



TESIS-TF185471

**OPTIMISASI *CHEMICAL OXYGEN DEMAND*  
*PRODUCED WATER* PADA *POLISHING UNIT***

DENI NUR FAUZI  
NRP. 02311850010002

DOSEN PEMBIMBING  
Totok R. Biyanto, Ph.D.

PROGRAM MAGISTER  
BIDANG KEAHLIAN REKAYASA INSTRUMENTASI INDUSTRI  
FAKULTAS TEKNOLOGI INDUSTRI DAN REKAYASA SISTEM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2021

*Halaman ini sengaja dikosongkan*



THESIS -TF185471

***OPTIMIZATION OF CHEMICAL OXYGEN DEMAND  
PRODUCED WATER AT POLISHING UNIT***

DENI NUR FAUZI  
NRP. 02311850010002

Supervisor  
Totok R. Biyanto, Ph.D.

MASTER PROGRAM  
INDUSTRIAL INSTRUMENTATION ENGINEERING  
ENGINEERING PHYSICS DEPARTMENT  
FACULTY OF INDUSTRIAL TECHNOLOGY AND SYSTEM ENGINEERING  
SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY  
SURABAYA  
2021

*Halaman ini sengaja dikosongkan*

# LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

**Magister Teknik ( MT )**

Di

**Institit Teknologi Sepuluh Nopember**

Oleh

**DENI NUR FAUZI**

**NRP. 02311850010002**

Tanggal Ujian : 23 Februari 2021

Periode Wisuda : April 2021

Disetujui oleh:

**Pembimbing:**

1. Totok R. Biyanto, Ph.D.  
NIP. 19710702 199802 1 001

**Penguji :**

1. Dr. Suyanto ST. MT.  
NIP. 197111131995121002
2. Prof. Dr. Ir. Aulia Siti Aisjah MT.  
NIP. 196601161989032001

Kepala Departemen Teknik Fisika

Fakultas Teknologi Industri dan Rekayasa Sistem



Disetujui untuk Buku Tesis  
Deni Nur Fauzi  
30 Maret 2021

Dr. Suyanto ST. MT.  
NIP. 197111131995121002

*Halaman ini sengaja dikosongkan*

## **OPTIMISASI *CHEMICAL OXYGEN DEMAND PRODUCED WATER* PADA *POLISHING UNIT***

Nama Mahasiswa : Deni Nur Fauzi  
NRP : 02311850010002  
Pembimbing : Totok R. Biyanto, Ph.D.

### **ABSTRAK**

*Polishing unit* pada Saka Indonesia Pangkah Limited menggunakan *biological treatment* yang memanfaatkan bakteri aerob untuk mengurangi kadar *Chemical Oxygen Demand (COD) effluent* pada *produce water* saat eksplorasi minyak agar sesuai dengan baku mutu. Untuk menjaga agar bakteri tetap hidup diperlukan tambahan substrat berupa nitrat dan fosfat yang dijaga pada kondisi tertentu. Uji data operasional menunjukkan bahwa hubungan antara kadar COD *effluent* dengan variabel-variabel lain non linier dan kompleks. Sehingga dibutuhkan pemodelan *black box* seperti *Artificial Neural Network (ANN)* untuk memodelkan hubungan ini. Dari *Process Flow Diagram (PFD)*, data operasional dan pertimbangan manajemen maka 11 variabel menjadi *input* model ANN dan COD sebagai *output* variabel. *Output* variabel model ini akan menjadi fungsi objektif dimana tujuannya adalah nilai minimum. Dua *input* variabel sebagai variabel yang dioptimisasi yaitu massa nitrat dan fosfat. Sedangkan konstrain berupa 9 parameter operasional dan tiga *range* variabel *input-output*. Hubungan empiris antara variabel *input-output* yang tidak mempunyai persamaan turunan maka teknik optimisasi stokastik diperlukan. Salah satu teknik optimisasi stokastik adalah *Genetic Algorithm (GA)*. Hasil dari prediksi ANN menggunakan struktur *Multi Layer Perceptron (MLP)* dengan *input Finite Impulse Response (FIR)* serta pelatihan Levenberg-Marquardt menghasilkan *Root Mean Square Error (RMSE)* paling optimal berada pada *hidden node 42* yaitu RMSE selama pelatihan adalah 0.16092 dan RMSE selama validasi 1.73769. Optimisasi kadar COD mendapatkan hasil kadar COD optimal yaitu 44.8668 mg/L pada kadar nitrat sebesar 9 mg/L dan kadar fosfat sebesar 12 mg/L.

Kata kunci: Optimisasi, *Chemical Oxygen Demand*, *Produce water*, Kualitas Air, *Artificial Neural Network*, *Genetic Algorithm*.

*Halaman ini sengaja dikosongkan*

## **OPTIMIZATION OF CHEMICAL OXYGEN DEMAND PRODUCED WATER IN POLISHING UNIT**

Name : Deni Nur Fauzi  
NRP : 02311850010002  
Supervisors : Totok R. Biyanto, Ph.D.

### **ABSTRACT**

*In order to conform with government regulation about waste water quality, Saka Indonesia Pangkah Limited utilizes the polishing unit aerobic bacteria to reduce levels of Chemical Oxygen Demand (COD) effluent in produce water during oil exploration. To control the bacteria alive, an additional substrate in the form of nitrate and phosphate is maintained under certain conditions. The operational data shows that the relationship between COD effluent levels with other variables is non-linear and complex. The black box model such as Artificial Neural Network (ANN) is required. Refer to Process Flow Diagram (PFD), operational data and management considerations. The 11 variables are selected as ANN model input and COD as the output variable. The output of this model variable will be representative as an objective function where the objective is the minimum value. Two input variables are selected as the optimized variables, namely the mass of nitrate and phosphate. While the constraint consists of 9 operational parameters and three ranges of input-output variables. The empirical relationship between the input-output variables that do not have a derivative equation is required the stochastic optimization technique. One of the famous stochastic optimization techniques is Genetic Algorithm (GA). The results of ANN predictions using the Multi Layer Perceptron (MLP) structure with Finite Impulse Response (FIR) input and Levenberg-Marquardt training resulted an optimal Root Mean Square Error (RMSE) at hidden node 4. RMSE during training was 0.16092 and RMSE during validation 1,73769. Optimization of COD levels resulted an optimal COD levels of 44.8668 mg / L at a nitrate level of 9 mg / L and a phosphate level of 12 mg / L.*

**Keywords:** *Optimization, Chemical Oxygen Demand, Produce water, Water quality, Artificial Neural Network, Genetic Algorithm*

*Halaman ini sengaja dikosongkan*

## KATA PENGANTAR

Alhamdulillah, segala puji dan syukur penulis panjatkan kepada Allah SWT atas limpahan rahmat, hidayah, serta petunjuk-Nya sehingga penulis dapat menyelesaikan tesis pada jenjang magister yang berjudul “*Optimisasi Chemical Oxygen Demand Produced Water pada Polishing Unit*”. Penulis telah banyak mendapatkan bantuan dari berbagai pihak dalam menyelesaikan tesis ini. Atas berbagai bantuan itu penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Totok R. Biyanto, Ph.D. selaku dosen pembimbing dan dosen wali yang sangat berjasa dalam kuliah S2 saya. Beliau telah sabar memberikan motivasi, petunjuk, bimbingan, serta ilmu yang sangat bermanfaat. Selain terkait dengan tesis banyak sekali ilmu tentang kehidupan yang beliau berikan.
2. Bapak Dr. Suyanto, S.T., M.T selaku kepala departemen Teknik Fisika yang telah memberikan petunjuk, ilmu serta bimbingan selama menempuh pendidikan di jurusan Teknik Fisika.
3. Kedua orang tua yang selalu mendukung dan berdoa setiap harinya sehingga saya dapat lulus dari S2 Teknik Fisika ITS.
4. Teman-teman seperjuangan kuliah S2 Teknik Fisika ITS yang telah berbagi ilmu dan pengalaman.
5. Semua pihak yang telah mendukung dan memberikan doa yang tidak bisa penulis sebutkan satu per satu.

Penulis menyadari bahwa penulisan laporan tesis ini tidaklah sempurna. Oleh karena itu, sangat diharapkan kritik dan saran yang membangun dari semua pihak sehingga mencapai sesuatu yang lebih baik. Penulis juga berharap semoga laporan ini dapat menambah wawasan yang bermanfaat bagi pembaca.

Surabaya, Februari 2021

Penulis

*Halaman ini sengaja dikosongkan*

## DAFTAR ISI

LEMBAR PENGESAHAN TESIS .....	i
ABSTRAK .....	iii
<i>ABSTRACT</i> .....	v
KATA PENGANTAR .....	vii
DAFTAR ISI .....	ix
DAFTAR GAMBAR .....	xi
DAFTAR TABEL .....	xiii
BAB I PENDAHULUAN .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	4
1.3 Tujuan Penelitian .....	4
1.4 Lingkup Kajian .....	4
1.5 Manfaat Penelitian .....	6
BAB II TINJAUAN PUSTAKA .....	7
2.1. <i>Produced Water</i> .....	7
2.2. Parameter Kualitas Air .....	7
2.2.1. <i>Chemical Oxygen Demand (COD)</i> .....	7
2.2.2. <i>Biochemical Oxygen Demand (BOD)</i> .....	8
2.2.3. <i>Total Suspended Solid (TSS)</i> .....	8
2.2.4. <i>Total Dissolved Solid (TSS)</i> .....	9
2.2.5. <i>Mixed-Liquor Suspended Solid (MLSS)</i> .....	9
2.2.6. <i>Sludge Volume Index (SVI)</i> .....	9
2.2.7. <i>Sludge Volume 30 (SV30)</i> .....	10
2.3. <i>Activated Sludge Process</i> .....	10
2.4. Mikroorganisme .....	13
2.5. <i>Artificial Neural Network (ANN)</i> .....	13

2.5.1. <i>Multilayer Perceptron</i> (MLP) .....	15
2.5.2. <i>Finite Impulse Response</i> (FIR).....	17
2.5.3. <i>Levenberg-Marquardt Algorithm</i> .....	17
2.5.4. <i>Root Mean Square Error</i> (RMSE).....	18
2.5.5. Penentuan Jumlah <i>Hidden Node</i> .....	18
2.6. <i>Genetic Algorithm</i> (GA).....	18
2.7. Kajian Penelitian Sebelumnya .....	20
BAB III METODOLOGI PENELITIAN .....	23
3.1. Diagram Alir Penelitian .....	23
3.2. Identifikasi Masalah.....	25
3.3. Pengumpulan Data .....	26
3.4. Pengolahan Data Awal.....	27
3.5. Problem Formulasi.....	29
3.6. Pemodelan dan Validasi ANN .....	29
3.7. Desain Teknik Optimisasi GA .....	31
3.8. Optimisasi Kadar COD pada <i>Polishing Unit</i> .....	32
3.9. Analisis Hasil dan Pembahasan serta kesimpulan .....	33
BAB IV HASIL DAN PEMBAHASAN.....	35
4.1. Pengujian Data pada Pengolahan Data Awal.....	35
4.1.1. Uji linieritas .....	35
4.1.2. Uji Korelasi.....	36
4.2. Pelatihan dan Vaidasi Model ANN.....	42
4.3. Optimisasi COD pada <i>Polishing Unit</i> Menggunakan ANN dan GA.....	46
BAB V KESIMPULAN DAN SARAN .....	49
5.1. Kesimpulan .....	49
5.2. Saran.....	49
DAFTAR PUSTAKA.....	51
LAMPIRAN .....	57
Lampiran 1. Report Harian <i>Polishing Unit</i> .....	57

## DAFTAR GAMBAR

<b>Gambar 2. 1</b> <i>Process Flow Diagram (PFD) Polishing Unit</i> [26] .....	12
<b>Gambar 2. 2</b> Struktur <i>Artificial Neural Network</i> [28] .....	14
<b>Gambar 2. 3</b> <i>Neuron model</i> [29] .....	15
<b>Gambar 2. 4</b> Struktur MLP [32] .....	16
<b>Gambar 2. 5</b> Urutan proses pada <i>Genetic Algorithm</i> secara umum.....	19
<b>Gambar 3. 1</b> Alur Penelitian .....	25
<b>Gambar 3. 2</b> Struktur Dari ANN .....	30
<b>Gambar 3. 3</b> Uji Algoritma.....	32
<b>Gambar 4. 1</b> Sensitivitas <i>flowrate produce water</i> terhadap <i>COD effluent</i> . .....	37
<b>Gambar 4. 2</b> Sensitivitas pH <i>produce water</i> terhadap <i>COD effluent</i> .....	37
<b>Gambar 4. 3</b> Sensitivitas temperatur <i>produce water</i> terhadap <i>COD effluent</i> . .....	38
<b>Gambar 4. 4</b> Sensitivitas TSS <i>produce water</i> terhadap <i>COD effluent</i> .....	38
<b>Gambar 4. 5</b> Sensitivitas TDS <i>produce water</i> terhadap <i>COD effluent</i> .....	38
<b>Gambar 4. 6</b> Sensitivitas COD <i>influent produce water</i> terhadap <i>COD effluent</i> ..	39
<b>Gambar 4. 7</b> Sensitivitas MLSS terhadap <i>COD effluent</i> . .....	39
<b>Gambar 4. 8</b> Sensitivitas SV30 terhadap <i>COD effluent</i> . .....	39
<b>Gambar 4. 9</b> Sensitivitas SVI terhadap <i>COD effluent</i> . .....	40
<b>Gambar 4. 10</b> Sensitivitas NO <sub>3</sub> terhadap <i>COD effluent</i> . .....	40
<b>Gambar 4. 11</b> Sensitivitas PO <sub>4</sub> terhadap <i>COD effluent</i> . .....	40
<b>Gambar 4. 12</b> RMSE ANN pada hidden node 1 sampai 150. ....	43
<b>Gambar 4. 13</b> Hasil pelatihan ANN dalam memprediksi <i>COD effluent</i> .....	44
<b>Gambar 4. 14</b> Hasil Prediksi <i>COD effluent</i> .....	45
<b>Gambar 4. 15</b> Skematik Diagram Optimisasi COD pada <i>Polishing Unit</i> .....	46
<b>Gambar 4. 16</b> Hasil Optimisasi COD Menggunakan GA .....	47

*Halaman ini sengaja dikosongkan*

## DAFTAR TABEL

<b>Tabel 3. 1</b> Data <i>polishing unit</i> Saka Indonesia Pangkah Limited.....	26
<b>Tabel 3. 2</b> Tingkat Hubungan Berdasarkan Koefisien Korelasi [48] .....	28
<b>Tabel 3. 3</b> Parameter dan Variabel GA .....	33
<b>Tabel 4. 1</b> Hasil Uji linieritas .....	35
<b>Tabel 4. 2</b> Hasil Uji Korelasi Nilai $r^2$ .....	36

*Halaman ini sengaja dikosongkan*

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Seiring meningkatnya kandungan air pada reservoir minyak dan gas bumi, akan berdampak pada peningkatan *produced water* yang harus diolah sebelum dikembalikan ke alam. *Produced water* merupakan air limbah yang terbawa keluar pada saat eksplorasi minyak dan gas bumi. *Produced water* mengandung beberapa polutan yang melebihi dari baku mutu yaitu Hydrogen Sulfide (H<sub>2</sub>S), minyak dan *grease*, Ammonium (NH<sub>3</sub>-N), dan *Chemical Oxygen Demand* (COD). Sehingga perlu dilakukan penurunan kadar polutannya sebelum dikembalikan ke alam. Kandungan polutan yang diperbolehkan untuk dikembalikan ke alam sesuai dengan baku mutu air limbah kegiatan eksplorasi dan produksi migas dari fasilitas darat yang diatur di dalam Keputusan Menteri Lingkungan Hidup No 19 tahun 2010 yang menyatakan batas maksimum kandungan COD *effluent*, NH<sub>3</sub>-N dan H<sub>2</sub>S [1].

Salah satu perusahaan yang melakukan kegiatan eksplorasi dan produksi migas adalah Saka Indonesia Pangkah Limited. Proses pengolahan kandungan polutan COD dalam *produced water* pada Saka Indonesia Pangkah Limited dilakukan di *polishing unit*. Proses yang terjadi pada *polishing unit* adalah pengolahan limbah menggunakan lumpur aktif (*activated sludge*). Menurut penelitian sebelumnya proses lumpur aktif dapat menghasilkan penurunan kadar COD tinggi sehingga sesuai untuk proses pengurangan COD dengan kadar yang tinggi [2]

*Polishing unit* ditempatkan di *downstream API Separator* yang berlokasi di *Onshore Processing Facility* (OPF). *API Separator* terdapat tiga bagian kanal yang mana salah satu kanalnya dipergunakan untuk proses *polishing unit* dengan *biological treatment*. Sedangkan dua bagian lain dipergunakan sebagai pengolahan *Oil in Water* (OiW). *Biological treatment* pada proses *polishing unit* menggunakan bakteri aerob yang berperan aktif untuk membantu proses pengolahan *produced water*. [3]

Bakteri aerob merupakan bakteri yang membutuhkan oksigen serta memanfaatkan polutan organik terlarut dan partikel organik sebagai sumber makanannya. Bakteri aerob melakukan proses sekresi enzim untuk menguraikan

partikel organik dan polutan organik pada air limbah sehingga *produced water* yang akan dikembalikan ke alam tidak akan merusak ekosistem. Penggunaan bakteri aerob dalam pengolahan *produced water* harus dijaga stabilitasnya untuk menghindari fenomena *washout* yaitu kematian bakteri akibat kekurangan oksigen dan substrat [4]. Oleh karena itu perlu dilakukan aerasi dan penambahan substrat untuk menjaga stabilitas pertumbuhan bakteri pada *polishing unit*.

Substrat yang dibutuhkan oleh bakteri aerob pada air limbah dalam melakukan proses pengolahan limbah adalah nitrat ( $\text{NO}_3$ ) dan fosfat ( $\text{PO}_4$ ). Laju pertumbuhan bakteri dipengaruhi oleh substrat yang dikonsumsi oleh bakteri, semakin banyak substrat yang diberikan maka pertumbuhan bakteri akan semakin cepat sesuai dengan persamaan Monod [5]. Hal itu menyebabkan ketika substrat yang ditambahkan terlalu banyak maka bakteri akan cepat mati jika substrat yang diberikan terlalu sedikit maka kinerja dari bakteri akan menurun. Oleh karena itu pemberian substrat harus diatur takarannya agar kinerja bakteri optimal. Untuk mendapatkan kadar COD *effluent* minimal maka kadar nitrat dan fosfat harus dijaga pada kondisi tertentu.

Untuk memprediksi COD yang dipengaruhi oleh beberapa variabel dan parameter yang hubungannya kompleks dan non linier maka diperlukan prediktor yang mampu mengatasi hal ini. Prediktor yang banyak digunakan adalah *Support Vector Machine* (SVM), *Adaptive Neuro Fuzzy Inference System* (ANFIS) dan *Artificial Neural Network* (ANN). Pada penelitian sebelumnya telah dilakukan perbandingan metode SVM, ANN dan ANFIS untuk memprediksi adsorpsi zat warna. Hasilnya menunjukkan bahwa metode ANN memiliki akurasi yang lebih baik dibandingkan metode yang lain [6]. Sehingga pada penelitian ini dipilih metode ANN sebagai prediktor untuk memprediksi kandungan COD.

