

PENENTUAN KUALITAS AIR SUNGAI MENGGUNAKAN METODE *EXTREME LEARNING MACHINE*

Alvia Nur Azizah¹, Imam Cholissodin², Edy Santoso³

^{1,2,3}Informatika / Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Brawijaya

Jl. Veteran No.8 Malang, Informatika, Gedung A PTIHK – UB

Email: ¹alvia.nura@gmail.com, ²imamcs@ub.ac.id, ³edy144@ub.ac.id

Abstrak

Air merupakan salah satu sumber daya alam yang memiliki fungsi sangat penting bagi kehidupan dan perikehidupan manusia. Sungai sebagai saluran utama pengalir air dari hulu ke hilir, memiliki banyak aktivitas domestik dan industri di sepanjang alirannya. Dinamika aliran tersebut menimbulkan perubahan kualitas dan kuantitas sungai secara signifikan. Kualitas air dijaga dengan melakukan analisis kualitas air sungai. Penggunaan sistem cerdas dirancang untuk mempermudah penentuan kualitas air secara komputasi. Input yang dibutuhkan adalah parameter uji kualitas air yang terdiri dari parameter fisika dan parameter kimia. Proses analisa kualitas air oleh sistem dilakukan dengan *metode extreme learning machine* (ELM). Implementasi metode ELM tidak memiliki acuan perhitungan terhadap aturan maupun ketentuan yang ada pada metode STORET melainkan membandingkan hasil penentuan keduanya, sehingga apabila dalam waktu tertentu terjadi perubahan perhitungan maupun ketentuan pada metode STORET tidak mempengaruhi perhitungan yang ada pada metode ELM. Metode ELM digunakan untuk menentukan kualitas air sungai kedalam 4 (empat) kelas yaitu memenuhi baku mutu (kondisi baik), tercemar ringan, tercemar sedang, dan tercemar berat. Hasil dari skenario pengujian didapatkan tingkat akurasi antara hasil perhitungan metode ELM dengan hasil diagnosa pakar menggunakan metode STORET sebesar 87,97%.

Kata kunci: *kualitas air sungai, ELM, metode STORET.*

Abstract

Water is a natural resource that has a very important function for life and human life. Diverter river as the main channel of water from upstream to downstream, has a lot of domestic and industrial activity along the stream. The flow dynamics cause changes in the quality and quantity of the river significantly. Water quality is maintained by analyzing water quality. The use of intelligent systems designed to facilitate the determination of water quality computing. Input is needed is a parameter water quality test that consists of physical parameters and chemical parameters. Water quality analysis process by the system is done by the method of extreme learning machine (ELM). ELM method implementations do not have a reference to the calculation of the rules and conditions contained in STORET methods but rather compare the results of the determination of both, so if within a certain time there is a change in the method of calculation as well as the provisions do not affect the calculation STORET that of the method of ELM. ELM method used to determine the quality of river water into the 4 (four) classes which meet quality standards (good condition), lightly polluted, medium polluted and heavily polluted. The results of the testing scenarios between the results obtained accuracy rate calculation method of ELM with expert diagnosis using methods STORET of 87.97%.

Keywords: *quality of water, ELM, STORET method.*

1. PENDAHULUAN

Sungai merupakan salah satu sumber daya alam yang mencukupi hajat orang banyak. Sungai juga menjadi sumber kebutuhan bagi manusia menjalankan aktifitas sehari – hari, seperti mengairi sawah, menggerakkan generator bagi perusahaan listrik, dan sebagai kebutuhan rumah tangga bagi masyarakat yang menggantungkan kebutuhan air pada sungai. Air sungai tidak lepas dari pencemaran yang merupakan hasil dari aktivitas industri – industri rumah tangga maupun industri besar.

Salah satu contoh waduk sutami merupakan waduk terbesar di Jawa Timur yang terletak di Desa

Karangates, Kecamatan Sumber Pucung, Kabupaten Malang. Waduk ini dibuat untuk menampung air untuk irigasi daerah hilir saat kemarau hingga mencapai 24 m per detik. Selain itu, Waduk ini memberikan pasokan ke sawah mencapai 34.000 hektar. Volume air yang bias ditampung Waduk ini mencapai 343.000.000 m³ (Juantari, 2013).

