i } adalah parameter dari fungsi keanggotaan atau disebut sebagai parameter premis.

Untuk mendapatkan hasil yang terbaik maka dilakukan 10 kali uji coba dengan perubahan dari fungsi keanggotaan yang digunakan, dari hasil uji coba tersebut diambil nilai *training* dan *testing* terkecil dari RMSE, MAE dan persentase tingkat keberhasilan terbesar. Setiap perubahan membership fungsi maka nilai dari RMSE, MAE dan % juga berbeda ini menandakan bahwa semakin besar *membership* fungsinya belum tentu mendapatkan hasil yang terbaik.

Hasil

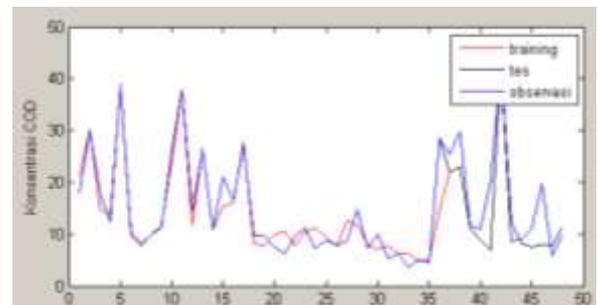
Hasil dari tingkat keberhasilan dengan model ANFIS ini ditentukan oleh data yang menjadi sumber pembelajaran. Hasil prediksi yang diperoleh merupakan hasil pembelajaran dari data yang sudah melalui proses pembelajaran terlebih dahulu. Dari proses pembelajaran tersebut tentunya memiliki tingkat kesalahan, maka berdasarkan variasi dari jumlah fungsi keanggotaan diambil nilai kesalahan terkecil dan persentase keberhasilan terbesar.

Dari hasil *training* dan *testing*, file terbaik disimpan dalam bentuk *.fis* yang berisi *engine fis*

Training		Testing	
RMSE	3.1208	RMSE	5.93532
MSE	0.38178	MSE	2.92794
MAE	1.90396	MAE	4.2165

Gambar 4.2 Error Training dan Testing

Gambar 4.2 menunjukkan hasil error dari training dan testing



Gambar 4.3 Grafik Hasil Training dan Testing

V. KESIMPULAN DAN SARAN

Kesimpulan

Kesimpulan yang dapat diambil dari penelitian ini adalah:

1. Hasil dari model ANFIS dalam proses pembelajaran ANFIS secara keseluruhan di setiap lokasi pemantauan didapat bahwa: MF 7, RMSE training 2,11993, RMSE testing 5,93532, MAE training 1,52225, MAE testing 4,2165 dengan persentase keberhasilan untuk training 94,7695 % dan testing 68,1839 %.
2. Dari hasil pembentukan model dapat diterapkan untuk prediksi COD dengan menggunakan variabel TSS, pH dan temperatur.

Saran

Berdasarkan penelitian ini, saran untuk penelitian berikutnya adalah:

1. Model estimasi menggunakan ANFIS ini bisa dikembangkan lagi dengan menggunakan algoritma selain ANFIS
2. Untuk penelitian selanjutnya, supaya membuat software aplikasi yang bisa diakses langsung oleh masyarakat sehingga jika masyarakat mengetahuinya diharapkan kesadaran terhadap lingkungan bisa meningkat.