Beberapa struktur ANN yang sering digunakan yaitu struktur *Multi-Layer Perceptron Artificial Neural Networks* (MLPANN) dan struktur *Radial Basis Function Artificial Neural Networks* (RBFANN). Penelitian sebelumnya membandingkan antara MLPANN dan RBFANN yang digunakan untuk simulasi konsentrasi limbah cair menunjukkan bahwa nilai *Root Mean Square Error* (RMSE)

struktur MLPANN lebih rendah dibandingkan RMSE struktur RBFANN [7]. Sehingga dalam penelitian ini struktur yang akan digunakan adalah MLPANN.

Sebagai *Black Box* model, pemodelan menggunakan ANN sangat tergantung kepada kualitas data atau kekuatan korelasi antara regressor sebagai *input* model dan yang diprediksi sebagai *output* model. Untuk itu analisa sensitivitas hubungan antara variabel-variabel *input* dengan COD sebagai variabel *output* diperlukan. Setelah pemodelan ANN telah dibuat, diperlukan teknik optimisasi yang sesuai untuk mendapatkan COD yang minimal dengan mencari variabel yang dioptimisasi yang sesuai, dengan mempertimbangkan parameter-parameter yang dimonitor pada kondisi operasi proses. Penggunaan model ANN yang tidak mempunyai persamaan diferensial, ditambah lagi nilai COD yang mempunyai kemungkinan banyak lokal optimum, maka teknik optimisasi stokastik akan lebih efektif dibandingkan teknik optimisasi deterministik.

Salah satu teknik optimisasi stokastik yang banyak digunakan adalah teknik optimisasi *Genetic Algorithm* (GA). Beberapa penelitian menggunakan GA telah dilakukan oleh Majid Bagheri pada *wastewater treatment* yang menghasilkan prediksi *sludge bulking* dengan memonitoring *sludge volume index* menggunakan *hybrid artificial neural network-genetic algorithm* [8]. Peneliti lain juga melakukan hal sama yaitu mengembangkan cara untuk memprediksi kuantitas produksi air menggunakan *Hybrid Artificial Neural Network* (HANN) dan GA. GA digunakan untuk mengoptimalkan bobot dan bias untuk membantu ANN menganalisa *input* dan *output* data. Performansi ANN ditunjukkan oleh nilai R sehingga HANN dapat digunakan untuk memprediksi produksi air [9]. Berbeda dengan kedua penelitian sebelumnya pada penelitian ini GA bukan untuk menemukan  $w$  dan  $n$  yang optimal akan tetapi untuk mengoptimisasi nilai COD *effluent* dari *polishing unit*.

Sampai saat ini belum ditemukan literatur yang membahas optimisasi COD pada *polishing unit* menggunakan model ANN dan teknik optimisasi GA. Walaupun, pada aplikasi lain penggunaan ANN dan GA sudah dilakukan seperti pada penelitian tentang Model ANN untuk temperatur profil tanur nikel [10] dan optimalisasi kapasitas produksi strategis pelumas kemasan lithos [11]. Sehingga

pada penelitian ini akan dilakukan pemodelan *polishing unit* dengan metode ANN dengan teknik optimisasi GA untuk mendapatkan COD minimum.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang diatas, maka rumusan masalah yang akan diangkat dalam penelitian ini adalah sebagai berikut:

- a. Perlu dianalisa hubungan variabel-variabel yang mempengaruhi COD pada *polishing unit* untuk pemilihan regressor pada ANN.
- b. Perlu dirancang *optimizer* berbasis GA dan ANN dalam mengoptimisasi COD pada *plant polishing unit*.
- c. Perlu dianalisa performansi sistem yang dirancang.

## 1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, maka tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

- a. Untuk menganalisa hubungan variabel-variabel terhadap COD pada *polishing unit* yang digunakan sebagai regressor pada ANN.
- b. Untuk mendesain *optimizer* berbasis GA dan ANN dalam mengoptimisasi COD pada *plant polishing unit*.
- c. Menganalisa performansi sistem yang dirancang

## 1.4 Lingkup Kajian

Lingkup kajian dari penelitian ini adalah pengambilan data dilakukan di *polishing unit* Saka Indonesia Pangkah Limited. Data yang diambil meliputi gambar *Process Flow Diagram* (PFD), *flowrate*, *power of Hydrogen* (pH), temperatur, *Total Suspended Solids* (TSS), *Total Dissolve Solid* (TDS), COD *influent*, *Mixed-Liquor Suspended Solid* (MLSS), *Sludge Volume* (SV30), *Sludge Volume Index* (SVI), NO<sub>3</sub>, PO<sub>4</sub> dan COD *effluent*. Sedangkan data hasil pengukuran selanjutnya dianalisa nilainya mulai dari nilai minimum, maksimum, rata rata dan standar deviasinya untuk melihat sebaran dari data.

Setelah data dianalisa kemudian dicari hubungan antara variabel-variabel tersebut terhadap COD *effluent* guna menemukan *input* yang sesuai untuk model

ANN. Untuk mencari hubungan antara variabel-variabel dilakukan uji korelasi terhadap COD *effluent*. Variabel yang memiliki koefisien korelasi sangat kuat dan kuat akan menjadi *input* dari model ANN.

Dengan menggunakan data yang sudah dikumpulkan, model ANN akan dibangun dengan struktur *Multi Layer Perceptron* (MLP), struktur *input Finite Impulse Respons* (FIR) dan dilatih menggunakan algoritma Levenberg Marquardt (LM) untuk memprediksi kadar dari COD *effluent*.

Setelah model ANN dibuat, akan didapatkan hubungan setiap variabel dengan COD *effluent* melalui grafik sensitivitas yang akan dibuat. Sehingga pola hubungan dapat diketahui dari setiap variabel terhadap COD *effluent*. Dengan menggunakan gambar dari PFD maka akan diketahui proses yang terjadi pada polishing unit sehingga dapat diketahui variabel yang akan dioptimisasi.

Dari uraian di atas, selanjutnya *output* dari model ANN akan menjadi fungsi objektif untuk mendapatkan COD *effluent* paling optimal. Optimisasi COD *effluent* perlu dilakukan dengan mengendalikan kadar nitrat dan fosfat pada *polishing unit*. Kadar nitrat dan fosfat diatur dengan mengontrol *flow rate* dari urea dan TSP.

Selain variabel nitrat dan fosfat, variabel lain yang tidak dioptimisasi akan menjadi parameter. Karena nilai *flowrate*, pH, temperatur, TSS, TDS, COD *influent*, MLSS, SV30 dan SVI tidak dapat diatur nilainya. Parameter ini bergantung pada kondisi *produced water* yang masuk dalam *polishing unit*. Parameter ini kemudian menjadi konstrain dari optimisasi. Selain itu konstrain lain adalah *input* yang diberikan dari proses dan *output* yang diinginkan. Sehingga didapatkan variabel yang dapat dioptimisasi yaitu massa nitrat dan fosfat atau *flow rate* urea dan TSP.

Salah satu teknik optimisasi yang banyak dipakai adalah GA. Teknik optimisasi ini banyak dipakai karena memiliki kemampuan dalam menemukan global optimum. Sehingga hasil dari optimisasi ini akan memberikan COD *effluent* yang optimal dengan menentukan kadar nitrat dan fosfat atau *flow rate* urea dan TSP yang paling sesuai.

### **1.5 Manfaat Penelitian**

Penelitian ini akan menghasilkan sistem optimisasi COD pada *polishing unit* berbasis ANN dan GA, dengan variabel yang dioptimisasi adalah massa nitrat dan fosfat atau dalam aplikasi akan berupa pengaturan *set point* dua *flow rate* urea dan TSP, yang belum ada penelitian sebelumnya baik di dunia akademis dan dunia praktisi. Diharapkan dengan adanya sistem yang diajukan, dunia industri dapat mengapikasinya dengan tujuan meningkatkan efisiensi proses dan ramah lingkungan.

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1. *Produced Water***

*Produced water* adalah istilah yang digunakan dalam industri minyak untuk menggambarkan air yang diproduksi sebagai produk sampingan selama ekstraksi minyak dan gas alam. *Produced water* adalah sejenis air payau dan air asin dari bawah tanah yang dibawa ke permukaan [12]. Untuk mencapai perolehan minyak yang maksimal sebagian *produced water* diinjeksikan ke dalam reservoir untuk membantu mendorong minyak ke sumur produksi sebagian lainnya dikembalikan ke alam. Kadar polutan pada *produced water* dapat merusak lingkungan jika langsung dibuang ke alam, maka perlu adanya pengolahan terlebih dahulu [13].

Pengolahan dapat dilakukan pada *onshore facility* dengan menggunakan berbagai macam *treatment*. Saka Indonesia Pangkah Limited memiliki 2 *treatment* untuk mengolah air limbah *produced water* yaitu *API separator* dan *polishing unit*. *Produced water* yang masuk ke dalam fasilitas pengolahan limbah pertama kali masuk ke dalam *API Separator* untuk memisahkan minyak dan air sehingga ketika keluar dari proses pemisahan, kadar Oil in Water (OiW) memenuhi baku mutu [14].

Setelah melalui proses pada *API Separator*, *produced water* dialirkan menuju *polishing unit* yang akan mengurangi kadar COD *effluent* dalam air menggunakan bantuan bakteri aerob yang dikenal dengan *activated sludge process*. Setelah proses ini selesai air dapat dibuang ke laut sesuai kualitas air yang diizinkan.

#### **2.2. Parameter Kualitas Air**

##### **2.2.1. *Chemical Oxygen Demand (COD)***

*Chemical Oxygen Demand (COD)* adalah jumlah oksigen yang dikonsumsi dalam kondisi tertentu dalam oksidasi kimiawi bahan anorganik, organik dan teroksidasi yang terkandung dalam air limbah [15]. Lebih detailnya yaitu jumlah oksigen yang dibutuhkan untuk mengoksidasi zat-zat organik yang ada dalam 1 liter sampel air yang digunakan sebagai sumber oksigen (*oxidizing agent*). Angka COD merupakan ukuran bagi pencemaran air oleh zat – zat organik yang secara alamiah dapat dioksidasikan melalui proses mikrobiologis, dan mengakibatkan berkurangnya oksigen terlarut di dalam air. Dalam baku mutu Keputusan Menteri

Lingkungan Hidup No 19 tahun 2010 disebutkan bahwa kadar maksimum dari COD yang diperbolehkan untuk dibuang ke laut adalah 200 mg/L. Pengukuran COD didasarkan pada ISO 6060 tentang *Water quality - Determination of the chemical oxygen demand*.

Secara teoritis COD dapat dihitung dengan menggunakan rumus seperti pada persamaan 2.1 [16].

$$COD = \frac{\text{Massa oksige yang diperlukan}}{\text{Massa subtrrat yang diperlukan}} \quad (2.1)$$

Dari rumusan tersebut dapat diketahui ketika substrat berupa variabel nitrat dan fosfat naik maka kadar COD *effluent* akan turun, akan tetapi pada batasan tertentu kenaikan nitrat dan fosfat tidak akan mempengaruhi dari COD *effluent* karena substrat yang dibutuhkan oleh bakteri memiliki batasan.

### 2.2.2. *Biochemical Oxygen Demand (BOD)*

*Biochemical Oxygen Demand (BOD)* adalah adalah jumlah oksigen terlarut yang dibutuhkan oleh organisme biologis aerobik untuk memecah bahan organik yang ada dalam sampel air tertentu pada suhu tertentu selama periode waktu tertentu. Biodegradasi aerobik akan mengoksidasi bahan organik secara biologis. Selama proses ini, bahan organik diubah oleh mikroorganisme menjadi biomassa, produk transformasi akhirnya dari reaksi biodegradasi adalah senyawa yang berasal dari bahan organik awal, CO<sub>2</sub> dan H<sub>2</sub>O. [17]

Pengukuran BOD dilakukan sesuai dengan metode standar yang dinamakan tes botol tertutup, dijelaskan dalam Standar Internasional ISO 5815-1: 2003. Nilai BOD paling sering dinyatakan dalam miligram oksigen yang dikonsumsi per liter sampel selama 5 hari inkubasi pada suhu 20 ° C dan sering digunakan sebagai pengganti derajat polusi organik air [18].

### 2.2.3. *Total Suspended Solid (TSS)*

*Total Suspended Solid (TSS)* adalah padatan yang menyebabkan kekeruhan air. TSS memiliki sifat tidak terlarut dan tidak dapat mengendap. Kandungan TSS terdiri dari fitoplankton, zooplankton, kotoran hewan, sisa tanaman dan limbah industri yanuug terbawa kedalam air. TSS merupakan jumlah bobot bahan yang tersuspensi dalam suatu volume air tertentu, dengan satuan mg perliter [19].

#### 2.2.4. *Total Dissolved Solid (TSS)*

Pengukuran TDS dilakukan dengan menggunakan gelas beaker yang di panaskan pada suhu 103-105°C kemudian di dinginkan dan ditimbang untuk mendapatkan massa awal. Kemudian ditambahkan air limbah sebesar 100 ml dan diuapkan hingga mengering. Kemudian gelas ditimbang kembali sehingga didapatkan TDS dari suatu limbah. [20]

#### 2.2.5. *Mixed-Liquor Suspended Solid (MLSS)*

*Mixed-Liquor Suspended Solid (MLSS)* adalah konsentrasi padatan tersuspensi, dalam tangki aerasi selama proses lumpur aktif, yang terjadi selama pengolahan air limbah [21]. Unit MLSS terutama diukur dalam miligram per liter (mg / L), tetapi untuk lumpur aktif sebagian besar diukur dalam gram per liter.

MLSS sebagian besar terdiri dari mikroorganisme dan zat tersuspensi yang tidak dapat terurai secara hayati. MLSS adalah bagian penting dari proses lumpur aktif untuk memastikan bahwa ada cukup jumlah biomassa aktif yang tersedia untuk mengkonsumsi jumlah yang diterapkan dari polutan organik setiap saat. Ini dikenal sebagai rasio makanan terhadap mikroorganisme, lebih umum dinotasikan sebagai rasio F/M. Dengan mempertahankan rasio ini pada tingkat yang sesuai, biomassa akan mengkonsumsi persentase makanan yang tinggi. Ini meminimalkan hilangnya sisa makanan dalam limbah yang diolah. Secara sederhana, semakin banyak biomassa yang dikonsumsi semakin rendah BOD.

#### 2.2.6. *Sludge Volume Index (SVI)*

Indeks ini didefinisikan sebagai volume (dalam mililiter) yang ditempati oleh 1 g padatan *mixed liquor* lumpur aktif setelah didiamkan selama 30 menit dalam silinder ukur 1000 mL. Dalam praktiknya, nilai ini diambil sebagai persentase volume yang ditempati oleh lumpur dalam sampel cairan campuran (diambil di *effluent* tangki aerasi) setelah 30 menit pengendapan, dibagi dengan konsentrasi padatan tersuspensi dari cairan campuran [22]. Rumusnya dinyatakan pada persamaan 2.2 [23]:

$$SVI = \frac{V_s}{MLSS} \quad (2.2)$$

dimana:

SVI = *sludge volume index*, mL/g MLSS

V<sub>s</sub> = *Volume sludge* yang menetap setelah 30 min, mL/L

MLSS = *Mixed Liquor Suspended Solids*, g/L

### 2.2.7. *Sludge Volume 30 (SV30)*

Pengukuran *Sludge Volume 30 (SV30)* mengadopsi metode pada SM 2710 C: *Settled Sludge Volume*. Dengan waktu settling selama 30 menit sehingga disebut sebagai SV30. Nilai SV30 dapat dicari dengan mengambil 1000 ml *mixed liquor* dari kolam aerasi, kemudian ditungkan kedalam *Imhoff*. Langkah selanjutnya adalah dengan mengendapkan larutan tersebut selama 30 menit [24].

### 2.3. *Activated Sludge Process*

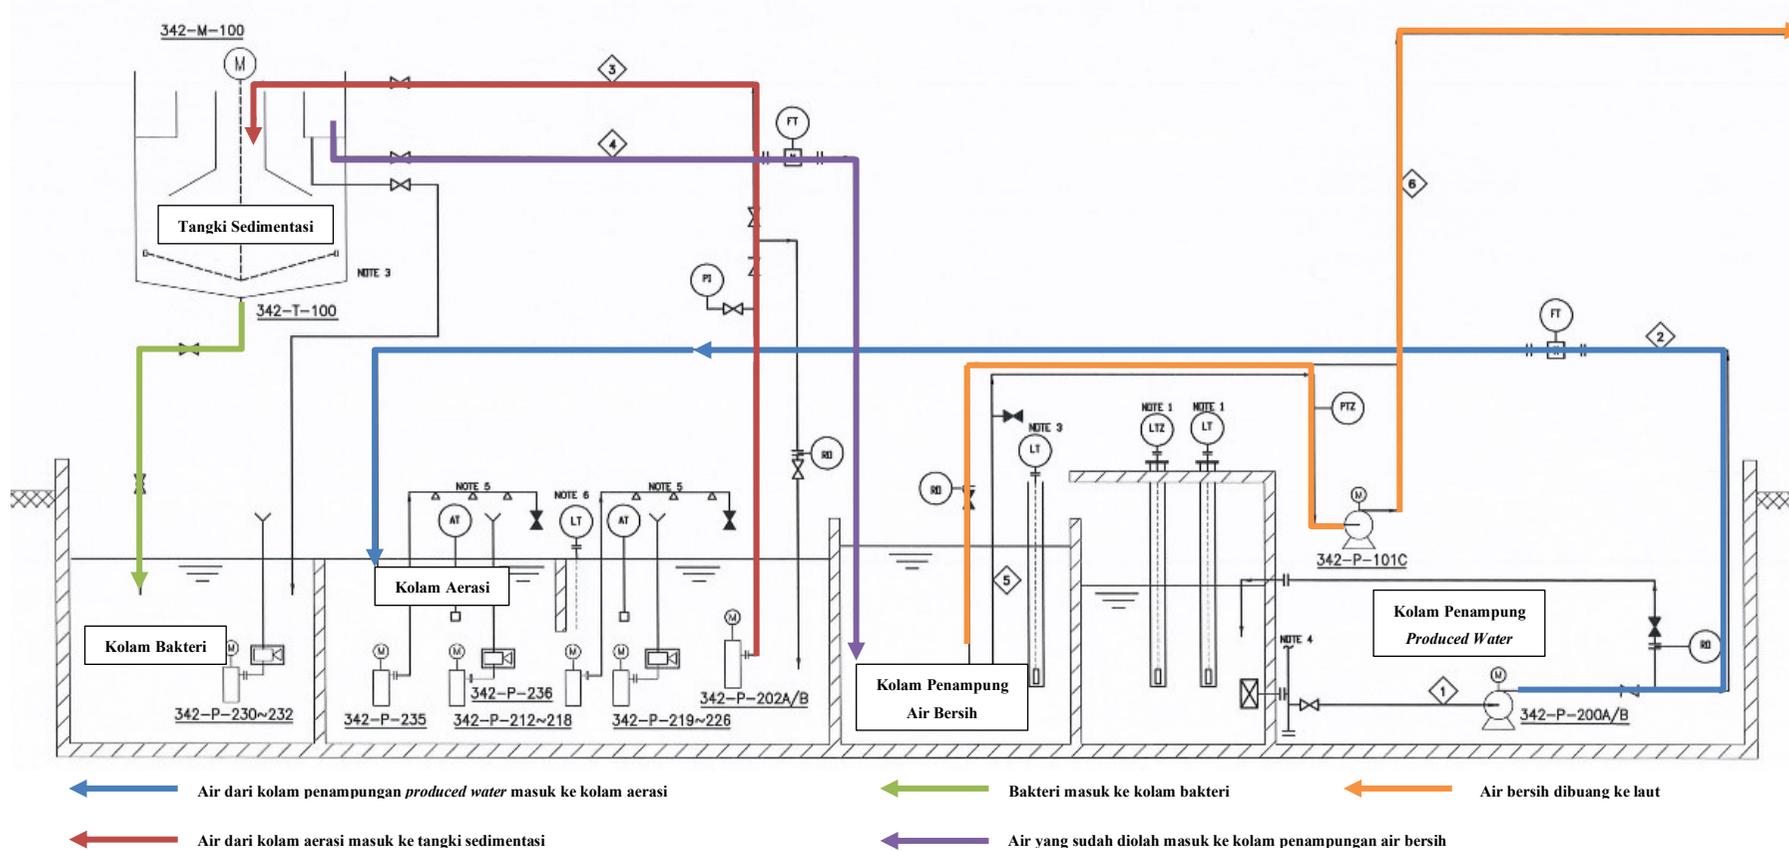
*Activated Sludge Process* merupakan proses pengolahan air limbah hasil pengeboran minyak dengan menggunakan lumpur aktif. Proses ini menggunakan mikroorganisme untuk menguraikan limbah secara aerob sehingga air hasil olahan sesuai dengan baku mutu. Pertumbuhan mikroorganisme optimal dengan memperhatikan faktor intrinsik (nutrien/substrat, pH, potensial redoks) dan ekstrinsik (suhu, oksigen) sebagai faktor penting pertumbuhan mikroorganisme.