Keberadaan lahan pemukiman di Daerah Aliran Sungai (DAS) mengakibatkan berbagai macam masalah, mulai dari terjadinya banjir, berkurangnya ketersediaan air yang diakibatkan semakin sempitnya lebar sungai hingga terjadinya pencemaran air yang mengakibatkan penurunan kualitas air sungai, dimana sebagian besar air sungai

digunakan untuk menopang kehidupan masyarakat sekitar Daerah Aliran Sungai. Pencemaran sungai dari adanya permukiman dapat berasal dari buangan air rumah tangga, padatan berupa sampah yang dibuang ke sungai, air cucian kamar mandi, buangan tinja. Untuk menjaga kualitas air agar tetap pada kondisi alamiahnya, perlu dilakukan pengelolaan dan pengendalian pencemaran air secara bijaksana. Hal ini dibutuhkan upaya pemantauan dan pengendalian pencemaran terhadap air sungai. Upaya yang dilakukan yaitu melakukan pengukuran dan analisis terhadap air sungai tentang status mutu air sebagaimana yang ditetapkan dalam Peraturan Pemerintah no 82 tahun 2001. Kementerian Lingkungan Hidup mengeluarkan keputusan Nomor: 115 Tahun 2003 tentang penentuan mutu air dengan Metode STORET atau Metode Indeks Pencemaran. Penentuan kualitas air sungai dengan Metode STORET masih dilakukan secara manual dengan cara menghitung satu-persatu data parameter pengujian sehingga membutuhkan waktu yang lama dan biaya pengujian yang besar. Oleh sebab itu, penulis mengajukan sebuah penelitian menggunakan metode *Extreme Learning Machine* (ELM) untuk memudahkan perhitungan. Penerapan algoritma ELM, dapat memberikan solusi bagi pengguna dalam membantu proses terkait dengan penentuan kualitas air sungai.

Beberapa penelitian sebelumnya yang berkaitan dengan penentuan status mutu air telah dilakukan oleh Annisah (2011). Pada penelitian tersebut Annisah meneliti status mutu air sungai di waduk sutami dengan metode STORET menggunakan 9 (sembilan) parameter yang terdiri dari BOD, COD, DO, TSS, pH, Amonia (NH₃_N), fenol, minyak dan lemak, dan sianida (CN). Hasil dari penelitian tersebut, status mutu air dibagi menjadi 4 (empat) kriteria yaitu memenuhi baku mutu (kondisi baik), tercemar ringan, tercemar sedang, dan tercemar berat (Annisah, 2011).

ELM juga diterapkan dalam bidang manajemen rumah sakit seperti yang dilakukan oleh Fardani (2015). Dalam penelitiannya Fardani menerapkan metode ELM kedalam sistem pendukung keputusan dalam menentukan jumlah pasien yang berkunjung di rumah sakit. Dalam industri, ELM bisa digunakan dalam meramalkan permintaan seperti yang dilakukan oleh Agustina (2014). Dalam penelitiannya, Agustina membandingkan hasil penerapan ELM dengan metode JST lainnya diperoleh peningkatan yang signifikan pada bagian training speed data. Penelitian terkait juga dilakukan Atmojo (2013) tentang model peramalan permintaan kebutuhan penjualan.

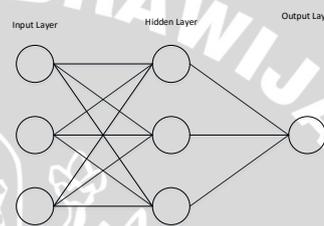
2. EXTREME LEARNING MACHINE

ELM merupakan salah satu metode baru dari segi pembelajaran yang ada pada jaringan saraf tiruan. Metode ini pertama kali diperkenalkan oleh

Huang dkk (2004). Metode pembelajaran ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*.

Menurut Huang dkk (2004), JST *feedforward* masih memiliki kelemahan dalam *learning speed* karena semua parameter pada jaringan ditentukan secara iterative dengan menggunakan metode pembelajaran tersebut.

Pada proses *learning* JST semua parameter harus ditentukan secara manual (Huang dkk ,2005). Parameter yang dimaksud adalah *input weight* dan *bias* yang menghubungkan *layer* satu dengan yang lain sehingga membutuhkan *learning speed* yang lama. Hal itu menjadikan ELM seribu kali lebih cepat dari algoritma JST. Gambar 1 adalah struktur ELM.