DAFTAR PUSTAKA

- [1] Agus (2009), *Belajar Cepat Fuzzy Logic Menggunakan MATLAB*, Andi Offset, Yogyakarta.
- [2] Alaerts, G dan Santika,S.S, (1997), “ *Metode Penelitian Air*”, Usaha Nasional, Surabaya.
- [3] Anonim. (2001), Peraturan Pemerintah Republik Indonesia Nomor 82 Tahun 2001 tentang Kualitas dan Pengendalian Pencemaran Air.
- [4] Anonim. (2009), Undang-Undang Republik Indonesia Nomor 32 Tahun 2009 tentang Perlindungan dan Pengelolaan Lingkungan Hidup.
- [5] Anonim. (2010), Peraturan Menteri Negara Lingkungan Hidup Nomor 01 Tahun 2010 Tentang Tata Laksana Pengendalian Pencemaran Air.
- [6] Anonim. (2010), Peraturan Gubernur Jawa Timur Nomor 61 Tahun 2010 tentang Penetapan Kelas Air Pada Air Sungai.
- [7] Anonim, (2012), “*Daya Dukung dan Daya Tampung Lingkungan di Sungai Kali Mas*”. Laporan Penelitian Badan Lingkungan Hidup Surabaya 2011
- [8] Arifin Z. dan M.I. Irawan, (2009), “Adaptive Sensitivity Sensitivity-based Linear Learning Method Algorithms for Data Classification”, *Proceeding of 5th International Conference of Mathematics, Statistics and Their Applications*, Bukit Tinggi – West Sumatra Indonesia.
- [9] Bramer, Max, (2007), “ *Principles of Data Mining* “, Springer-Verlag, London.
- [10] Barba-Brioso C., Fernández-Caliani J.C., Miras A. , Cornejo J. , Galán E, (2010), “Multi-source water pollution in a highly anthropized wetland system associated with the estuary of Huelva (SW Spain)”, *Elsevier Journal of Marine Pollution Bulletin*.
- [11] Bao L.J., Maruya K A, Snyder S.A., and E Y. Zeng, (2011), “China’s water pollution by persistent organic pollutants,” *Elsevier Journal of Environmental Pollution*.
- [12] Effendi, H. (2003), *Telaah Kualitas Air Bagi Pengelolaan Sumber Daya dan Lingkungan Perairan*”, Penerbit Kanisius, Yogyakarta.
- [13] Fausett, L, (1995), *Fundamental of Neural Networks: Architecture, Algorithms, and Applications*, Prentice Hall New Jersey
- [14] Hanselman, Duane and Bruce Littlefield, (2001), *Matlab-Bahasa Komputasi Teknis, Komputasi, Visualisasi dan Pemrograman (Terjemahan)*, Andi Offset, Yogyakarta,
- [15] Hasanuddin dan M.I. Irawan, (2009), “Sensitivity Analysis of Probabilistic Radial Basis Function Networks”, *Proceeding of 5th International Conference on Mathematics, Statistics and Their Applications*, Bukit Tinggi – West Sumatra Indonesia.
- [16] Haykin, Simon,(1999), *Neural Networks: A Comprehensive Foundation*, Prentice Hall, New Jersey.
- [17] Hazlina, (2013), *An Exploration of the Adaptive Neuro-Fuzzy Inference System (ANFIS) in Modelling Survival*, Thesis submitted to The University of Nottingham, Nottingham.
- [18] Irawan M.I., Syaharuddin, M., Daryono Budi Utomo, dan A. Mustikarukmi, (2013), “Intelligent Irrigation Water Requirement System Based On Artificial Neural Networks and Profit Optimization for Planting Time Decision Making of Crops In Lombok Island” *Journal of Applied and Theoretical Information Technology*, Volume 58 No.3 December 31, 2013
- [19] Irawan M.I. dan E. Satriyanto, (2008), “Virtual Pointer untuk Identifikasi Isyarat Tangan sebagai Pengendali Gerakan Robot Secara Real-Time, *Jurnal Informatika* Vol.9 No. 1 Mei 2008
- [20] Irawan, M.I. dan A.B. Pratiwi, (2011), “A RBF- Egarch Neural Networks Model for Time Series Forecasting”, *Proceeding of The International Conference on Numerical Analysis and Optimization (ICeMATH - 2011)*, Yogyakarta
- [21] Irawan, M. I, (2010), “Pembangunan Metode Pembelajaran Cepat Pada Jaringan Syaraf Tiruan untuk Optimasi Waktu Dalam Stabilitas Bobot dan Minimalisasi Kesalahan Dalam Pengenalan Pola”, *Laporan Hasil Penelitian Hibah Pascasarjana – LPPM ITS*.
- [22] Irawan, M.I, Apiliani, E dan Z. Darojah, (2008), “Using An Extended and Ensemble Kalman Filter For The Training of Feedforward Neural Network In Time Series Forecasting”, *in Proceeding of 3rd- International Conference On Mathematics And Statistics (ICoMS 3)*, Bogor, Juli 2-4.
- [23] Jong, JS., *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*, Andi Offset, Yogyakarta.
- [24] JSR jang, CT Sun, E Mizutami, (1997), *Neuro Fuzzy and Soft Computing*, PTR Prentice Hall
- [25] Keputusan Menteri Negara Lingkungan Hidup Nomor 112 Tahun 2013 tentang Baku Mutu Air Limbah Domestik.
- [26] Kusumadewi, S. (2001), *Artificial Intelligence (Teknik dan Aplikasinya)*, Graha Ilmu, Yogyakarta.
- [27] Kusumadewi, S. (2004), *Membangun Jaringan Syaraf Tiruan menggunakan Matlab dan Excel Link*, Graha Ilmu, Yogyakarta.
- [28] Li, C and Diebold, F.X, (2006),” Forecasting the Term Structure of Government Bond Yield”, *Journal of Econometrics*,130,337-364.
- [29] Masduqi, A dan E. Apriliani, (2008), “Estimation of Surabaya River Water Quality Using Kalman Filter Algorithm”, *IPTEK, The Journal for Technology and Science, Vol. 19, No. 3, August 2008*
- [30] Masduqi A, (2012), *Operasi dan Proses Pengolahan Air*, ITS Press
- [31] Murat Ay, Ozgur Kisi (2014), “Modelling of chemical oxygen demand by using ANNs, ANFIS and k-means clustering techniques”, *Journal of Hydrolog*, 511 (2014) 279–289
- [32] Nastos, P.T., Moustiris, K.P., Larissi, I.K., Paliatsos, A.G. (2011), “Rain Intensity Forecast Using Artificial Neural Network in Athens, Greece”, *Atmospheric Research*, Vol 119, Hal. 153 - 160.