Mikroorganisme yang ditumbuhkan dalam air limbah akan menguraikan air limbah menjadi air yang bebas polutan organik. Pada proses ini terdapat mikroorganisme yang hidup dan sudah mati setelah mengolah air limbah. Mikroorganisme yang mati akan dialirkan keluar dari proses sementara Mikroorganisme yang hidup akan dikembalikan pada proses utama sehingga dapat digunakan untuk melakukan proses pengolahan limbah kembali. Pada *activated sludge process* terdapat tiga jenis lumpur yang terlibat, yaitu lumpur sisa, lumpur biomassa yang berada pada bak aerasi, serta lumpur sekunder yang berada pada tangki pengendapan [25].

Kondisi lingkungan pengolahan air limbah merupakan faktor eksternal yang menentukan pertumbuhan mikroorganisme sehingga proses penguraian air limbah menjadi efisien. Selain itu faktor lain yang dapat menentukan pertumbuhan mikroorganisme adalah faktor intrinsik misalnya adanya nutrisi atau substrat yang digunakan mikroorganisme untuk sumber energi [26].

Proses pengolahan limbah dengan lumpur aktif merupakan proses aerobik dimana senyawa organik dioksidasi menjadi  $\text{CO}_2$ ,  $\text{H}_2\text{O}$ ,  $\text{NH}_4$  dan sel biomassa baru. Sumber oksigen dari proses diperoleh melalui aerasi. Alasan utama dari pengolahan limbah dengan proses lumpur aktif yaitu untuk menghilangkan COD, nitrifikasi, dan denitrifikasi.

Proses pengolahan limbah dengan lumpur aktif terdapat empat proses utama yaitu tangka aerasi, tangki pengendapan, resirkulasi lumpur, dan penghilangan lumpur sisa. Proses lebih jelas dapat dilihat pada Gambar 2.1.



**Gambar 2. 1** *Process Flow Diagram (PFD) Polishing Unit* [27]

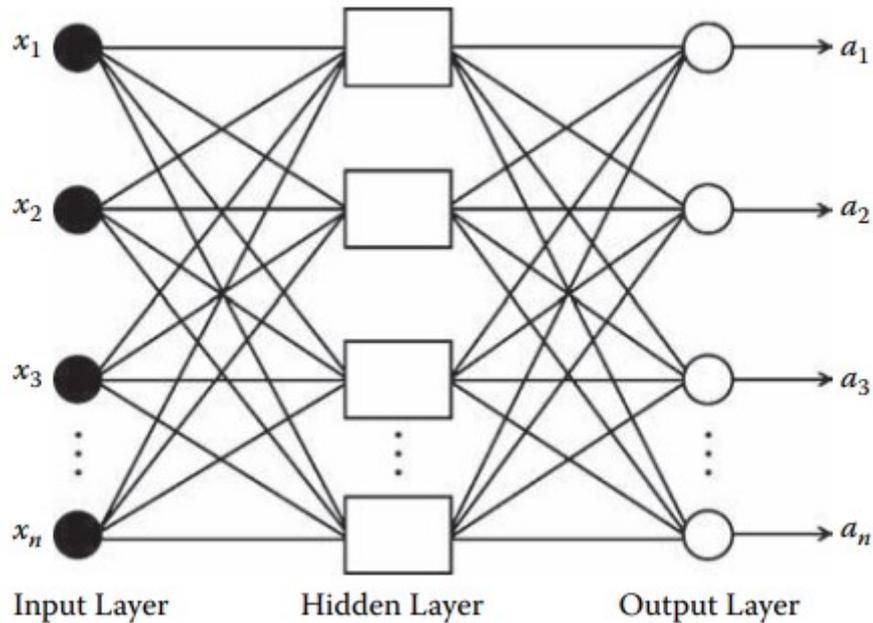
#### **2.4. Mikroorganisme**

Pengolahan limbah ini memanfaatkan berbagai macam organisme dalam melakukan proses pengolahannya seperti bakteri, fungi, protozoa, atau rotifers. Mikroorganisme tersebut berperan untuk menguraikan air limbah dengan cara melakukan oksidasi pada material organik yang bersifat biodegradable melalui proses aerasi untuk menghasilkan biomassa limbah. Biomassa ini akan dikonversi menjadi bentuk sel baru, dan hasil dari proses tersebut adalah terpisahnya biomassa yang baru terbentuk.

Proses penguraian polutan organik dilakukan secara absorpsi dan adsorpsi. Proses absorpsi terjadi pada polutan organik terlarut yang dapat masuk ke dalam sel. Sedangkan proses adsorpsi terjadi pada polutan organik tak larut yang tidak dapat masuk ke dalam sel tetapi dapat menempel pada dinding sel. Selanjutnya sel akan menghasilkan enzim untuk menguraikan polutan organik terlarut dan tidak terlarut [28].

#### **2.5. *Artificial Neural Network* (ANN)**

*Artificial Neural Network* (ANN) adalah sekelompok unit pemroses kecil yang dimodelkan berdasarkan sistem saraf manusia. Ada tiga konsep dasar yang penting dalam memahami ANN. Pertama, kekuatan hubungan antara dua neuron sangat penting untuk fungsi memori. Hubungan akan semakin kuat seiring dengan peningkatan nilai bobot [29]. Arsitektural dari ANN dapat dilihat pada Gambar 2.2.



**Gambar 2. 2** Struktur *Artificial Neural Network* [29]

Pada Gambar 2. 2 terdapat 3 komponen utama dari ANN yaitu

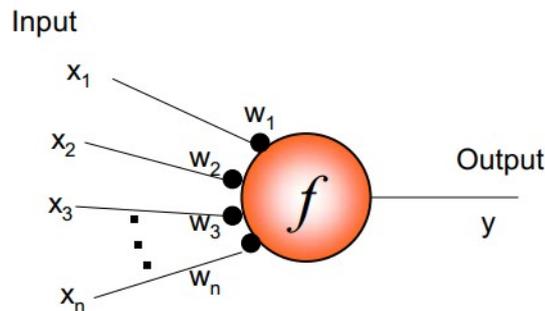
- input layer*: lapisan yang membawa data masuk kedalam system untuk kemudian di proses pada layer selanjutnya.
- hidden layer*: lapisan antara *input layer* dan *output layer*, dimana *artificial neuron* yang memiliki sekumpulan *input* pembobot ‘*weight*’ dan prosedur untuk menghasilkan *output neuron* melalui *activation function*.
- output layer*: lapisan terakhir dari neuron yang menghasilkan output system.

ANN ini meniru otak manusia dari cara pemrosesan data hingga dalam pengambilan keputusan. Persamaan lain yaitu pada:

- Pengetahuan diperoleh dari lingkungan, melalui suatu proses pembelajaran.
- Kekuatan koneksi antar unit yang disebut *synaptic weights*, berfungsi untuk menyimpan pengetahuan yang telah diperoleh oleh jaringan tersebut.

Secara matematik ANN digambarkan seperti pada Gambar 2.3. Pada gambar 2.3 terlihat ANN terdiri dari

- Synapse*  $(w_1, w_2, \dots, w_n)^T$
- Alat penambah (*adder*)
- Fungsi aktivasi (*f*)



**Gambar 2. 3** *Neuron model* [30]

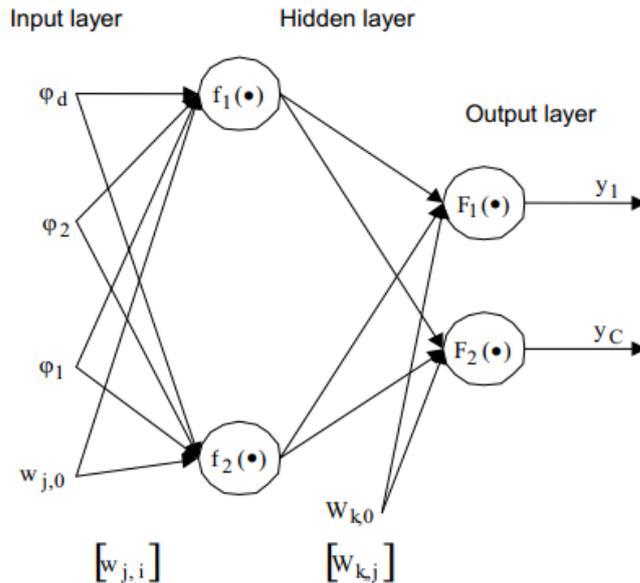
Korelasi antara ketiga komponen ini dirumuskan pada persamaan (2.3) berikut:

$$y = f \left( \sum_{i=1}^n x_i \times w_i \right) \quad (2.3)$$

Signal  $x$  berupa vektor berdimensi  $n$   $(x_1, x_2, \dots, x_n)^T$  akan mengalami penguatan oleh *synapse*  $w$   $(w_1, w_2, \dots, w_n)^T$ . Selanjutnya akumulasi dari penguatan tersebut akan mengalami transformasi oleh fungsi aktivasi  $f$  [31]. Berdasarkan arsitekturnya, neural network dapat dikategorikan, antara lain, *Single-Layer Neural Network*, *Multilayer Neural Network* (MLP), *Recurrent Neural Network* dan lain lain. Berbagai algoritma pembelajaran antara lain *Levenberg-Marquardt* (LM), *Hebb's Law*, *Delta Rule*, *Back Propagation Algorithm*, *Self Organizing Feature Map* dan lain lain [32]. MLP dan LM akan dipergunakan dalam penelitian ini.

### **2.5.1. Multilayer Perceptron (MLP)**

*Multilayer perceptron* (MLP) adalah salah satu arsitektur ANN yang banyak digunakan. Struktur MLP membangun perkiraan fungsi yang memiliki *multi-input multi-output* dengan cara yang sama seperti pemasangan polinomial orde rendah melalui satu set data poin [33]. Banyak pembelajaran yang berbeda telah dikembangkan. Gambar 2.4 menunjukkan struktur dari MLP, yang terdiri dari lapisan *input*, lapisan *hidden* dan lapisan *output*.



**Gambar 2. 4** Struktur MLP [33]

MLP yang dipilih dalam penelitian ini memiliki rumus matematika pada persamaan 2.4 sebagai berikut:

$$y_k = F \left[ \sum_{j=1}^{n_h} W_{k,j} \cdot f \left( \sum_{i=1}^d w_{j,i} \cdot \varphi_i + w_{j,0} \right) + W_{k,0} \right] \quad k = 1, 2, \dots, C \quad (2.4)$$

di mana  $\varphi$  adalah *input* eksternal,  $d$  adalah jumlah *input* dalam lapisan *input*,  $n_h$  adalah jumlah neuron tersembunyi dalam lapisan tersembunyi,  $W$  dan  $w$  adalah bobot,  $f$  dan  $F$  adalah fungsi aktivasi masing-masing untuk lapisan tersembunyi dan lapisan keluaran.

Algoritme pembelajaran MLP diuraikan seperti pada langkah-langkah di bawah ini [34] :

1. Inisialisasi jaringan dengan semua bobot diatur ke nomor acak.
2. Pola pelatihan pertama hasilnya didapatkan.
3. Bandingkan keluaran jaringan dengan keluaran target.
4. Sebarkan kesalahan ke belakang.

MLP terdiri dari setidaknya tiga lapisan node: lapisan *input*, lapisan tersembunyi dan lapisan *output*. MLP menggunakan teknik pembelajaran turunan yang disebut *backpropagation* untuk pelatihan. Berbagai lapisan dan aktivasi *non-*

*linier* yang membedakan MLP dari perceptron linier adalah data yang tidak dapat dipisahkan secara linier.[35]

### **2.5.2. Finite Impulse Response (FIR)**

FIR *neural network* menggunakan pendekatan statis *unfold-in-time* dan setara fungsional dari *Time Delay Neural Network* (TDNN). Mereka tidak memiliki koneksi umpan balik antar unit. TDNN menyediakan bentuk dinamika sederhana dengan menyangga variabel masukan tertinggal pada lapisan masukan dan keluaran pada lapisan tersembunyi. Jaringan FIR adalah jaringan *feedforward* yang bobot koneksi statis antar unit diganti dengan *filter* linier FIR yang dapat dimodelkan dengan garis tunda [36].

Setelah menerapkan teknik *unfold-in-time* ke FIR, semua penundaan akan dihilangkan dengan memperluas jaringan menjadi struktur statis besar. *backpropagation algorithm* kemudian diterapkan untuk pelatihan. Secara formal, penundaan waktu identik dengan *time windows* dipandang sebagai model autoregresif [36].

### **2.5.3. Levenberg-Marquardt Algorithm**

Dalam matematika dan komputasi, algoritma Levenberg-Marquardt (LMA atau hanya LM), juga dikenal sebagai metode kuadrat-kuadrat terkecil (DLS). Metode Levenberg-Marquardt merupakan salah satu metode optimasi untuk menyelesaikan masalah kuadrat terkecil yang didasarkan pada metode Gauss-Newton. LMA digunakan dalam banyak aplikasi perangkat lunak untuk memecahkan masalah pemasangan kurva generik. Namun, seperti halnya banyak pemasangan algoritma, LMA hanya menemukan minimum lokal, yang belum tentu minimum global [37].

Salah satu kelemahan dari metode Levenberg-Marquardt adalah bila terjadi osilasi pada proses iterasinya, maka iterasi akan berjalan lambat. Selain itu dalam banyak kasus LM akan menemukan solusi bahkan jika itu dimulai sangat jauh dari minimum final. LM digunakan untuk mengoptimalkan struktur ANN dengan menentukan jumlah neuron dalam satu lapisan tersembunyi selama tahap pelatihan.

#### 2.5.4. Root Mean Square Error (RMSE)

*Root Mean Square Error* (RMSE) adalah ukuran yang sering digunakan dari perbedaan antara nilai yang diprediksi oleh model atau estimator dan nilai yang diamati. Nilai RMSE lebih kecil dikatakan lebih akurat. RMSE digunakan untuk menunjukkan keakuratan model selama tahap pelatihan dan validasi. RMSE dapat diekspresikan dalam persamaan 2.5 [38].

$$RMSE = \left( \frac{\sum (y_i - \hat{y}_i)}{n} \right)^{0.5} \quad (2.5)$$

dengan

RMSE = *Root Mean Square Error*

$y_i$  = hasil observasi

$\hat{y}_i$  = hasil prediksi

$i$  = urutan data pada *database*

$n$  = jumlah data

#### 2.5.5. Penentuan Jumlah *Hidden Node*

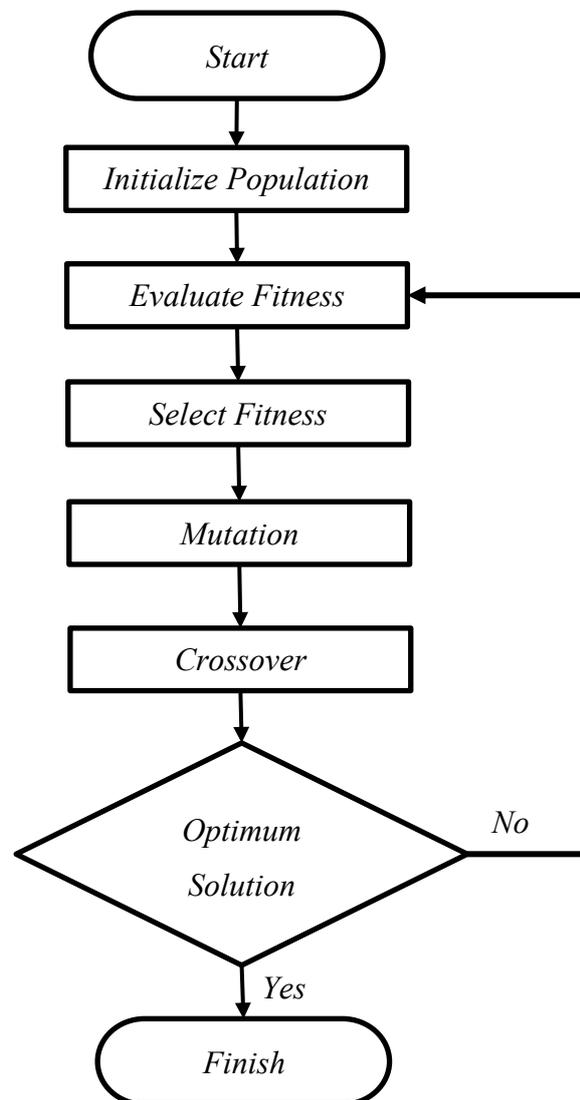
*Hidden node* merupakan *node* yang terdapat di antara *input node* dan *output node*. *Hidden node* ini menerima masukan dari *input node* atau dari *hidden node* dari *layer* sebelumnya. *Hidden node* mengkombinasikan bobot berdasarkan *input* yang diterima dari *node* sebelumnya dan memberikan keluaran untuk *layer* berikutnya.