Gambar 1. Struktur ELM

Struktur ELM terdiri dari 3 layer, yaitu *input layer*, *hidden layer*, dan *output layer*. Setiap *node* pada *input layer* terhubung dengan *hidden node* yang ada pada *hidden layer*. *Node* tersebut dihubungkan oleh bobot yang disebut bobot *input* dengan nilai yang berbeda. Setiap *input node* terhubung ke semua *hidden node*. Setiap *node* pada *hidden layer* terhubung dengan *output layer* yang dihubungkan oleh bobot *output*. Semua *hidden node* terhubung ke satu *output*. Metode ELM mempunyai model matematis yang berbeda dari jaringan syaraf tiruan *feedforward*. Model matematis ELM lebih sederhana dan efektif. Berikut langkah – langkah algoritma ELM.

1. Menghitung keluaran *hidden layer*.

Pada proses ini, data sebanyak N berupa matriks $m \times n$ dikalikan dengan bobot awal dan hasilnya dijumlahkan dengan bias sehingga diperoleh matriks keluaran *hidden layer* dari Persamaan 3. Pada ELM bobot input dan hidden bias ditentukan secara acak. Untuk mendapatkan bobot awal dan bias berupa matriks diperoleh dari Persamaan 1 dan 2.

$$w = h * N \tag{1}$$

Keterangan:

w = ukuran bobot awal

h = jumlah *hidden node*

N = jumlah *input node*

$$b = h * 1 \tag{2}$$

Keterangan:

b = ukuran bias

h = jumlah *hidden node*

$$H = (N * w^T + b) \quad (3)$$

Keterangan:

H = matriks keluaran *hidden layer*

N = *input node*

w^T = matriks transpose bobot awal

b = ukuran bias

2. Aktivasi Hasil Keluaran *Hidden Layer*

Fungsi aktivasi digunakan untuk memetakan nilai dari matriks keluaran *hidden layer*. Fungsi aktivasi yang digunakan yaitu Sigmoid Biner. Fungsi sigmoid biner memiliki rentang nilai dari 0 sampai dengan 1. Rumus fungsi aktivasi Sigmoid Biner ditunjukkan pada Persamaan 4:

$$G(x) = \frac{1}{1+e^{-x}} \quad (4)$$

Keterangan:

G(x) = fungsi aktivasi sigmoid biner

e^{-x} = eksponensial pangkat minus data ke-x

3. Menghitung Matriks *Moore-Penrose Pseudo Inverse*

Penggunaan umum dari *pseudo inverse* adalah untuk menghitung solusi untuk sistem persamaan linear yang tidak memiliki solusi yang unik. Persamaan untuk mencari matriks *moore-penrose* ditunjukkan pada Persamaan 5.

$$H^+ = (H^T H)^{-1} H^T \quad (5)$$

Keterangan:

H^+ = matriks *moore-penrose pseudo inverse*

H^T = matriks H transpose

H = matriks H keluaran *hidden layer*

4. Hitung Bobot Output

Bobot output menghubungkan *hidden layer* dengan output layer untuk menghitung hasil keluaran. Persamaan untuk memperoleh bobot output ditunjukkan pada Persamaan 6.

$$\beta = H^+ T \quad (6)$$

Keterangan:

β = bobot output

H^+ = matriks *moore-penrose pseudo inverse*

T = matriks target

5. Hitung Output

Hasil keluaran ELM diperoleh dari proses perhitungan dari *hidden layer* dengan bobot output yang menghubungkan keduanya. Persamaan menghitung keluaran ditunjukkan pada Persamaan 7.

$$O = H\beta \quad (7)$$

Keterangan:

O = keluaran

β = bobot output

H = matriks H keluaran *hidden layer*

6. Nilai Evaluasi

Evaluasi dilakukan untuk mencari nilai akurasi yang paling baik. Pengukuran tingkat akurasi dilakukan untuk menentukan efisiensi dan ketepatan dari sebuah metode. Berikut ini merupakan Persamaan 8 untuk menghitung nilai akurasi dari algoritma ELM.

$$\text{Akurasi} = \frac{N-m}{N} \% \quad (8)$$

Keterangan:

N = Jumlah data keseluruhan

m = data yang tidak sama

3. METODOLOGI

Penelitian ini menggunakan metode *extreme learning machine* dalam menentukan kualitas air sungai. Tahapan-tahapan penelitian yang dilakukan adalah sebagai berikut:

3.1. Studi Literatur

Studi literatur dilakukan dengan tujuan untuk mempelajari dasar teori dan sumber acuan tentang air sungai, metode STORET, jaringan saraf tiruan, dan metode *extreme learning machine*.

3.2. Pengumpulan Data

Pengumpulan data diperoleh dari hasil diagnosa pakar, yaitu Dosen Pengairan, Jurusan Pengairan, Fakultas Teknik, Universitas Brawijaya, Malang. Jumlah data sebanyak 150 data yang terdiri dari 3 kelas dengan masing – masing kelas terdapat 50 data.

3.3 Algoritma Yang Digunakan

Proses penentuan air sungai menggunakan algoritma *extreme learning machine* (ELM), selanjutnya hasil dari perhitungan akan dicari nilai akurasi yang paling baik. Penggunaan algoritma ELM pada penelitian ini difokuskan pada *learning speed* dan bobot input (w) secara *random* tanpa manual satu persatu sehingga waktu komputasi semakin cepat dan proses komputasi tidak menghabiskan slot memori begitu besar.

3.4 Analisis Kebutuhan

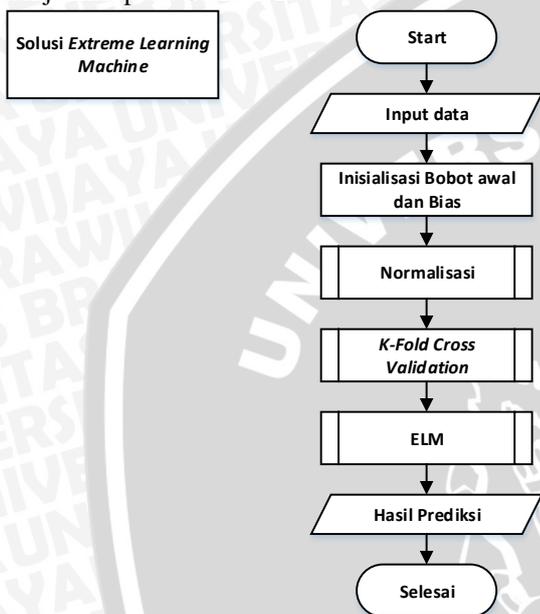
Analisis kebutuhan bertujuan untuk mendapatkan semua kebutuhan yang diperlukan dari sistem yang akan dibangun.

3.5 Perancangan Sistem

Perancangan sistem dibangun berdasarkan hasil pengambilan data dan analisis kebutuhan yang telah dilakukan. Sistem penentuan kualitas air sungai ini memiliki inputan berupa parameter status mutu air sungai yang terdiri dari TSS, BOD, COD, DO, pH, fenol, serta minyak dan lemak. Pada proses

perhitungan ELM terdapat 3 (tiga) tahapan yaitu: (1) Normalisasi; (2) Pembagian data *training* dan data *testing* menggunakan metode *k-fold cross validation*; (3) perhitungan algoritma ELM. Keluaran dari perhitungan metode ini adalah menghasilkan nilai kualitas air sungai. *Output* dari sistem ini adalah status mutu air sungai yang terdiri dari 4 (empat) kelas yang terdiri dari memenuhi baku mutu, tercemar ringan, tercemar sedang, dan atau tercemar berat.

Diagram alir penentuan kualitas air sungai menggunakan metode *extreme learning machine* ditunjukkan pada Gambar 2.



Gambar 2. Siklus Penyelesaian ELM

4. IMPLEMENTASI

Sistem akan melakukan perhitungan menggunakan metode ELM. Berikut ini merupakan langkah-langkah perhitungan yang dilakukan oleh sistem:

(1) Normalisasi Data

Proses normalisasi menggunakan metode *Min-Max*. Langkah pertama mencari nilai minimum dan maksimum dari setiap parameter. Tabel 1 merupakan contoh hasil pencarian nilai maksimal dan minimal dari setiap parameter dari data inputan pengguna. Keunggulan *Min-Max* perbandingan nilai antara sebelum dan sesudah proses normalisasi seimbang. Fungsi normalisasi dapat dituliskan pada Persamaan 9 sebagai berikut (Santosh dkk, 2014).