#### 2.6. Genetic Algorithm (GA)

*Genetic Algorithm* (GA) adalah metode komputasi yang meniru proses evolusi dan seleksi alam. GA terinspirasi dari teori evolusi Darwin yang mencari dan mensimulasikan beberapa proses evolusi: seleksi, *crossover* dan mutasi [39]. Suatu populasi individu dicirikan oleh urutan genetik yang mengindikasikan karakteristik fisik yang berkembang di bawah tekanan seleksi lingkungan. Individu terkuat akan mereproduksi dan mengirimkan gen mereka, sementara mutasi dan *crossover* materi genetik akan mengeksplorasi karakteristik individu baru.

GA termasuk pelopor dalam bidang konsep metaheuristik dikarenakan banyak algoritma komputasi muncul dan menggunakan beberapa langkah dari GA

[40]. Yang membedakan GA dengan metode optimisasi lainnya yaitu, prosedur pencarian dalam GA hanya didasarkan pada nilai fungsi tujuan tanpa ada pemakaian gradien atau teknik kalkulus. Dengan prosedur inilah, akhirnya akan didapatkan solusi akhir dari permasalahan optimisasi yang dihadapi. Metode ini sering dimanfaatkan untuk mencari nilai optimal suatu fungsi/permasalahan.



**Gambar 2. 5** Urutan proses pada *Genetic Algorithm* secara umum[41].

Gambar 2.5 menunjukkan urutan tahapan dalam GA. Untuk mencari nilai optimal tersebut, pertama-tama parameter-parameter permasalahan ditransfer kedalam bentuk genetik sebuah kromosom individu yang disebut *genotype*. Kromosom ini terdiri dari sederetan *string* (misalnya angka “0” dan “1”) yang

merupakan analogi dari rantai DNA: A, T, G dan C yang sebenarnya, pada tubuh makhluk hidup. Selanjutnya suatu populasi yang terdiri dari ribuan kromosom individu ini mengalami proses seleksi, *crossover* (persilangan) dan mutasi yang meniru proses biologi yang terjadi di alam. Operasi ini diulang-ulang, dari satu generasi ke generasi berikutnya. Kualitas suatu individu ditunjukkan oleh nilai *fitness*, yang diukur dengan suatu kriteria yang mencerminkan sejauh mana kromosom individu tersebut mendekati nilai optimal yang diinginkan. Kriteria ini menjadi alat kontrol bagi proses evolusi, agar kondisi *fitness* generasi yang mendatang lebih baik dari pada generasi-generasi sebelumnya [30].

Setelah melewati ratusan atau mungkin ribuan generasi, proses evolusi ini akan menghasilkan individu-individu dengan nilai *fitness* yang tinggi. Hal ini mencerminkan diperolehnya jawaban yang merupakan pendekatan terhadap nilai optimal yang diinginkan.

## **2.7. Kajian Penelitian Sebelumnya**

Penelitian tentang *produced water* sudah dilakukan oleh banyak peneliti, salah satunya adalah yang dilakukan oleh Francine Piubeli yang membahas tentang pengurangan COD dan aromatik dalam *produced water* dari pengeboran minyak bumi menggunakan mikroorganisme dan penambahan substrat. Hasilnya yaitu dengan penambahan asam glukuronat, alanin atau histidin akan meningkatkan pengurangan COD dengan kombinasi substrat tertentu. Penurunan maksimum 80% dicapai dengan menggunakan kombinasi tryptone dan asam glukuronat [42].

Penelitian ini tidak membahas mengenai penambahan substrat nitrat dan fosfat. Hal ini yang akan dicoba pada tesis ini yaitu pengaruh dari penambahan nitrat dan fosfat terhadap kinerja bakteri untuk mengurangi kadar COD *effluent* dari *polishing unit*.

Pertimbangan pemakaian metode ANN adalah sudah dilakukan perbandingan metode antara ANN dengan *Support Vector Machine* (SVM) dan *Adaptive Neuro Fuzzy Inference System* (ANFIS) dalam memprediksi adsorpsi zat warna. Hasil Studi ini melaporkan bahwa penggunaan ANN menunjukkan akurasi

yang lebih baik dibandingkan metode yang lain dalam memprediksi suatu nilai [6]. Hal ini yang menjadi alasan penulis memilih metode ANN.

Pada penelitian lain tentang simulasi konsentrasi limbah cair seperti COD, NH<sub>4</sub> dan *Total Suspended Solids* (TSS) menggunakan metode ANN dengan variabel *input* COD, NH<sub>4</sub>, TSS, *Filling Time* (FT), *Reaction Time* (RT), *Aeration Intensity* (AI), *Sludge Residence Time* (SRT) dan *Mixed Liquor Volatile Suspended Solids* (MLVSS). Dengan hasil penelitiannya adalah dengan nilai *input* data yang rendah untuk melatih ANN, model *Multi-Layer Perceptron Artificial Neural Networks* (MLPANN) lebih sesuai dari pada model *Radial Basis Function Artificial Neural Networks* (RBFANN) karena R yang lebih tinggi dan nilai RMSE yang lebih rendah [7]. Tesis ini akan menggunakan metode yang sama yaitu MLPANN agar nilai RMSE yang didapat kecil. Selain itu dilakukan Optimisasi pada variabel *output* ANN dengan metode optimisasi GA agar pengurangan kadar COD lebih optimal.

Pradyut Kundu menjelaskan pada penelitiannya tentang pemodelan ANN untuk mengurangi *Organic Carbon* dan Nitrogen secara biologis dari Rumah Potong Hewan. Hasil dari penelitian ini adalah *output* model ANN memiliki error sebesar 3,33% [43]. Penelitian ini hanya menggunakan 6 variabel yaitu COD, NH<sub>4</sub>, Waktu Proses, MLVSS, pH dan DO. Selain itu penelitian ini tidak memberikan variasi substrat pada plant. *Improvement* yang akan dilakukan pada tesis ini yaitu memberikan penambahan nitrat dan fosfat sebagai substrat.

Penelitian lain tentang prediksi *Dissolved Oxygen* (DO) di Sungai Surma berdasarkan BOD dan COD dalam air menggunakan ANN memberikan hasil MSE = 0.465 dengan data eksperimental menunjukkan bahwa model ANN memberikan hasil yang cocok [44].

Penelitian tentang ANN pada *wastewater treatment* dilakukan oleh Majid Bagheri yang menghasilkan prediksi sludge bulking dengan memonitoring *sludge volume index* menggunakan *hybrid artificial neural network-genetic algorithm*. Modeling yang dilakukan memberikan hasil RMSE tidak lebih dari 3 persen [8]. Penelitian lain juga melakukan hal sama yaitu mengembangkan cara untuk memprediksi produksi air menggunakan *Hybrid Artificial Neural Network*

(HANN) dan GA. GA digunakan untuk mengoptimalkan bobot dan bias untuk membantu ANN menganalisa *input* dan *output* data. Performansi ANN ditunjukkan oleh nilai R dan HANN dapat digunakan untuk memprediksi produksi air [8] Berbeda dengan kedua penelitian sebelumnya pada tesis ini GA bukan untuk menemukan  $w$  dan  $n$  yang optimum akan tetapi untuk mengoptimisasi nilai COD *effluent* dari *polishing unit*

Penelitian tentang optimisasi menggunakan GA oleh Hongbin yang membahas tentang *hybrid learning method* yang mengkombinasikan *Genetic Algorithm with Adaptive Neuro-Fuzzy Inference System* (GA-ANFIS) untuk mengestimasi konsentrasi substrat pada wastewater treatment plant. Hasilnya menunjukkan bahwa metode ini memiliki akurasi yang tinggi [30]. Penelitian ini tidak melakukan optimisasi akan tetapi hanya mengestimasi nilai nutrient removal, melalui dasar penelitian ini dikembangkan optimisasi menggunakan model ANN dengan teknik optimisasi GA untuk menemukan kadar nitrat dan fosfat yang sesuai dengan COD optimum.

Pada penelitian ini dilakukan kontrol dari *Dissolved Oxygen* (DO) pada kolam aerasi pada proses *activated sludge* menggunakan algoritma *Radial Basis Function* (RBF) *Neural Network* (NN)-based adaptive PID (RBFNNPID) karena penyesuaian parameter PID tidak adaptif [45]. Selain itu pada penelitian lain yang dilakukakn oleh Hongbin Liu menggunakan *cascade MPC-PI controller* untuk pengurangan nitrogen dan ammonium pada *activated sludge process* [46]. Pada tesis ini menggunakan teknik optimisasi GA untuk meminimalkan COD *effluent* dari *activated sludge process*.

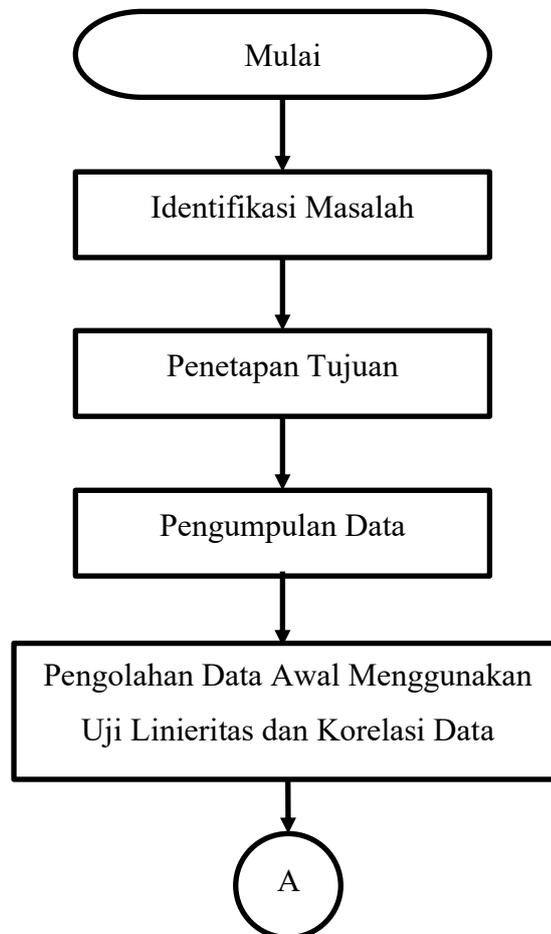
Hingga saat ini penelitian yang mengoptimisasi COD *effluent* dari *polishing unit* menggunakan model ANN dan teknik Optimisasi GA yang dapat memberikan variabel optimisasi kadar nitrat dan fosfat belum pernah dilakukan. Tesis ini akan mengoptimisasi COD *effluent* dengan menggunakan model MLPANN dan teknik optimisasi GA untuk memberikan kadar nitrat dan fosfat yang sesuai agar COD *effluent* minimum..

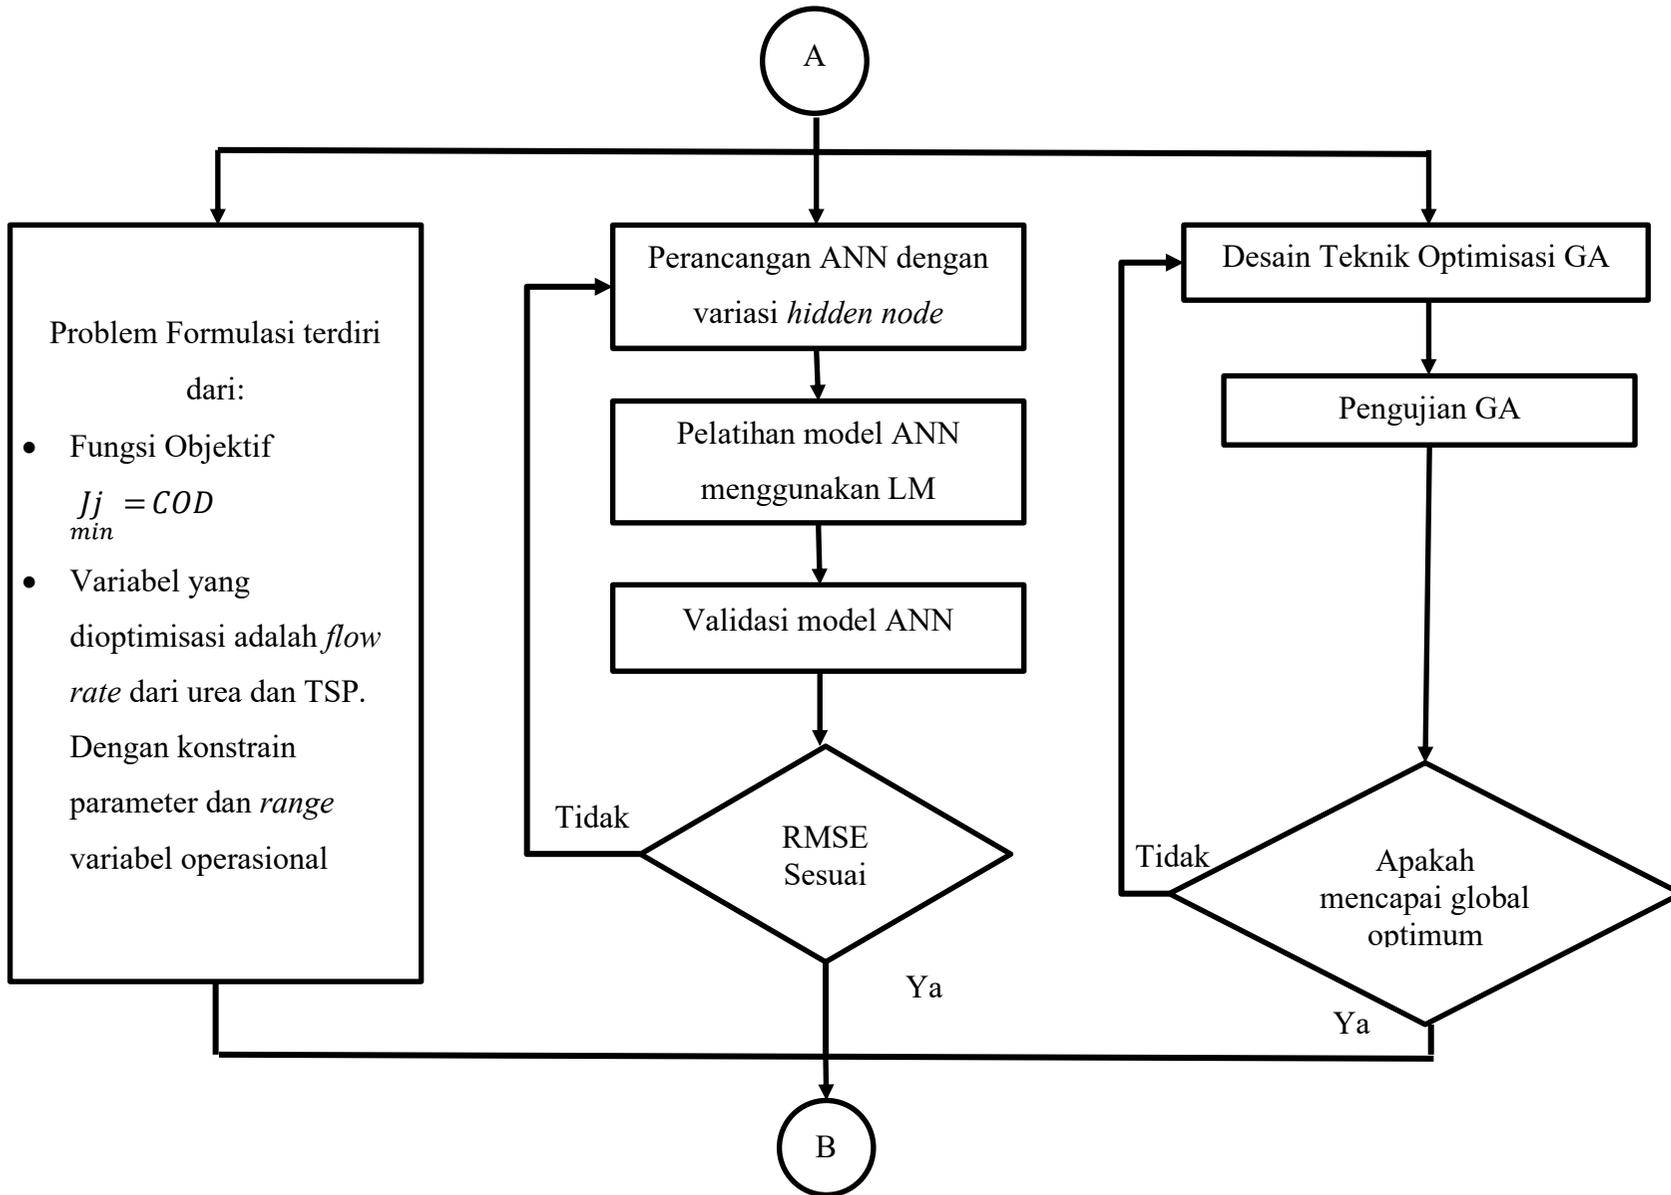
## BAB III

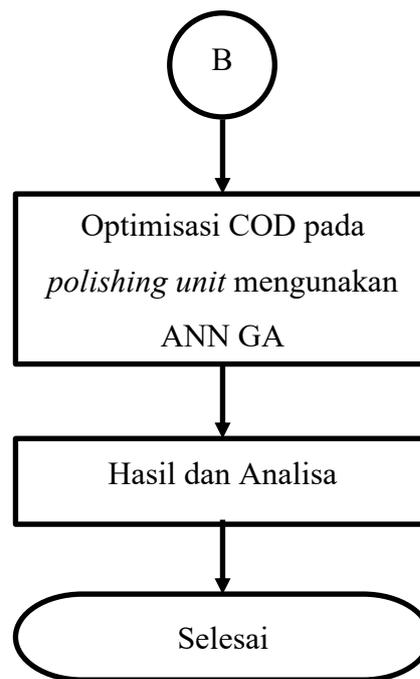
### METODOLOGI PENELITIAN

#### 3.1. Diagram Alir Penelitian

Pada tesis ini akan dilakukan optimisasi COD pada *polishing unit* Saka Indonesia Pangkah Limited. Optimisasi bertujuan untuk mengurangi kadar COD *effluent*. Untuk mencapai tujuan tersebut disusun langkah-langkah mulai dari identifikasi masalah hingga analisa hasil penelitian. Untuk mempermudah pembaca dalam memahami penelitian ini maka dibuatlah alur penelitian seperti Gambar 3.1.