Tabel 1. Nilai Maksimum Dan Minimum

	TSS	BOD	COD	DO	pH	Fenol	Minyak & Lemak
Max	229.8	21.3	97.5	42.25	9	0.3825	6.85
Min	0	1.925	6.408	3.5	6.55	0	0

$$x = \frac{(data_{awal} - data_{min})}{(data_{max} - data_{min})} \quad (9)$$

Keterangan:

x = data normalisasi

data_awal = data inputan

data_min = nilai *minimal* dari data inputan

data_max = nilai *maksimal* dari data inputan

(2) K-Fold Cross Validation

Metode KCV membagi data set sebanyak variabel nilai k dan dilakukan iterasi sebanyak nilai k. Pada penelitian yang dilakukan Anguita dkk (2009) yaitu semua data digunakan sebagai data *training* dan salah satu sebagiannya sebagai data *testing* secara bergantian. Pengambilan data diletakkan pada masing – masing *fold* dimana data yang sudah diambil tidak boleh diletakkan pada *fold* yang lainnya. Pengambilan untuk masing – masing dari setiap kelas dapat menggunakan Persamaan 10.

$$X = \frac{100}{k} \% \quad (10)$$

Keterangan:

x = persentase pembagian

k = jumlah *fold*

Langkah – langkah pembagian data menggunakan KCV yaitu: (1) Inisialisasi nilai k. Pada contoh menggunakan nilai k=3 yang berarti terdapat 3 *fold* yaitu *fold-1*, *fold-2*, dan *fold-3*; (2) hitung banyaknya data dari setiap kelas yang diambil menggunakan Persamaan 9. Untuk sisa data akan diletakkan pada *fold* terakhir.

(3) Solusi ELM

Proses perhitungan ELM terdiri dari proses *training*, *testing* dan evaluasi penentuan.

a) Proses Training

Langkah 1: Inisialisasi bobot awal dan bias menggunakan Persamaan 1 dan 2. Bobot awal dan bias diambil secara acak dengan rentang nilai 0 sampai 1. Misal jumlah *hidden layer* = 2. Maka, hasil bobot awal ditunjukkan pada Tabel 2 dan nilai bias ditunjukkan pada Tabel 3.

Tabel 2. Nilai Bobot Awal

w	1	2	3	4	5	6	7
1	0.56	0.51	0.53	0.76	0.51	0.77	0.58
2	0.16	0.26	0.16	0.63	0.81	0.92	0.55

Tabel 3. Nilai Bias

b	1
1	0.352154
2	0.798536

Langkah 2: menghitung keluaran setiap *hidden node* dan hasil perhitungannya akan dipetakan menggunakan fungsi aktivasi *sigmoid biner*. Berikut contoh menghitung matriks keluaran *hidden layer* menggunakan data 1.

$$H_{(1,1)} = [(0.146214 * 0.554463) + (0.029677 * 0.512528) + (0.025809 * 0.524558) + (0.068387 * 0.756425) + (0.408263 * 0.513373) + (0.101961 * 0.768145) + (0.056934 * 0.578257)] + 0.352154 = 1.41756$$

Aktivasi keluaran *hidden layer* menggunakan fungsi *sigmoid biner*. Berikut contoh data 1 yang di aktivasi

$$H(x)_{(1,1)} = \frac{1}{1+e^{-0.834487}} = 0.697303$$

Langkah 3: Menghitung matriks *moore-penrose pseudo inverse*. Contoh perhitungan dari manualisasi program untuk mencari matriks *moore-penrose* menggunakan Persamaan 5.

$$H(x)^T H(x) = (0.697302765 * 0.697302765) + (0.769965147 * 0.769965147) + \dots + (\dots_{(n)} * \dots_{(n)}) = 23.68653061$$

Langkah 4: Hitung bobot *output* menggunakan Persamaan 6. Bobot *output* digunakan dalam proses testing untuk menentukan hasil keluaran. Dalam menghitung bobot *output* mengalikan matriks *moore-penrose pseudo inverse* dengan matriks target. Berikut ini contoh perhitungannya.

$$\beta_1 = (-1.45802338 * 1) + (-0.759597732 * 1) + \dots + (\dots_{(n)} * \dots_{(n)}) = 8.79524042$$

Hasil keluaran dari proses *training* berupa bobot *output* yang masuk pada proses *testing* digunakan untuk menghitung keluaran.

b) Proses *Testing*

Menghitung fungsi keluaran menggunakan data *testing* dengan langkah yang sama seperti proses *training* pada Langkah 1 sampai 2. Tujuan proses ini menghasilkan keluaran. berikut contoh perhitungannya.

$$T_1 = (0.730799 * 8.79524042) + (0.823931 * -5.638528651) + \dots + (\dots_{(n)} * \dots_{(n)}) = 1.781788$$

Hasil keluaran diteruskan untuk dievaluasi sehingga diperoleh nilai akurasi.

c) Proses Evaluasi Penentuan

Hasil keluaran proses testing akan dihitung nilai selisih dari masing – masing Kelas pengelompokan, kemudian didapatkan nilai minimum dari ketiga kelas tersebut. Nilai

minimum akan dikonversi kedalam Kelas dengan mencocokkan setiap nilai minimum dengan setiap nilai selisih. Berikut contoh hasil akurasi dari langkah – langkah implementasi ELM.

$$Akurasi = \frac{22-4}{22} \times 100\% = 81.818\%$$

Hasil yang ditunjukkan diatas merupakan contoh perhitungan menggunakan data *training fold-1* dan *fold-2* sebagai dan data testing pada *fold-3*. Tingkat akurasi yang dicapai adalah 81.818 %.

5. PENGUJIAN DAN PEMBAHASAN

Pada tahap ini menjelaskan hasil pengujian dan pembahasan dari penentuan kualitas air sungai menggunakan *extreme learning machine*. Pengujian yang dilakukan meliputi: pengujian nilai *k*, dan pengujian jumlah *hidden node*.

5.1 Pengujian Nilai *k*

Pada pengujian nilai *k*, pengambilan data untuk setiap *fold* dilakukan secara *random*. Hal ini akan menimbulkan nilai akurasi yang berubah – ubah setiap dilakukan pengambilan. Maka dari itu, untuk memperoleh akurasi yang baik dilakukan percobaan pengambilan data sebanyak 10 kali untuk setiap nilai *k* dan diambil nilai terbaik dengan akurasi yang paling tinggi. Pengujian nilai *k* dilakukan antara 2 sampai 5 dengan jumlah data sebanyak 150. Berikut grafik hasil pengujian nilai *k* ditunjukkan pada Gambar 2.



Gambar 2. Grafik Hasil Pengujian Nilai *k*

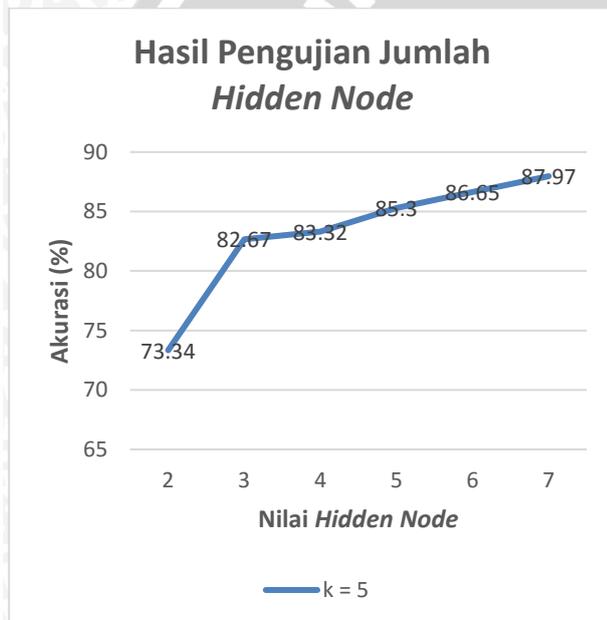
Berdasarkan grafik hasil pengujian nilai *k* pada Gambar 2 diperoleh nilai akurasi terbaik 86% pada nilai *k* = 5. Nilai *k* semakin tinggi, semakin banyak pula *fold* yang dibentuk dan semakin kecil pula persentase pengambilan datanya. Semakin besar nilai *k*, variasi dari estimasi data dalam setiap *fold* yang dihasilkan berkurang karena nilai *k* semakin



besar. Kondisi ini memungkinkan data *testing* yang digunakan semakin sedikit jumlahnya dibandingkan data *training*, sehingga akurasi yang diperoleh semakin baik. Selain itu, nilai k juga menentukan banyaknya iterasi dalam percobaan yang nantinya diperoleh rata – rata akurasi sehingga nilai k yang besar memiliki banyak percobaan dengan akurasi disetiap percobaannya.

5.2 Pengujian Jumlah *Hidden Node*

Pada proses *training*, *hidden node* digunakan untuk pembentukan bobot *input* dan bias. Pada pengujian jumlah *hidden node* data *training* dan data *testing* yang digunakan diambil dari hasil pengujian nilai k terbaik pada pengujian sebelumnya, yaitu 5. Pembentukan bobot *input* dan bias dilakukan sebanyak 10 kali percobaan untuk setiap nilai *hidden node* dan diambil nilai akurasi terbaik. Berikut grafik hasil pengujian jumlah *hidden node* ditunjukkan pada Gambar 3.