**Gambar 3. 1** Alur Penelitian

Setiap langkah pada Gambar 3.1. alur penelitian akan dijelaskan pada tiap subbab berikut ini:

### 3.2. Identifikasi Masalah

Proses pada *polishing unit* adalah penurunan kadar COD agar sesuai dengan baku mutu limbah yang diperbolehkan untuk dibuang ke laut. Besar kadar COD maksimum yang diperbolehkan adalah 200 mg/L, akan tetapi kadar COD rata rata *produced water* yang dihasilkan dari produksi minyak dan gas pada Saka Indonesia Pangkah Limited adalah 706.84 mg/L. Hal ini menunjukkan bahwa perlu adanya proses pengolahan limbah agar kadar COD turun.

Penurunan kadar COD pada Saka Indonesia Pangkah Limited dilakukan pada *polishing unit*. Penurunan kadar COD pada *produced water* terjadi pada kolam aerasi yang terdapat bakteri aerob. Setelah diproses dalam waktu tertentu *produced water* kemudian dialirkan menuju *sedimentation tank* untuk diendapkan sehingga air dan bakteri dapat terpisah. Endapan bakteri dikembalikan ke kolam aerasi untuk digunakan kembali, sedangkan air yang sudah diolah, dialirkan menuju kolam penampungan sementara yang selanjutnya dibuang ke laut.

Kondisi real saat ini, pengambilan data dilakukan secara manual dengan melakukan analisa di laboratorium. Data MLSS dan SVI digunakan untuk melihat pertumbuhan dari bakteri. Ketika laju pertumbuhan bakteri terlalu rendah maka bakteri tidak dapat mengolah COD dengan baik. Sedangkan ketika laju pertumbuhan bakteri terlalu cepat bakteri akan terlalu cepat mati. Untuk mengatasi hal ini ada dua variabel yang bisa diatur yaitu kadar nitrat dan fosfat. Untuk variabel lain seperti *flowrate produced water*, temperatur dan pH nilainya tergantung dari kondisi *produced water* yang masuk ke dalam *polishing unit*. Ketika kadar dari nitrat kurang maka dilakukan penambahan urea sedangkan ketika kadar fosfat kurang maka dilakukan penambahan TSP.

### 3.3. Penetapan Tujuan

Berdasarkan identifikasi masalah tersebut ditarik sebuah tujuan untuk menyelesaikan masalah yang terjadi pada *polishing unit*. Hubungan antara variabel-variabel pada *polishing unit* terhadap COD *effluent* perlu dicari guna menemukan *input* yang sesuai untuk model ANN. Variabel yang memiliki koefisien korelasi sangat kuat dan kuat akan menjadi *input* dari model ANN.

Setelah didapatkan model ANN, pada tesis ini diambil tujuan yaitu untuk mencapai kadar COD optimal dengan melakukan optimisasi COD dengan mencari kadar nitrat dan fosfat yang paling sesuai untuk mendapat kadar COD paling minimal.

### 3.4. Pengumpulan Data

Pada tesis ini, *polishing unit* Saka Indonesia Pangkah Limited digunakan sebagai objek penelitian. Data yang dikumpulkan adalah variabel-variabel yang berpengaruh dalam proses pengolahan *produced water* yang masuk ke *polishing unit*. Data yang dikumpulkan adalah *flowrate*, pH, temperatur, *Total Suspended Solids* (TSS), *Total Dissolve Solid* (TDS), COD *influent*, MLSS, SV30, SVI, NO<sub>3</sub>, PO<sub>4</sub> dan COD *effluent*. Data yang dikumpulkan sejumlah 364 hari pengukuran. Data lapangan terlampir pada Lampiran 1. Keterangan lebih jelas dari kualitas data dapat dilihat pada Tabel 3.1.

**Tabel 3. 1** Data *polishing unit* Saka Indonesia Pangkah Limited

Variabel	Satuan	Minimum	Maximum	Mean	Std. Deviation
<i>Flowrate</i>	Bbls/Day	265.00	1011.00	762.1374	140.08
pH	-	6.66	8.25	7.52	0.26
Temperatur	°C	27.10	35.90	31.91	1.75
TSS	mg/L	33.00	220.00	82.3099	26.31
TDS	mg/L	10620.00	14690.00	13473.10	806.80
COD	mg/L	396.00	1606.00	728.18	183.08
MLSS	mg/L	460.00	984.00	764.27	81.37
SV30	-	54.00	140.00	98.48	17.02
SVI	-	75.00	228.00	128.85	18.36
NO3	mg/L	3.35	28.40	11.13	4.15
PO4	mg/L	2.50	29.30	7.72	3.43
COD <i>effluent</i>	mg/L	22.00	80.00	45.08	8.00

Dari Tabel 3.1 kemudian dianalisa nilainya mulai dari nilai minimum, maksimum, rata rata dan standar deviasinya untuk melihat sebaran dari data. Ketika data memiliki sebaran yang sempit atau bahkan konstan maka akan sulit untuk dilakukan pemodelan dengan ANN. Dari Tabel 3.1 dan Lampiran 1, semua data yang diperoleh terlihat cukup bervariasi untuk dijadikan data set pelatihan dan validasi ANN.

### 3.5. Pengolahan Data Awal

Data yang didapatkan dari *polishing unit* kemudian diuji menggunakan uji linieritas. Uji linieritas adalah salah satu uji asumsi klasik yang dilakukan untuk mengetahui sifat linier pada sebaran data antara variabel X dan Y. Hal ini dilakukan untuk mengetahui adakah sifat linier pada hubungan X dan Y yang akan mempengaruhi tingkat valid atau tidaknya model regresi yang dihasilkan. Uji linieritas dilakukan menggunakan *software IBM SPSS Statistics*.

Uji linieritas dengan membandingkan uji F dengan tabel F. Selanjutnya harga F yang diperoleh dibandingkan dengan harga F tabel. Jika harga  $F_{hitung} \leq F_{tabel}$ , maka korelasi antara variabel bebas dengan variabel terikat bersifat linier.

Sebaliknya, jika harga  $F_{hitung} > F_{tabel}$  maka korelasi antara variabel bebas dengan variabel terikat tidak linier [47].

Selain uji linieritas uji korelasi juga dilakukan. Uji korelasi adalah suatu pengujian untuk mengetahui tingkat korelasi antar variabel secara linier yang dinyatakan dalam bentuk koefisien korelasi ( $r^2$ ). Rentang nilai koefisien korelasi adalah 0 hingga 1. Semakin mendekati nilai 1, maka semakin erat hubungan antar variabel. Metode yang digunakan untuk menghitung koefisien korelasi adalah *Pearson Correlation* dengan persamaan koefisien korelasi pada persamaan (3.1) [48].

$$r = \frac{\sum(x_i - \bar{x}) \sum(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2} \sqrt{\sum(y_i - \bar{y})^2}} \quad (3.1)$$

dengan :

$r$  = koefisien korelasi variabel x dengan y

$x_i$  = data variabel x ke-i

$\bar{x}$  = rata-rata variabel x

$y_i$  = data variabel y ke-i

$\bar{y}$  = rata-rata variabel y

Pemilihan *input* dari ANN didasarkan pada besar koefisien korelasi. Nilai koefisien korelasi memiliki *range* antara 0-1. Koefisien korelasi yang memiliki tingkat hubungan kuat dan sangat kuat dipilih untuk menjadi *input* dari ANN. Standar dalam memberikan pernyataan terhadap koefisien korelasi dapat dilihat pada Tabel 3.2.

**Tabel 3. 2** Tingkat Hubungan Berdasarkan Koefisien Korelasi [49]

Koefisien Korelasi	Tingkat Hubungan
0,00 – 0,199	Sangat rendah atau tidak berpengaruh
0,20 – 0,399	Rendah
0,40 – 0,599	Sedang
0,60 – 0,799	Kuat
0,80 – 1,000	Sangat kuat

### 3.6. Problem Formulasi

*Key Performance Indicator* (KPI) pada *Waste Water Treatment* (WWT) yang mengolah *produced water* pada *polishing unit* adalah *COD effluent*. Sehingga *COD effluent* ini dijadikan sebagai tujuan yang harus dicapai atau fungsi objektif. *COD effluent* yang minimum adalah kondisi yang harus dicapai dalam optimisasi ini. Fungsi objektif ini dapat ditulis seperti pada persamaan 3.2 [16].

$$J_{min} = COD = \frac{\text{Massa oksige yang diperlukan}}{\text{Massa substrat yang diperlukan}} \quad (3.2)$$

Dari fungsi objektif diatas, *COD effluent* minimum akan diperoleh ketika massa substrat maksimal dan massa oksigen yang diperlukan adalah minimal atau kadar *COD influent* yang rendah. Massa substrat yang maksimal memiliki batasan tertentu tergantung kepada *COD* larutan yang akan diolah. Sehingga optimisasi diperlukan.

Ketidakpastian kadar *COD effluent* pada optimisasi ini dipengaruhi oleh 11 variabel *input* yaitu *flowrate* air, kadar pH air, temperatur air, TSS, TDS, *COD influent*, MLSS, SV30, SVI, nitrat dan fosfat. Berdasarkan PFD dan diskusi dengan manajemen, diputuskan bahwa variabel yang dioptimisasi adalah kadar nitrat dan fosfat yang akan menjadi *set point* pengendalian *flow rate* urea dan TSP. Sedangkan variabel lainnya yang ditetapkan berdasarkan hasil pengukuran di laboratorium, akan menjadi parameter pada model ANN dan menjadi konstrain pada optimisasi *COD effluent*. Fungsi kendala dari variabel *flowrate* air, kadar pH air, temperatur air, TSS, TDS, *COD influent*, MLSS, SV30 dan SVI memiliki range tertentu sesuai dengan hasil pengambilan data.

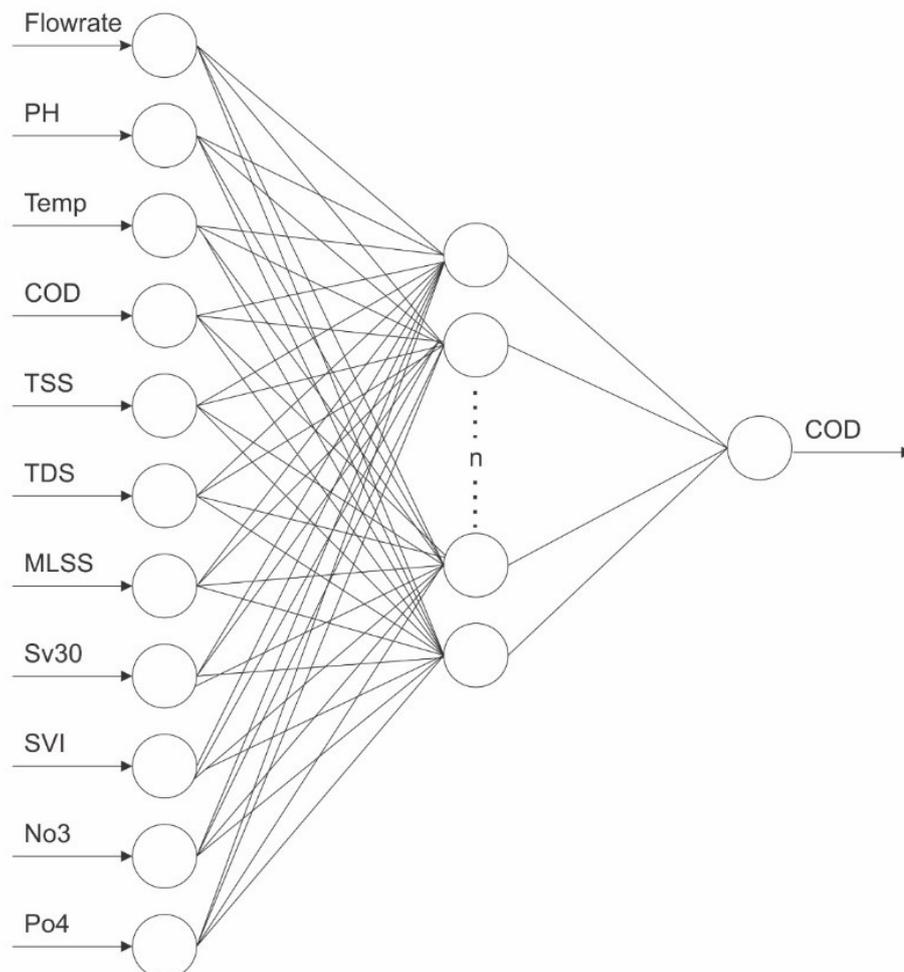
### 3.7. Pemodelan dan Validasi ANN

Seperti diutarakan pada subbab sebelumnya, *COD* dipengaruhi oleh banyak parameter dan variabel yang hubungannya sangat kompleks dan hanya bisa ditentukan dengan rumus empiris dan *black box model*. Oleh karena itu ANN sebagai *black box model* dipergunakan untuk memodelkan hubungan yang

kompleks dan non linier antara COD dengan variabel dan parameter yang mempengaruhinya.

Variabel yang digunakan berdasarkan *input* ANN ada 11 variabel *input* yaitu *flowrate* air, kadar pH air, temperatur air, TSS, TDS, COD *influent*, MLSS, SV30, SVI, nitrat dan fosfat. Sedangkan outputnya adalah kadar dari COD *effluent* dari *polishing unit* seperti pada Gambar 3.2.

Parameter dan variabel yang mempengaruhi COD *effluent* akan menjadi *input* pada ANN, sedangkan outputnya adalah COD *effluent*. Dimana COD *effluent* akan menjadi fungsi objektif, dua variabel *input* menjadi variabel yang dioptimisasi sedangkan parameter dan *range input-output* model sebagai konstrain pada optimisasi ini.



**Gambar 3. 2** Struktur Dari ANN

Hubungan COD *effluent* dan variabel *input* pada ANN yang kompleks dan non linier, ditambah lagi model yang digunakan yaitu ANN yang tidak mempunyai fungsi derivatif, maka keberadaan teknik optimisasi stokastik diperlukan.

Karena hubungan dari COD *effluent* dengan variabel yang mempengaruhinya non linier dan sangat kompleks, sulit untuk dilakukan pemodelan menggunakan rumus matematis. Untuk memperoleh hubungan COD *effluent* digunakan model ANN yang dapat mengetahui kadar COD *effluent* dengan nilai variabel-variabel yang dimasukkan. Output ANN berupa COD dan Input ANN adalah variabel yang mempengaruhinya.

ANN digunakan sebagai prediksi kadar dari COD *effluent* dari *polishing unit* sehingga nantinya akan didapatkan model. Selanjutnya dilakukan Optimisasi COD *effluent* dari *polishing unit* dengan cara mengontrol kadar nitrat dan fosfat menggunakan model yang didapat dari ANN menggunakan metode optimisasi GA.

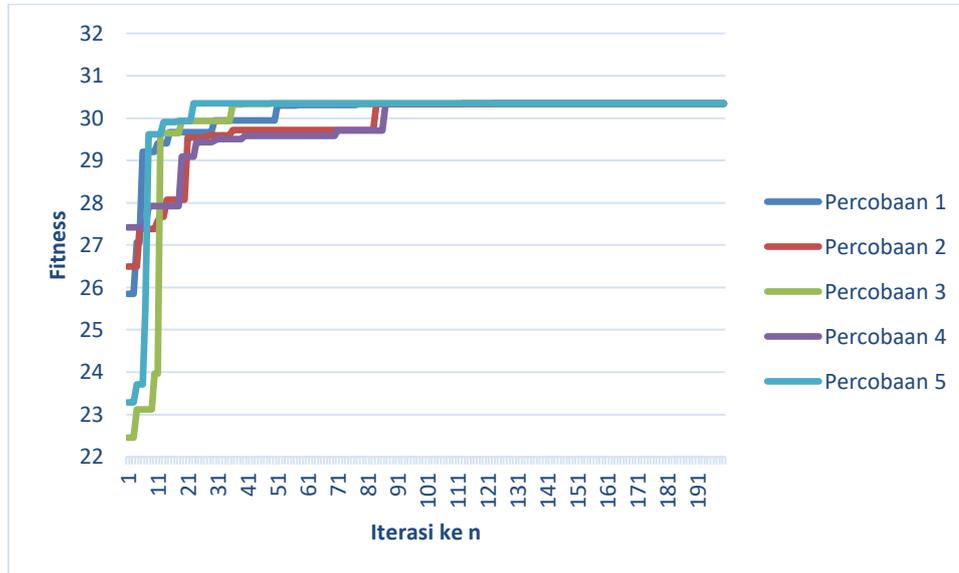
### 3.8. Desain Teknik Optimisasi GA

Teknik optimisasi terdiri dari teknik optimisasi stokastik dan deterministik. Teknik optimisasi deterministik bekerja berdasarkan turunan dari persamaan yang dioptimisasi, sedangkan teknik optimisasi stokastik tidak menggunakan turunan dari persamaan melainkan bekerja *random* sesuai *coding* yang dipakai. Salah satu teknik optimisasi stokastik yang banyak digunakan adalah GA. GA sebagai teknik optimisasi stokastik belum tentu bisa mencapai global optimum bila parameter GA sebagai *optimizer* belum ditetapkan secara layak.

Untuk mengetahui kebenaran suatu algoritma perlu dilakukan pengujian kebenaran dari algoritma tersebut. Sehingga uji algoritma dilakukan dengan cara mencoba algoritma tersebut dengan fungsi yang memiliki nilai maksimal yang sudah diketahui. Fungsi diambil dari publikasi penelitian sebelumnya tentang teknik optimisasi *Duelist Algorithm* yang dibandingkan dengan beberapa metode optimisasi lainnya [50]. Persamaan tersebut adalah persamaan 3.3.

$$f = - \left( \sqrt{x^2 + y^2 * \cos(x - y) * e^{\cos((x*(y+5)/7))}} \right) \quad (3.3)$$

Setelah melakukan 5 kali percobaan, hasilnya menunjukkan nilai yang sama dan sesuai dengan nilai yang ada pada *paper* sebelumnya. Grafik hasil uji algoritma ditunjukkan pada Gambar 3.3. Karena hasil dari uji memiliki nilai yang sudah sesuai maka disimpulkan bahwa *coding* algoritma optimisasi GA ini sudah bisa dipakai sebagai *optimizer* pada kasus optimisasi ini.



Gambar 3. 3 Uji Algoritma GA

### 3.9. Optimisasi Kadar COD pada *Polishing Unit*

Telah dijelaskan di subbab sebelumnya tentang problem formulasi yang berisi penentuan fungsi objektif, konstrain dan variabel yang dioptimisasi, model ANN dengan input variabel yang dioptimisasi dan output akan menjadi fungsi objektif syarat kesiapan teknik optimisasi GA sebagai *optimizer* yang akan mencari COD *effluent* minimum dalam kasus ini, maka pada subbab ini ketiga komponen optimisasi akan disatukan untuk memecahkan permasalahan optimisasi COD pada *polishing unit*.

Seperti diutarakan sebelumnya, GA tidak akan mendapatkan global optimum bila belum diberi parameter optimisasi yang layak. Untuk mendapatkan COD *effluent* yang optimal, GA dirancang untuk mencari variabel optimisasi kadar nitrat dan fosfat yang paling sesuai. Kedua variabel ini akan dioptimisasi dengan jumlah bit sebanyak 20 untuk setiap variabel dengan total populasi sebanyak 200.

Parameter GA pada penelitian menggunakan elitisme sebesar 5% sehingga ada 5% kromosom yang memiliki nilai fitness paling optimum akan dipilih, probabilitas *crossover* ( $P_c$ ) pada penelitian ini sebesar 0,9 sehingga akan ada 90% gen yang mengalami kawin silang dan probabilitas mutasi ( $P_m$ ) sebesar 0.005 sehingga ada 0.5% dari seluruh gen dalam kromosom yang akan mengalami mutasi. Dengan melakukan iterasi sebanyak 200 kali menggunakan software Matlab 2018. Parameter tersebut dapat diubah untuk memberikan hasil optimisasi lebih baik. Sehingga parameter dan variabel tersebut dapat diganti lebih besar atau lebih kecil dari yang ditetapkan dengan batasan tertentu. Parameter dan Variabel GA dirangkum dalam Tabel 3.3.

**Tabel 3. 3** Parameter dan Variabel GA

<b>Parameter dan Variabel</b>	<b>Nilai</b>
Populasi	200
Iterasi	200
Elitisme	0.05
Probabilitas <i>Crossover</i>	0.9
Probabilitas Mutasi	0.005
Jumlah Variabel Desain yang Dioptimasi	2
Jumlah Bit	40

### **3.10. Analisis Hasil dan Pembahasan serta kesimpulan**

Dari data-data yang didapatkan kemudian diolah sesuai dengan langkah langkah yang sudah dirancang. Hasil dari pengolahan data tersebut kemudian dianalisa linieritasnya data, korelasi dan sensitivitas variabel-variabel terhadap COD *effluent*. Sehingga input dari model ANN dan variabel yang akan dioptimisasi didapatkan.

Penentuan model ANN dengan memilih *hidden node* yang menghasilkan RMSE pelatihan dan validasi yang paling rendah, untuk menjamin model cukup terlatih. Setelah semua komponen optimisasi dibuat dan dianalisa, maka optimisasi

COD pada *polishing unit* bisa dilakukan dan dianalisa hasilnya sehingga dapat disimpulkan berdasarkan tujuan penelitian ini.

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1. Pengujian Data pada Pengolahan Data Awal

##### 4.1.1. Uji linieritas

Hasil uji linieritas COD *effluent polishing unit* dengan variabel yang mempengaruhi dihitung menggunakan *software IBM SPSS Statistics*. Hasil hitung dapat dilihat pada Tabel 4.1. Ketikan nilai  $F_{hitung}$  lebih kecil dari pada  $F_{tabel}$  dan Nilai *Sig. Deviation* lebih besar dari pada 0.05 maka hubungan COD *effluent* dengan variabel yang mempengaruhinya linier sedangkan sebaliknya jika  $F_{hitung}$  lebih besar dari pada  $F_{tabel}$  dan nilai *Sig. Deviation* lebih kecil dari pada 0.05 maka hubungan COD *effluent* dengan variabel yang mempengaruhinya non linier. [47]

**Tabel 4. 1** Hasil Uji linieritas

Variabel	Perbandingan F Hitung dan F tabel	Nilai <i>Sig. Deviation</i>
<i>Flowrate out</i>	208.329 > 1.286	0.001
pH	185.112 > 1.303	0.001
Temperature	142.609 > 1.295	0.001
TSS	162.658 > 1.286	0.001
TDS	568.390 > 1.290	0.001
COD	40.844 > 1.421	0.001
MLSS	360.692 > 1.306	0.001
SV30	23.381 > 1.379	0.001
SVI	60.371 > 1.333	0.001
NO3	41.556 > 1.278	0.001
PO4	74.009 > 1.304	0.001

Tabel 4.1 menunjukkan bahwa semua variabel memiliki nilai *Sig. Deviation* 0.001 atau kurang dari 0.05 dengan semua nilai  $F_{hitung}$  lebih besar dari pada  $F_{tabel}$ . Sehingga dapat ditarik kesimpulan bahwa semua variabel memiliki hubungan yang non linier dengan COD *effluent*, sehingga pemodelan yang paling sesuai adalah

menggunakan ANN. Karena ANN dapat memodelkan suatu proses yang kompleks dan non linier tanpa mengetahui hubungan input output dari variabelnya.

#### 4.1.2. Uji Korelasi

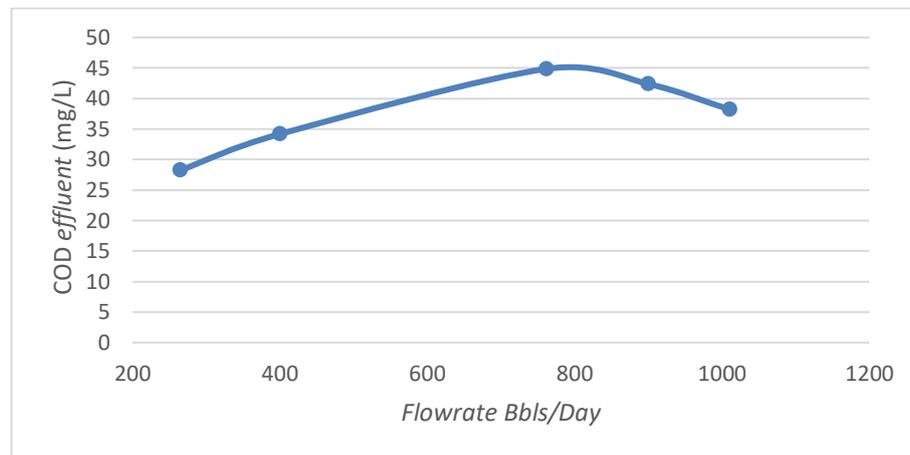
Uji korelasi dilakukan dengan menggunakan *software* IBM SPSS *Statistics* untuk mengetahui hubungan antara COD *effluent* dengan variabel lainnya. Uji korelasi digunakan untuk menyeleksi apakah variabel yang diuji dapat digunakan untuk masukan dari ANN untuk memprediksi kadar COD *effluent*. Hasil dari uji korelasi dapat dilihat dari Tabel 4.2.

**Tabel 4. 2** Hasil Uji Korelasi Nilai  $r^2$

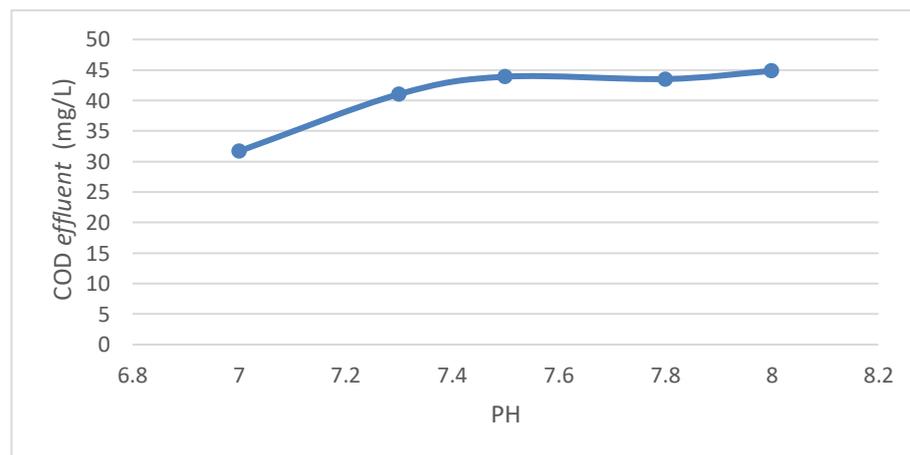
Variabel	Uji Korelasi Terhadap COD <i>effluent polishing unit</i>
COD <i>influent</i>	0.968
SVI	0.957
NO3	0.94
PO4	0.928
SV30	0.911
Temperature	0.864
pH	0.851
TSS	0.84
<i>Flowrate</i>	0.827
MLSS	0.822
TDS	0.744

Tabel 4.2 menunjukkan bahwa nilai koefisien korelasi antara COD *effluent* dari *polishing unit* dengan variabel input lainnya sangat berkorelasi sesuai dengan Tabel 3.1. Pada Tabel 4.2 menunjukkan bahwa semua data berada pada kondisi sangat kuat berkorelasinya kecuali TDS yang masuk kategori kuat, sehingga 11 variabel tersebut dapat digunakan sebagai input dari *modeling* ANN. Hasil uji korelasi menunjukkan bahwa COD *influent* memiliki korelasi tertinggi dengan COD *effluent* yaitu sebesar 0.968. Sedangkan TDS memiliki korelasi paling rendah dengan COD *effluent* yaitu sebesar 0.744.

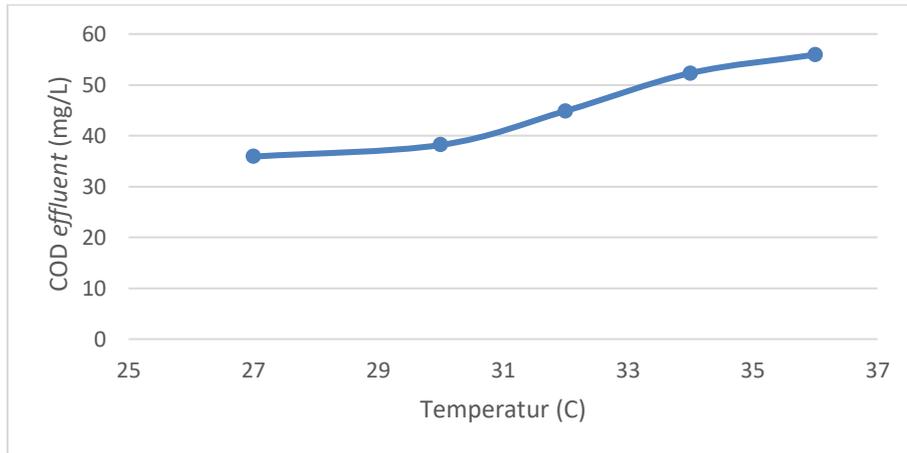
Selain koefisien korelasi yang menyatakan seberapa besar pengaruh variabel lain terhadap COD *effluent*, perlu dilihat lebih detail mengenai sensitivitas variabel tersebut pada *range* variabel yang dikaji. Dari uji sensitivitas dengan mensimulasikan hubungan antara COD *effluent* dengan setiap variabel ketika variabel lain bernilai rata rata. Didapatkan hasil seperti pada Gambar 4.1 hingga 4.11.



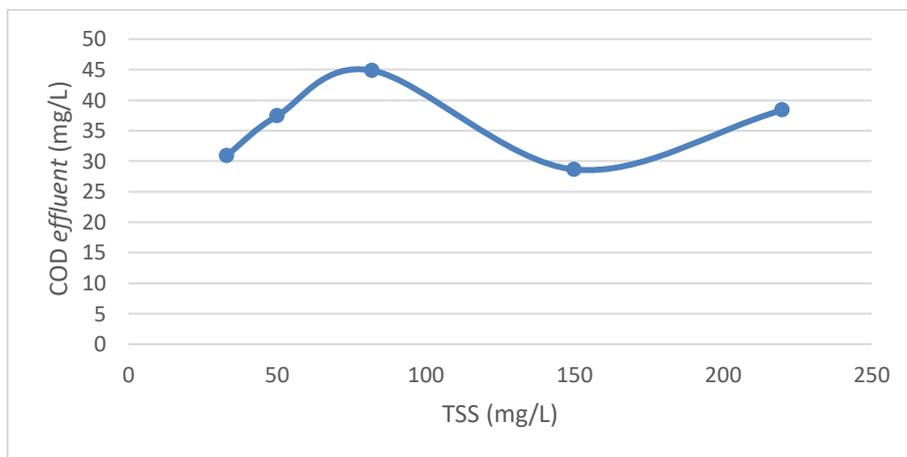
**Gambar 4. 1** Sensitivitas *flowrate produce water* terhadap COD *effluent*.



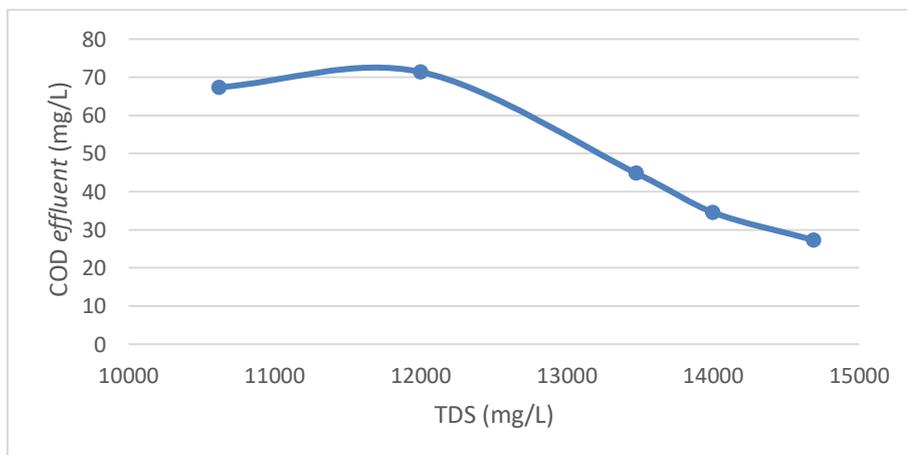
**Gambar 4. 2** Sensitivitas *pH produce water* terhadap COD *effluent*.



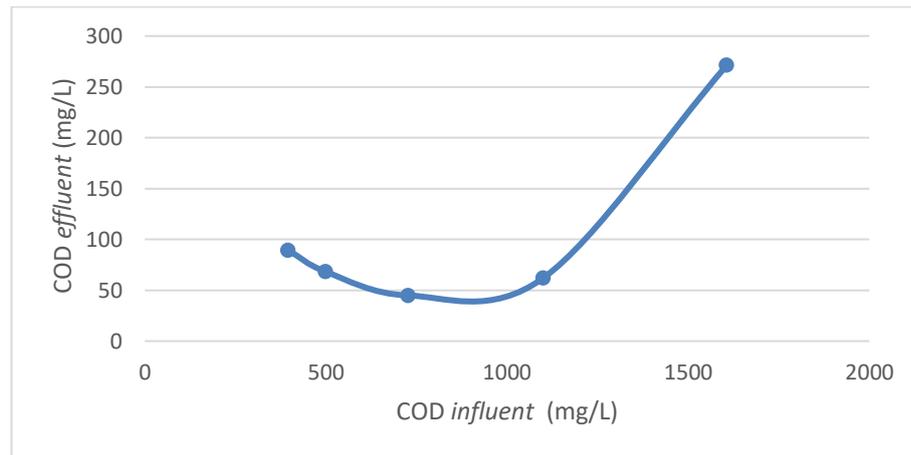
**Gambar 4. 3** Sensitivitas temperatur *produce water* terhadap COD *effluent*.



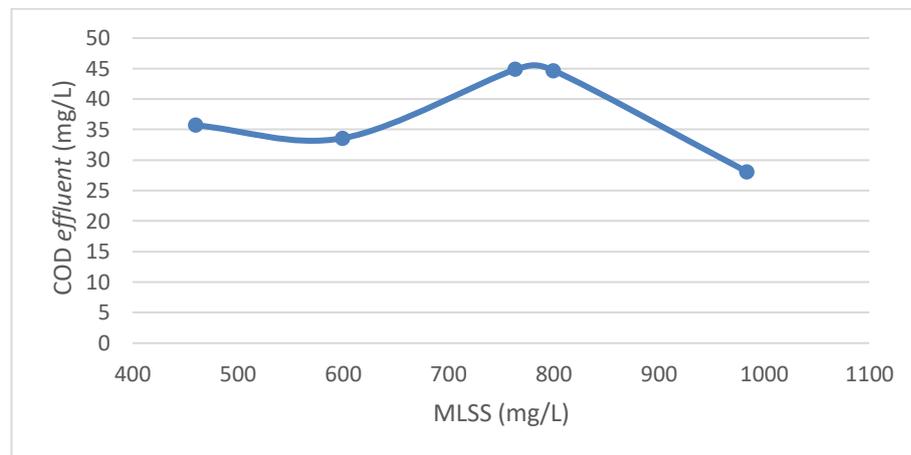
**Gambar 4. 4** Sensitivitas TSS *produce water* terhadap COD *effluent*.



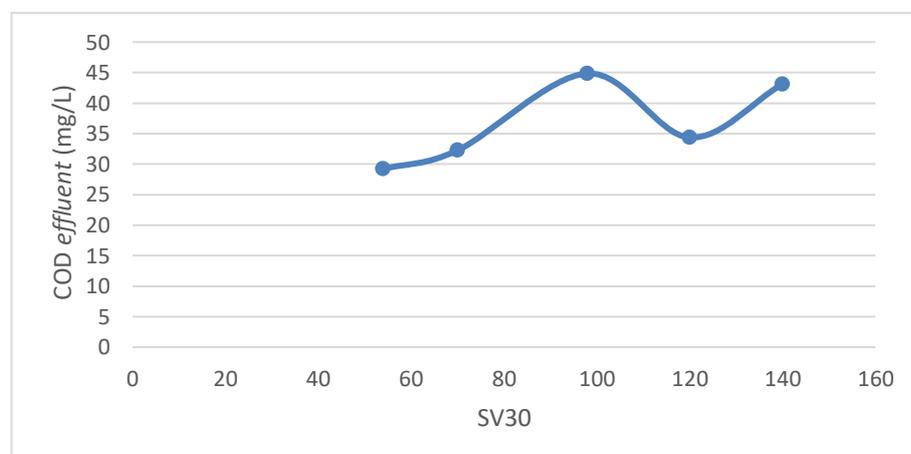
**Gambar 4. 5** Sensitivitas TDS *produce water* terhadap COD *effluent*.



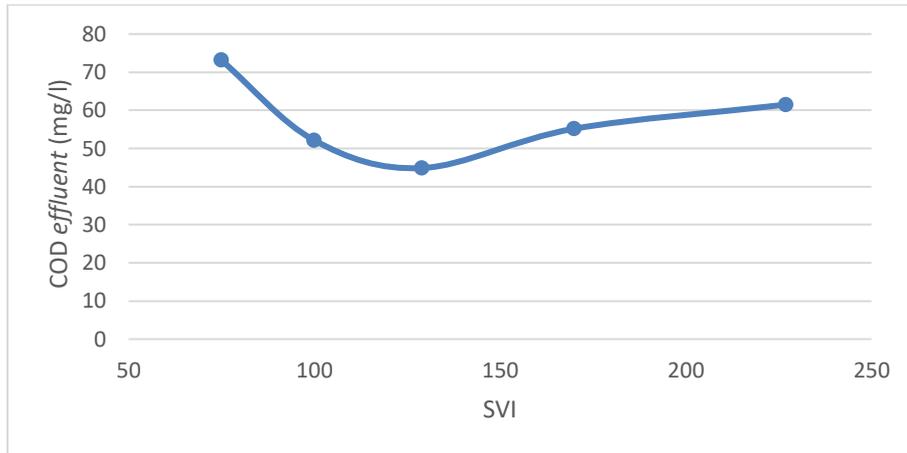
**Gambar 4. 6** Sensitivitas COD *influent produce water* terhadap COD *effluent*.