Gambar 3. Grafik Hasil Pengujian Jumlah *Hidden Node*

Berdasarkan grafik hasil pengujian jumlah *hidden node* pada Gambar 3 diperoleh nilai akurasi terbaik 87.97% pada jumlah *hidden node* sebanyak 7. Semakin besar jumlah *hidden node*-nya, maka nilai akurasi yang diperoleh semakin tinggi. Nilai *hidden node* yang besar akan membentuk banyak penghubung (*connector*) dengan *input layer* dan *output layer*. Kondisi ini memungkinkan unit pemroses pada sistem yang melakukan proses pembobotan untuk mengenali data memiliki kemampuan yang baik dengan semakin banyaknya pertimbangan keputusan yang dilakukan oleh *hidden node* untuk hasil yang lebih *detail*.

6. PEMBAHASAN HASIL PENGUJIAN

Penentuan kualitas air sungai menggunakan metode extreme learning machine dilakukan dengan menggunakan parameter dengan hasil yang optimum yang diperoleh melalui hasil skenario pengujian yaitu, nilai $k = 5$ dan jumlah *hidden node* = 7. Dengan menggunakan nilai dari parameter tersebut, sistem memperoleh solusi penyelesaian nilai akurasi yang optimum sebesar 87.97%.

Kondisi ini belum sesuai dengan hasil yang diperoleh menggunakan metode standar baku dari pemerintah. Hal ini dikarenakan oleh beberapa alasan. Pertama, metode STORET merupakan metode standar dari pemerintah yang melakukan perhitungan secara manual dengan pemberian skor dengan rentang nilai tertentu pada setiap nilai parameter air sesuai kebijakan pemerintah. Kedua, sistem menggunakan 7 parameter utama kimia-fisika yang paling berpengaruh, sedangkan pada metode STORET menggunakan beberapa parameter tambahan, sehingga hasil penentuannya kurang obyektif dengan metode STORET.

Terlepas dari paparan beberapa alasan diatas, sistem yang dibangun bertujuan sebatas memberikan rekomendasi penentuan kualitas air sungai berdasarkan pendekatan *extreme learning machine* yang dievaluasi dengan parameter yang menghasilkan nilai akurasi paling baik. Selanjutnya, dari hasil penentuan tersebut dapat dilakukan analisis lebih lanjut guna menemukan informasi tertentu sehingga dapat digunakan sebagai bahan pertimbangan dalam menentukan kualitas air sungai yang sesuai dengan kondisi air yang sebenarnya.

7. PENUTUP

7.1 Kesimpulan

Berdasarkan hasil pengujian dan pembahasan dari penentuan kualitas air sungai menggunakan metode extreme learning machine maka diperoleh kesimpulan sebagai berikut:

1. Algoritma extreme learning machine dapat digunakan dalam penentuan kualitas air sungai dilakukan dengan mendefinisikan jumlah *hidden node* sebagai unit yang melakukan perhitungan menghasilkan keluaran dan melakukan pembagian data *training* dan data *testing* yang ideal menggunakan metode *k-fold cross validation*. Hasil keluaran dari setiap *hidden node* berupa fungsi keluaran *hidden layer* dan parameter penghubung (β) yang akan

diteruskan ke *output layer*, dimana semua *hidden node* terhubung pada setiap *output node*. Pada tahap akhir dari *output layer* akan dilakukan evaluasi penentuan yang akan dihitung akurasi dengan acuan hasil diagnosa pakar menggunakan STORET.

2. Penambahan jumlah *hidden node* berpengaruh terhadap akurasi hasil penentuan kualitas air. Selain itu, dalam proses pembagian data *training* dan data *testing* menggunakan *k-fold cross validation* ditentukan berdasarkan nilai *k*. Hal ini akan berpengaruh terhadap banyaknya data yang digunakan untuk proses *training* dan *testing*. Berdasarkan hasil pengujian, nilai akurasi tertinggi diperoleh dengan nilai $k = 5$ dan jumlah *hidden node* = 7 mencapai 87.89%.