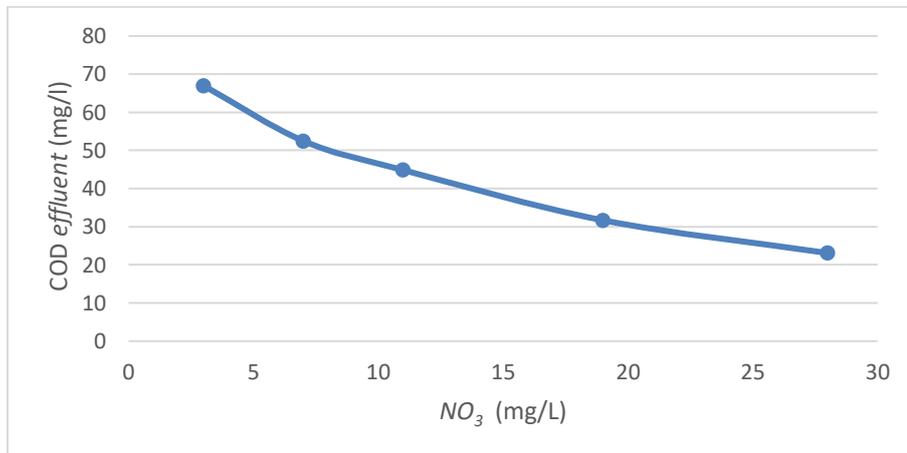
**Gambar 4. 7** Sensitivitas MLSS terhadap COD *effluent*.



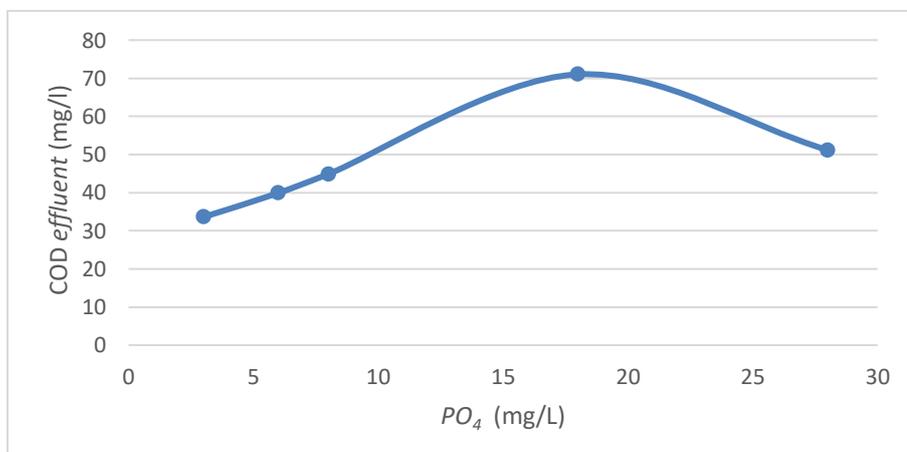
**Gambar 4. 8** Sensitivitas SV30 terhadap COD *effluent*.



**Gambar 4. 9** Sensitivitas SVI terhadap COD *effluent*.



**Gambar 4. 10** Sensitivitas NO<sub>3</sub> terhadap COD *effluent*.



**Gambar 4. 11** Sensitivitas PO<sub>4</sub> terhadap COD *effluent*.

Gambar 4.1 menunjukkan hubungan COD *effluent* dengan *flowrate produced water* yang masuk dalam *polishing unit*, semakin besar *flowrate* yang masuk maka semakin besar kadar COD *effluent* yang dihasilkan akan tetapi pada nilai *flowrate* tertentu ketika *flowrate* naik akan menyebabkan COD *effluent* yang dihasilkan turun.

Gambar 4.2 dan 4.3 menunjukkan hubungan COD *effluent* dengan pH dan temperatur *produced water* yang masuk dalam *polishing unit*, semakin besar pH dan temperatur yang masuk maka semakin besar kadar COD *effluent* yang dihasilkan.

Gambar 4.4, 4.7 dan 4.8 menunjukkan hubungan COD *effluent* dengan TSS, MLSS dan SV30 dalam *polishing unit*, TSS, MLSS dan SV30 tidak dapat diamati polanya karena grafik yang dihasilkan dari hubungannya dengan COD *effluent* naik turun.

Gambar 4.5 menunjukkan hubungan COD *effluent* dengan TDS dalam *polishing unit*, semakin TDS maka semakin kecil kadar COD *effluent* yang dihasilkan.

Gambar 4.6 menunjukkan hubungan COD *effluent* dengan COD *influent* memiliki sensitivitas yang tinggi. Karena dengan memberikan COD *influent* maksimal yaitu 1606 mg/L akan menyebabkan perubahan COD *effluent* sebesar 271 mg/L. Sedangkan baku mutu maksimal untuk kadar COD *effluent* yang diperbolehkan untuk dibuang ke laut adalah 200 mg/L. Akan tetapi kadar COD *influent* tidak dapat dikendalikan. Sehingga variabel lain yaitu nitrat dan fosfat harus dikendalikan untuk menjaga agar COD *effluent* yang keluar dari *polishing unit* tidak melebihi dari baku mutu yang sudah ditetapkan.

Kadar dari nitrat dan fosfat memiliki hubungan yang berbanding terbalik dengan COD *effluent*, ketika kadar nitrat dan fosfat dinaikan maka akan menyebabkan kadar COD *effluent* akan turun, hal tersebut dapat dilihat pada grafik Gambar 4.10 dan Gambar 4.11. Dari grafik juga dapat dilihat pada batasan tertentu kenaikan kadar fosfat tidak akan mempengaruhi dari COD *effluent* karena substrat yang dibutuhkan oleh bakteri memiliki batasan.

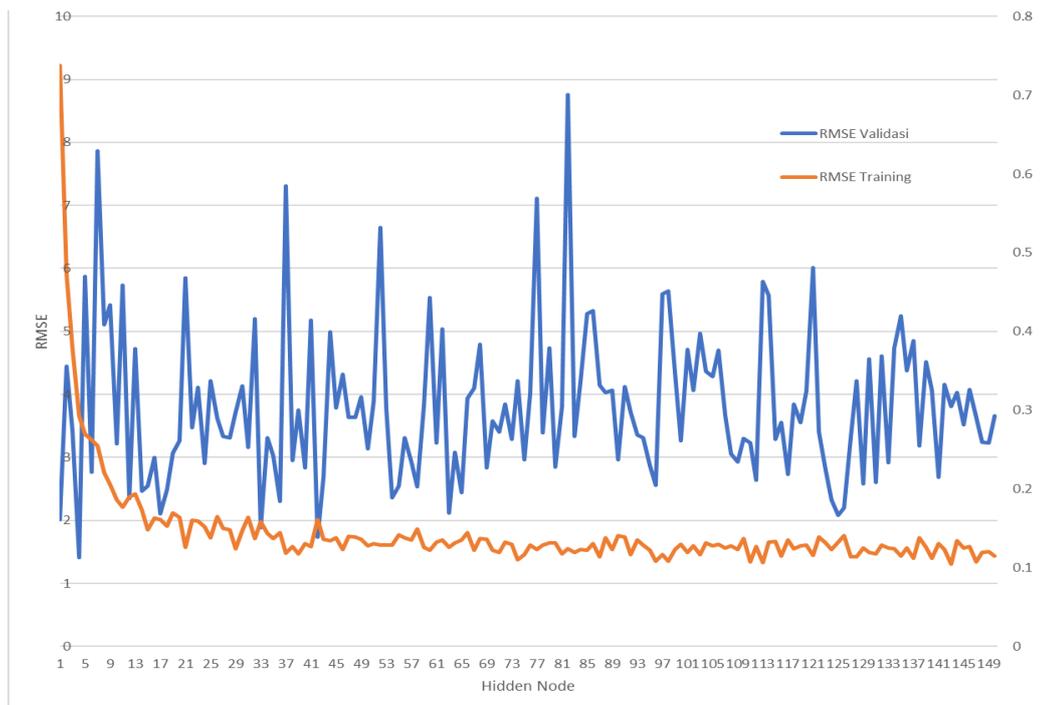
#### 4.2. Pelatihan dan Vaidasi Model ANN

Pelatihan ANN dilakukan dengan 300 data yang ada untuk menentukan bobot pada struktur MLP *Neural Networks* dengan *Finite Impulse Response* (FIR), yang akan digunakan sebagai pemodelan untuk memprediksi COD *effluent* pada *polishing unit*. Algoritma pembelajaran Levenberg Marquardt digunakan untuk mengoptimalkan bobot jaringan. Kinerja *Neural Network* dinyatakan oleh RMSE. Semakin kecil nilai RMSE, semakin baik kinerja *Neural Network*.

Validasi dari model ANN dilakukan dengan 64 data sisa dari data latihan. Ketika hasil dari simulasi memiliki nilai RMSE kecil maka simulasi dianggap sesuai. Akan tetapi apabila nilai RMSE besar maka hasil simulasi dianggap tidak sesuai. Sehingga perlu adanya perbaikan dalam simulasi yang dilakukan dengan memberikan variasi dari *hidden node*. Validasi ini diperlukan untuk memastikan model tidak *under learning* dan *over learning*.

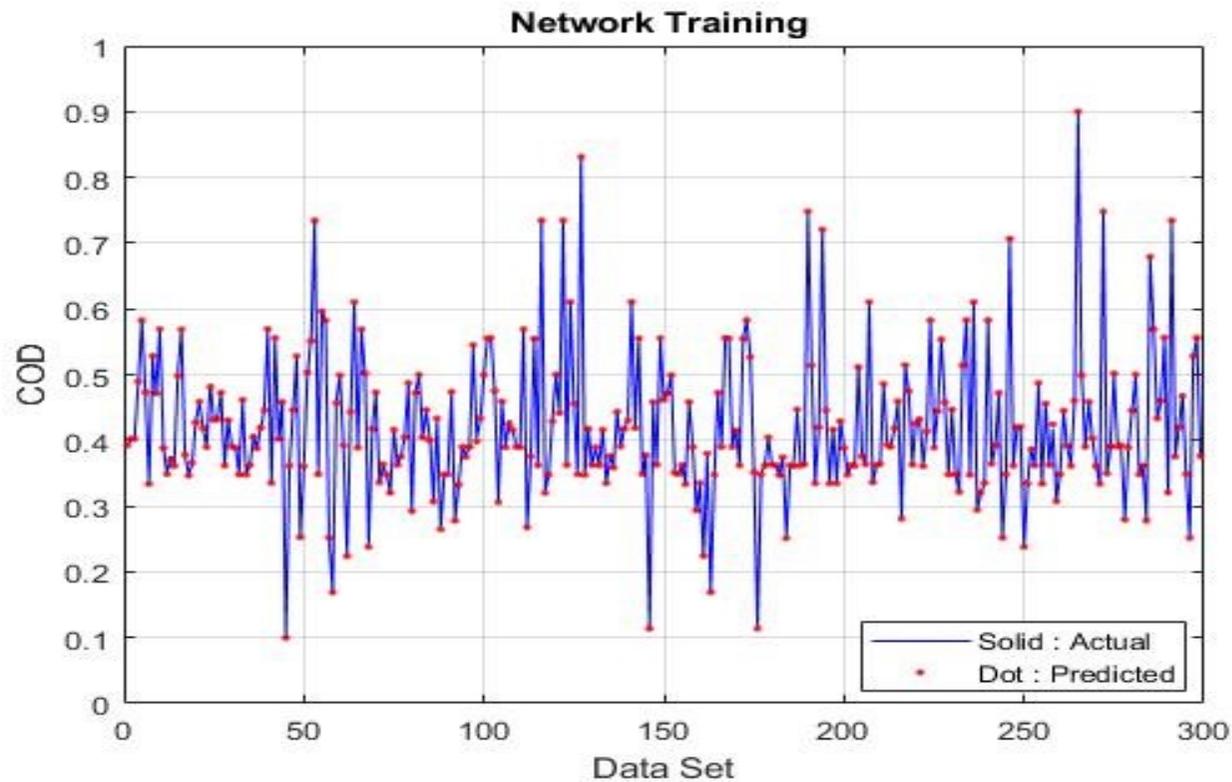
Pada Tesis ini, dilakukan perubahan jumlah *hidden node* dari 1 hingga 150. Variasi *hidden node* yang dilakukan bertujuan untuk mendapatkan *hidden node* mana yang memiliki RMSE paling rendah.

Dari Gambar 4.12 hasil RMSE paling optimal berada pada *hidden node* 42. Setelah model didapatkan maka model tersebut digunakan untuk mengoptimisasi nilai COD *effluent* dengan memberikan kadar nitrat dan fosfat paling sesuai dengan metode optimisasi GA.



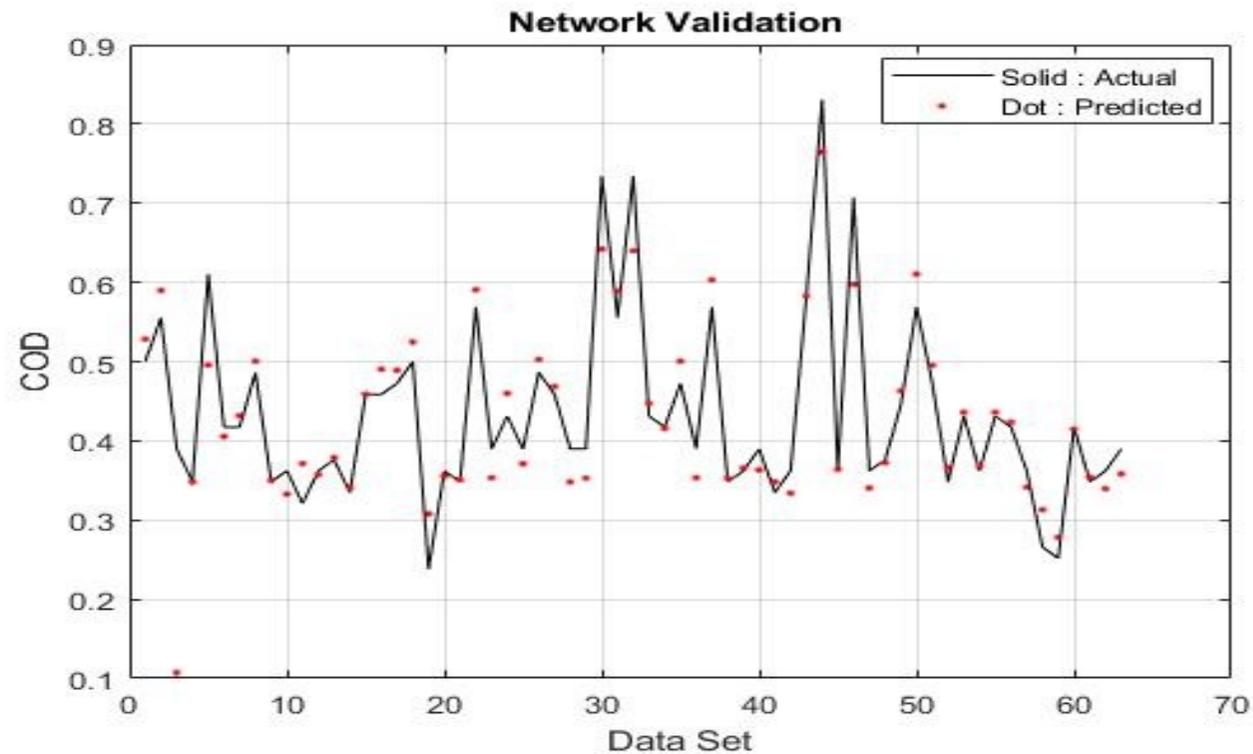
**Gambar 4. 12** RMSE ANN pada *hidden node* 1 sampai 150.

Gambar 4.13 adalah grafik data dan hasil prediksi ANN pada tahap pelatihan menggunakan *hidden node* 42. Gambar 4.13 menunjukkan hasil pemodelan yang dilatih dalam memprediksi COD *effluent* dalam fase latihan untuk prediksi COD *effluent*. Sedangkan untuk data hasil validasi dalam prediksi COD *effluent* ditunjukkan oleh Gambar 4.14. Secara umum, COD *effluent* yang diprediksi oleh model ANN dalam penelitian ini sangat mendekati nilai sebenarnya. Secara umum, pemodelan menggunakan ANN MLP dengan struktur FIR dapat memprediksi *output* dari parameter *input* yang yang kompleks dan non linier.



**Gambar 4. 13** Hasil pelatihan ANN dalam memprediksi COD *effluent*

Gambar 4. 13 menunjukkan 300 data yang dilatih pada ANN dengan *hidden node 42*. Garis biru merupakan nilai yang sebenarnya dari data sedangkan titik merah merupakan hasil prediksi dari model. Pada proses pelatihan didapatkan RMSE pada *hidden node 42* sebesar 0.16092.

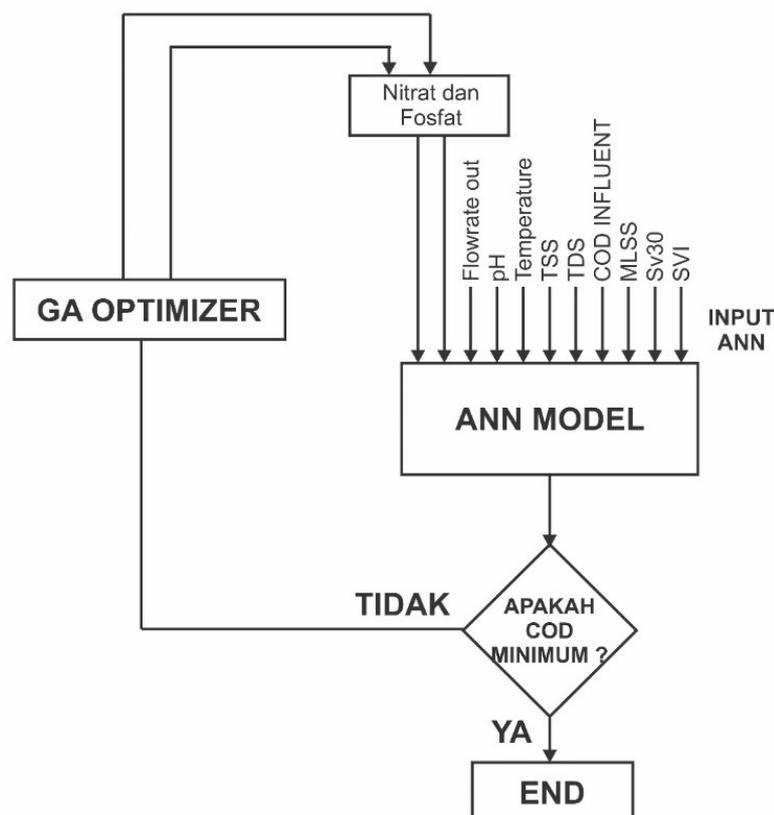


**Gambar 4. 14** Hasil Prediksi COD *effluent*

Agar model tidak *over learning* maka model harus divalidasi menggunakan data yang tidak digunakan dalam pelatihan. Gambar 4. 14 menunjukkan 64 data pada tahap validasi. Garis hitam merupakan nilai yang sebenarnya dari data sedangkan titik merah merupakan hasil prediksi dari model. Terlihat bahwa nilai prediksi tidak terlalu jauh dengan nilai sebenarnya dengan RMSE validasi sebesar 1.73769.