7.2 Saran

Penelitian tentang penentuan kualitas air sungai menggunakan metode *extreme learning machine* dapat dikembangkan dengan beberapa saran sebagai berikut:

1. Pada penelitian mendatang dilakukan penambahan seleksi fitur bertujuan untuk memilih fitur yang berpengaruh dari keseluruhan parameter air sungai, sehingga kondisi dimana fitur yang berpengaruh selain fitur utama (TSS, BOD, COD, DO, pH, Fenol, Minyak dan Lemak) digunakan dalam proses perhitungan.
2. Pada penelitian mendatang menggabungkan algoritma/metode lain dengan ELM seperti metode optimasi atau dengan metode kecerdasan buatan lainnya supaya didapatkan bobot awal yang optimal. Hal ini bertujuan agar hasil yang diperoleh lebih baik daripada penelitian sebelumnya.

DAFTAR PUSTAKA

- Agustiningtih, Dyah. 2014. Thesis: Analisis Kualitas Air Dan Strategi Pengendalian Pencemaran Air Sungai Blukar Kabupaten Kendal. Vol. 9 No.2 September 2012, ISSN 1907-187X.
- Anguita, Davide., Ghio, Alessandro., Ridella, Sandro., Sterpi Dario. 2009. K-Fold Cross Validation for Error Rate Estimate in Support Vector Machines. University of Genova, Italy.
- Cao, Jiuwen dan Xiong, Lianglin. 2014. Protein Sequence Classification with Improved Extreme Learning Machine Algorithms. China.
- Fardani, Delia Putri. 2015. Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus : Poli Gigi RSUD Dr. Wahidin Sudiro Husodo Mojokerto). Vol. 1, No. 1, April 2015. Universitas Airlangga.
- Juantari, Gilang Y. 2013. Status Trofik Dan Daya Tampung Beban Pencemaran Waduk Sutami. Vol 4. No 1 pp 61-66.
- Hermawan, A. 2006. Jaringan Saraf Tiruan Teori dan Aplikasi. Andi: Yogyakarta.
- Huang, G.B., Zhu, Q.Y., dan Siew, C.K. 2004. Extreme Learning Machine : A New Learning Scheme of Feedforward neural Networks. Proceeding of International Joint Conference on Neural Networks. Hungary, 25-29 Juli.
- Huang, G.B., Zhu, Q.Y., dan Siew, C.K. 2005. Extreme Learning Machine : Theory and applications. Elsevier science : Neurocomputing 70 (2006) 489-501.
- Keputusan Menteri Negara Lingkungan Hidup Nomor 115 Tahun 2003 tentang Pedoman Penentuan Status Mutu Air. Menteri Negara Lingkungan Hidup. Jakarta.
- Paramadyastha, Annisah. 2011. Studi Penentuan Status Mutu Air dengan Metode Storet dan Metode Indek Pencemaran di Waduk Sutami. Malang. Teknik Pengairan Universitas Brawijaya.
- Peraturan Pemerintah Nomor 38 Tahun 2011 tentang Sungai.
- Prastyo, DedyDwi., 2010. Peramalan Menggunakan Metode Ekspensial Smoothing, Jurusan Statistika Institut Teknologi Sepuluh November, Surabaya.
- Santosh, Kumar Sahu, Sauravranjan, Sarangi and Sanjaya, Kumar Jena, "A Detail Analysis on Intrusion Detection Datasets," in International Advance Computing Conference (IACC), 2014.
- Shamshirband, Shahaboddin., Mohammadi, Karsa., Tog, Chong Wen., Petkovic, Dalibor., Porcu, Emilio., Mostafaeipour, Ali., Ch, Sudheer., dan Sedaghat, Ahmat. 2015. Application of extreme learning machine for estimation of wind speed distribution. Springer-Verlag Berlin Heidelberg.
- Siang, J. (2005). Jaringan Saraf Tiruan & Pemrogramannya Menggunakan Matlab. Yogyakarta: Andi.
- Sun, Z.L., Choi, T.M., Au, K.F., dan Yu, Y. 2008. Sales Forecasting using Extreme Learning Machine with Application in

Fashion Retailing.Elsevier Decision Support Systems 46 (2008) 411-419.

Suriawiria, Unus. 2003. Air dalam Kehidupan dan Lingkungan yang Sehat. Penerbit Alumni. Bandung

Tafangenyasha, C. and T. Dzinomwa. 2005. Land-use Impacts on River Water Quality in Lowveld Sand River Systems in South-East Zimbabwe. Land Use and Water Resources Research 5: 3.1-3.10. <http://www.luwrr.com>

Wiwoho, 2005, Model Identifikasi Daya Tampung Beban Cemaran Sungai Dengan QUAL2E. Tesis. Universitas Diponegoro. Semarang