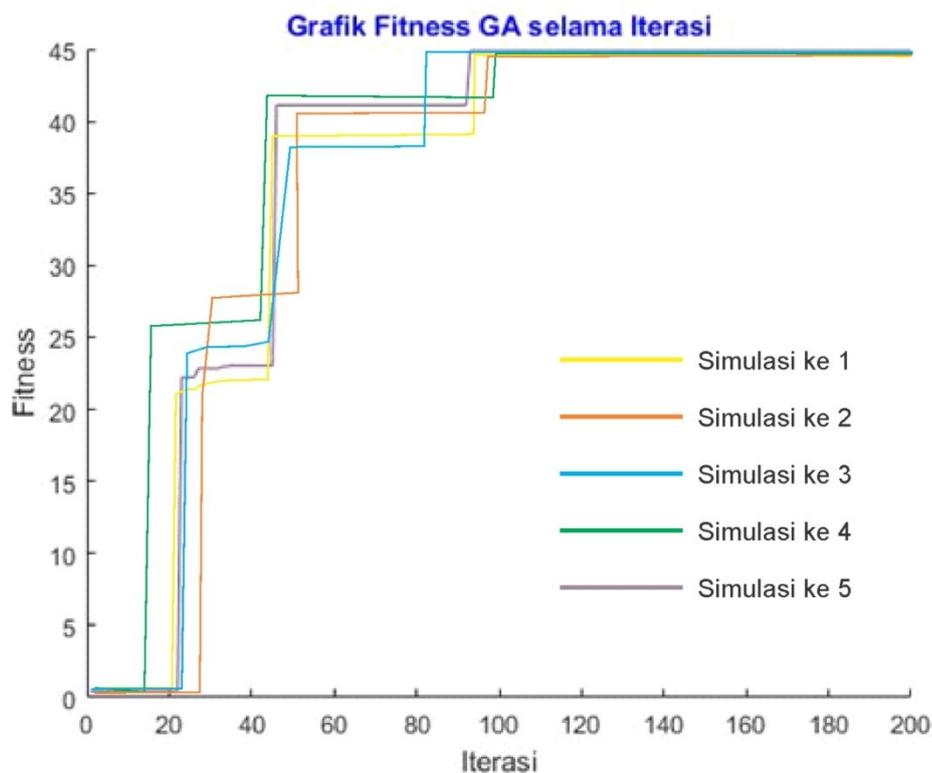
### 4.3. Optimisasi COD pada Polishing Unit Menggunakan ANN dan GA

Skematik diagram dari optimisasi ini dapat dilihat pada Gambar 4.15. Pada simulasi ini *optimizer* GA akan mengenerate massa nitrat dan fosfat dalam jumlah 200 buah atau 200 individu. Semua kombinasi nitrat dan fosfat akan menjadi *input* ANN bersama parameter operasional yang telah ditetapkan terlebih dahulu dari kondisi proses. Variabel dan parameter tersebut akan menjadi *input* ANN dan ANN akan memprediksi nilai COD pada *polishing unit*. *Output* hasil prediksi ANN akan direpresentasikan menjadi *fitness* pada GA. *Fitness* ini akan di proses elitisme sebanyak 5%, lalu sisanya yang 95% akan mengalami proses perkawinan dengan PC sebesar 90%. Anak dari hasil perkawinan akan dimutasi sebesar 0.5% dan menghasilkan individu baru sebesar 95%. Individu baru ini akan ditambah dengan 5% individu elit yang tidak dikawinkan dan dimutasi menjadi 100% atau 200 individu baru pada generasi berikutnya. Begitu proses optimisasi berlangsung sampai akhir generasi yaitu 200 generasi.



**Gambar 4. 15** Skematik Diagram Optimisasi COD pada *Polishing Unit*

Optimisasi ini diulang sebanyak 5 kali untuk memastikan hasil global optimum yang dicapai sama. Gambar 4.16 menunjukkan hasil 5 kali pengulangan simulasi yang diplot dalam satu grafik dengan warna garis yang berbeda. Grafik tersebut menunjukkan bahwa hasil optimisasi memiliki global optimum yang sama untuk 5 kali pengulangan simulasi.



**Gambar 4. 16** Hasil Optimisasi COD Menggunakan GA

Dalam penelitian ini, global optimum sudah diperoleh sebelum iterasi mencapai 200. Tetapi untuk berjaga jaga agar tidak terjebak pada lokal optimum, penelitian ini menggunakan iterasi maksimum 200 untuk memperlihatkan global optimum. Dari hasil simulasi didapatkan nilai COD optimal yaitu 44.8668 mg/L. Dengan kadar nitrat paling sesuai sebesar 9 mg/L sedangkan kadar fosfat paling sesuai sebesar 12 mg/L.

*Halaman ini sengaja dikosongkan*

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1. Kesimpulan

Kesimpulan yang bisa diambil dari penelitian ini adalah

1. Hubungan COD dengan 11 variabel proses sangat kompleks dan non linier dengan ditunjukkan dari grafik sensitifitas dan nilai *Sig. Deviation* lebih kecil dari pada 0.05 yaitu 0.001. Dari semua variabel tersebut menunjukkan hubungan yang kuat ditunjukkan dengan koefisien korelasi antara 0.744 sampai 0.968.
2. Optimisasi kadar COD *effluent* pada *polishing unit* agar sesuai baku mutu adalah dengan cara mengatur kadar nitrat dan fosfat dengan mempertimbangkan 9 parameter proses lainnya yang mempengaruhi COD *effluent* pada *polishing unit*. Nilai dari kadar nitrat dan fosfat didapat dari prediksi model ANN yang dibangun dari stuktur MLP FIR. Hasil simulasi ANN mendapatkan hasil RMSE paling optimal berada pada *hidden node* 42 dengan nilai RMSE selama pelatihan adalah 0.16092 sedangkan RMSE selama validasi adalah 1.73769.
3. Hasil optimisasi menggunakan teknik optimisasi GA dan model ANN mendapatkan hasil kadar COD optimal yaitu 44.8668 mg/L, dengan memberikan *set point* kadar nitrat sebesar 9 mg/L dan kadar fosfat sebesar 12 mg/L.

#### 5.2. Saran

Penelitian selanjutnya dapat melakukan analisa terhadap jumlah bakteri yang digunakan dalam mengolah limbah pada *polishing unit*. Karena sampai saat ini penelitian tentang jumlah bakteri yang digunakan pada *polishing unit* masih terbatas.

*Halaman ini sengaja dikosongkan*

## DAFTAR PUSTAKA

- [1] Menteri Negara Lingkungan Hidup, “Baku Mutu Air Limbah bagi Usaha dan/atau Kegiatan Minyak dan Gas Serta Panas Bumi,” 2007.
- [2] Huynh Ngoc Phuong Mai, *Integrated Treatment of Tapioca Processing Industrial Wastewater Based on Environmental Bio-Technology*. 2006.
- [3] R. Ningtyas, “Pengolahan Air Limbah dengan Proses Lumpur Aktif Pengolahan Air Limbah dengan Proses Lumpur Aktif,” no. December, 2015.
- [4] C. B. Kadu and C. Y. Patil, “Design and Implementation of Stable PID Controller for Interacting Level Control System,” *Procedia Comput. Sci.*, vol. 79, pp. 737–746, 2016, doi: 10.1016/j.procs.2016.03.097.
- [5] H. Pawignya, “Pembuatan Protein Sel Tunggal dari Limbah Nanas dengan Proses Fermentasi,” *Pros. Semin. Nas. Tek. Kim.*, pp. A05-1-A05-5, ISSN 1693-4393, 2011.
- [6] A. M. Ghaedi and A. Vafaei, “Applications of artificial neural networks for adsorption removal of dyes from aqueous solution: A review,” *Adv. Colloid Interface Sci.*, vol. 245, no. April, pp. 20–39, 2017, doi: 10.1016/j.cis.2017.04.015.
- [7] M. Bagheri, S. A. Mirbagheri, M. Ehteshami, and Z. Bagheri, “Modeling of a sequencing batch reactor treating municipal wastewater using multi-layer perceptron and radial basis function artificial neural networks,” *Process Saf. Environ. Prot.*, vol. 93, no. April, pp. 111–123, 2014, doi: 10.1016/j.psep.2014.04.006.
- [8] M. Bagheri, S. Ahmad, Z. Bagheri, and A. Morad, “Modeling and optimization of activated sludge bulking for a real wastewater treatment plant using hybrid artificial neural networks-genetic algorithm approach,” *Process Saf. Environ. Prot.*, vol. 95, pp. 12–25, 2015, doi: 10.1016/j.psep.2015.02.008.
- [9] Y. Zhang *et al.*, “Integrating water quality and operation into prediction of water production in drinking water treatment plants by genetic algorithm enhanced artificial neural network,” *Water Res.*, vol. 164, p. 114888, 2019, doi: 10.1016/j.watres.2019.114888.

- [10] L. A. A. Purnomo and T. R. Biyanto, "Neural network model for profile temperature of nickel kiln," *AIP Conf. Proc.*, vol. 2088, no. March, 2019, doi: 10.1063/1.5095267.
- [11] R. D. Noriyati, R. D. O. Safitri, and T. R. Biyanto, "Optimization strategic production capacities lubricants lithos packaging," *AIP Conf. Proc.*, vol. 2088, no. March, 2019, doi: 10.1063/1.5095272.
- [12] H. D. Atoufi and D. J. Lampert, "Impacts of Oil and Gas Production on Contaminant Levels in Sediments," *Curr. Pollut. Reports*, vol. 6, no. 2, pp. 43–53, 2020, doi: 10.1007/s40726-020-00137-5.
- [13] U.S. EPA - United States Environmental Protection Agency, "Development Document for Effluent Limitations Guidelines and New Sources Performance Standards for the Offshore Subcategory of the Oil and Gas Extraction," *Off. Water*, vol. Washington, p. 407, 1993.
- [14] M. Negara and L. Hidup, "No Title," pp. 1–12, 2010.
- [15] A. Bahadori, *Waste Management*. New Delhi, India: Aptara Inc, 2014.
- [16] A. Tasnim, "Estimation of Chemical Oxygen Demand in WasteWater using UV-VIS Spectroscopy," *Sch. Mechatron. Syst. Eng.*, pp. 10–18, 2015.
- [17] S. Jouanneau *et al.*, "Methods for assessing biochemical oxygen demand (BOD): A review," *Water Res.*, vol. 49, no. 1, pp. 62–82, 2014, doi: 10.1016/j.watres.2013.10.066.
- [18] C. N. Sawyer, *Chemistry for environmental engineering and science*. 2003.
- [19] P. Pujiastuti and B. Ismail, "Kualitas dan Beban Pencemaran Perairan Waduk Gajah Mungkur," vol. V, no. 1, pp. 59–75, 2013.
- [20] M. Azamia, "Pengolahan limbah cair laboratorium kimia dalam penurunan kadar organik serta logam berat Fe,Mn,Cr dengan metode koagulasi dan adsorpsi," 2012.
- [21] M. L. Davi and D. A. Cornwel, *INTRODUCTION TO ENVIRONMENTAL ENGINEERING*. McGraw-Hill, 2008.
- [22] D. J. Flynn and J. Weeks, *The Nalco Water Handbook Nalco Company*. .
- [23] N. Gray, *WASTEWATER TREATMENT BIOLOGY OF Second Edition*. 2008.

- [24] D. F. Aristiami and I. N. Widiassa, "Pengaruh Co-Precipitation Besi Klorida Terhadap Kinerja Lumpur Aktif Pada Proses Pengolahan Air Limbah Domestik Sintetik," *Reaktor*, vol. 15, no. 3, p. 182, 2015, doi: 10.14710/reaktor.15.3.182-189.
- [25] M. Von Sperling, *Activated Sludge and Aerobic Biofilm Reactors*, vol. 6, no. 0. 2015.
- [26] M. Sustarsic, "Wastewater Treatment : Understanding the Activated Sludge Process," no. November, pp. 26–29, 2009.
- [27] "Process Flow Diagram Polishing Unit Facility."
- [28] R. Snyder, "Activated Sludge Process Control," 2010.
- [29] G. Hanrahan, *Artificial Neural Networks in Biological and Environmental Analysis*. Taylor and Francis Group, 2011.
- [30] A. S. Nugroho, "Pengantar Softcomputing," 2005, pp. 1–7.
- [31] B. Santoso, *Machine Learning & Reasoning Fuzzy Logic*. Deepublish, 2019.
- [32] I. Muzakkir, A. Syukur, and I. Novita Dewi, "Peningkatan Akurasi Algoritma Backpropagation Dengan Seleksi Fitur Particle Swarm Optimization Dalam Prediksi Pelanggan Telekomunikasi Yang Hilang," *Pseudocode*, vol. 1, no. 1, pp. 1–10, 2015, doi: 10.33369/pseudocode.1.1.1-10.
- [33] T. R. Biyanto, B. L. Widjiantoro, A. A. Jabal, and T. Budiati, "Artificial neural network based modeling and controlling of distillation column system," *Int. J. Eng. Sci. Technol.*, vol. 2, no. 6, pp. 177–188, 2011, doi: 10.4314/ijest.v2i6.63709.
- [34] L. Noriega, "Multilayer perceptron tutorial," *Sch. Comput. Staff. Univ.*, pp. 1–12, 2005.
- [35] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, 2016, doi: 10.12962/j23373539.v5i1.15696.
- [36] M. Miljanovic, "Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction," *Indian J. Comput. Sci. Eng.*, vol. 3, no. 1, pp. 180–191, 2012.

- [37] L. K. Budiasih, "Metode Levenberg-Marquardt Untuk Masalah Kuadrat Terkecil Nonlinear," *Semin. Nas. Mat. dan Pendidik. Mat. Jur. Pendidik. Mat. FMIPA UNY*, 5 Desember 2009, pp. 1152–1161, 2009.
- [38] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecast.*, vol. 22, no. 4, pp. 679–688, 2006, doi: 10.1016/j.ijforecast.2006.03.001.
- [39] S. Ni Luh Gede Pivin, S. I Made, and D. Suta, "Penerapan Algoritma Genetika Untuk Penjadwalan Mata Pelajaran," *J. Appl. Intell. Syst.*, vol. 1, no. 3, pp. 220–233, 2016.
- [40] T. R. Biyanto, "Genetic Algorithm Untuk Mengoptimasi Return of Investment Pada Green Building," *Semin. Nas. CITIES 2014*, no. February, pp. 1–10, 2014.
- [41] B. Nagaraj and N. Murugananth, "A comparative study of PID controller thning using GA, EP, PSO and ACO," *2010 IEEE Int. Conf. Commun. Control Comput. Technol. ICCCT 2010*, pp. 305–313, 2010, doi: 10.1109/ICCCCT.2010.5670571.
- [42] F. Piubeli, M. J. Grossman, F. Fantinatti-Garboggini, and L. R. Durrant, "Enhanced reduction of COD and aromatics in petroleum-produced water using indigenous microorganisms and nutrient addition," *Int. Biodeterior. Biodegrad.*, vol. 68, pp. 78–84, 2012, doi: 10.1016/j.ibiod.2011.11.012.
- [43] P. Kundu, A. Debsarkar, and S. Mukherjee, "Artificial Neural Network Modeling for Biological Removal of Organic Carbon and Nitrogen from Slaughterhouse Wastewater in a Sequencing Batch Reactor," *Adv. Artif. Neural Syst.*, vol. 2013, pp. 1–15, 2013, doi: 10.1155/2013/268064.
- [44] A. A. M. Ahmed, "Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs)," *J. King Saud Univ. - Eng. Sci.*, vol. 29, no. 2, pp. 151–158, 2017, doi: 10.1016/j.jksues.2014.05.001.
- [45] X. Du, J. Wang, V. Jegatheesan, and G. Shi, "Dissolved oxygen control in activated sludge process using a neural network-based adaptive PID algorithm," *Appl. Sci.*, vol. 8, no. 2, 2018, doi: 10.3390/app8020261.

- [46] H. Liu and C. K. Yoo, “Cascade control of effluent nitrate and ammonium in an activated sludge process,” *Desalin. Water Treat.*, vol. 57, no. 45, pp. 21253–21263, 2016, doi: 10.1080/19443994.2015.1119741.
- [47] Y. Prihadi Utomo, *Eksplorasi Data dan Analisis Regresi dengan SPSS*. Surakarta: Muhammadiyah University Press, 2007.
- [48] H. Zhou, Z. Deng, Y. Xia, and M. Fu, “A new sampling method in particle filter based on Pearson correlation coefficient,” *Neurocomputing*, vol. 216, pp. 208–215, 2016, doi: 10.1016/j.neucom.2016.07.036.
- [49] Sugiyono, *Statistika Untuk Penelitian*. Bandung, Jawa Barat, Indonesia: Alfabeta, 2017.
- [50] T. R. Biyanto *et al.*, “Duelist algorithm: An algorithm inspired by how duelist improve their capabilities in a duel,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9712 LNCS, pp. 39–47, 2016, doi: 10.1007/978-3-319-41000-5\_4.

*Halaman ini sengaja dikosongkan*

## LAMPIRAN

### Lampiran 1. Report Harian *Polishing Unit*

Description		Regulatory Limit	Unit	Time		
				8:00	15:00	
INFLUENT PARAMETER	Totalizer Reading	-	M <sup>3</sup>	3	3	
	pH		-	6.95	6.8	
	Temperature		°C	34.3	33.7	
	TSS		mg/L	58	-	
	TDS		mg/L	13690		
	COD <i>influent</i>		mg/L	1087		
	NH3-N (Ammonia)		mg/L	-		
	OiW		mg/L	16		
	TDS		mg/L	9396		
	MLSS		mg/L	587		
	SV30		-	68		
	SVI		-	116		
	NO3		mg/L	12.4		
	PO4		mg/L	5.88		
AERATION	TSS (Supernatan)		mg/L	58		-
	TDS		mg/L	9396		
	MLSS		mg/L	587		
	SV30		-	68		
	SVI		-	116		
	NO3		mg/L	12.4		
	PO4		mg/L	5.88		
EFFLUENT PARAMETER	Totalizer Reading	-	M <sup>3</sup>	4.5	4.5	
	pH	6 - 9	-	7.87	7.79	
	Temperature	40	°C	29.9	28.9	
	TSS	100	mg/L	18	-	

Description	Regulatory Limit	Unit	Time	
			8:00	15:00
TDS	4000	mg/L	13750	
COD <i>effluent</i>	200	mg/L	250	
NH3-N (Ammonia)	5	mg/L	-	
OiW	25	mg/L	2	