

Penentuan Arsitektur Jaringan Syaraf Tiruan Backpropagation (Bobot Awal dan Bias Awal) Menggunakan Algoritma Genetika

Christian Dwi Suhendra*¹, Retantyo Wardoyo²

¹Program Studi S2 Ilmu Komputer, FMIPA UGM, Yogyakarta

²Jurusan Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta

e-mail: *¹christiansuhendra@gmail.com, ²rw@ugm.ac.id

Abstrak

Kelemahan dari jaringan syaraf tiruan backpropagation adalah sangat lama untuk konvergen dan permasalahan lokal minimum yang membuat jaringan syaraf tiruan (JST) sering terjebak pada lokal minimum. Kombinasi parameter arsitektur, bobot awal dan bias awal yang baik sangat menentukan kemampuan belajar dari JST untuk mengatasi kelemahan dari JST backpropagation.

Pada penelitian ini dikembangkan sebuah metode untuk menentukan kombinasi parameter arsitektur, bobot awal dan bias awal. Selama ini kombinasi ini dilakukan dengan mencoba kemungkinan satu per satu, baik kombinasi hidden layer pada architecture maupun bobot awal, dan bias awal. Bobot awal dan bias awal digunakan sebagai parameter dalam perhitungan nilai fitness. Ukuran setiap individu terbaik dilihat dari besarnya jumlah kuadrat galat (sum of squared error = SSE) masing – masing individu, individu dengan SSE terkecil merupakan individu terbaik. Kombinasi parameter arsitektur, bobot awal dan bias awal yang terbaik akan digunakan sebagai parameter dalam pelatihan JST backpropagation.

Hasil dari penelitian ini adalah sebuah solusi alternatif untuk menyelesaikan permasalahan pada pembelajaran backpropagation yang sering mengalami masalah dalam penentuan parameter pembelajaran. Hasil penelitian ini menunjukkan bahwa metode algoritma genetika dapat memberikan solusi bagi pembelajaran backpropagation dan memberikan tingkat akurasi yang lebih baik, serta menurunkan lama pembelajaran jika dibandingkan dengan penentuan parameter yang dilakukan secara manual.

Kata kunci Jaringan syaraf tiruan, algoritma genetika, backpropagation, SSE, lokal minimum

Abstract

The weakness of back propagation neural network is very slow to converge and local minima issues that makes artificial neural networks (ANN) are often being trapped in a local minima. A good combination between architecture, intial weight and bias are so important to overcome the weakness of backpropagation neural network.

This study developed a method to determine the combination parameter of architector, initial weight and bias. So far, trial and error is commonly used to select the combination of hidden layer, intial weight and bias. Initial weight and bias is used as a parameter in order to evaluate fitness value. Sum of squared error(SSE) is used to determine best individual. individual with the smallest SSE is the best individual. Best combination parameter of architecture, initial weight and bias will be used as a paramater in the backpropagation neural network learning.

The results of this study is an alternative solution to solve the problems on the backpropagation learning that often have problems in determining the parameters of the learning. The result shows genetic algorithm method can provide a solution for

backpropagation learning and can improve the accuracy, also reduce long learning when it compared with the parameters were determined manually.

Keywords: Artificial neural network, genetic algorithm, backpropagation, SSE, local minima.

1. PENDAHULUAN

Permasalahan komputasi selalu dapat menyesuaikan dengan perilaku yang ada di alam sekitar. terkadang sifat – sifat dari alam dapat diadopsi untuk menyelesaikan permasalahan komputasional, misalnya jaringan saraf tiruan, kecerdasan buatan, algoritma genetik, sistem pakar, dan lain-lainnya. Jaringan syaraf tiruan adalah sistem komputasi yang arsitekturnya dan operasinya diilhami dari pengetahuan tentang sel syaraf biologis dalam otak. Model jaringan syaraf tiruan ditunjukkan dengan kemampuannya dalam emulasi, analisis, prediksi, dan asosiasi. Kemampuan yang dimiliki jaringan syaraf tiruan dapat digunakan untuk belajar dan menghasilkan aturan atau operasi dari beberapa contoh *input* yang dimasukan dan membuat prediksi tentang kemungkinan *output* yang akan muncul atau menyimpan karakteristik *input* yang diberikan kepada jaringan syaraf tiruan. Salah satu jenis metode pembelajaran jaringan syaraf tiruan adalah *backpropagation*. *Backpropagation* merupakan model JST dengan *layer* yang jamak, *Backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan mengenal pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa dengan pola yang dipakai selama pelatihan. Menurut [1] *backpropagation* memiliki kemampuan untuk mengatasi permasalahan pelatihan klasifikasi dengan skala data yang luas, hal ini membuat *backpropagation* menjadi algoritma pelatihan yang terkenal. Namun menurut [2] *Backpropagation* memiliki dua kelemahan utama yaitu kecepatan *convergence* yang buruk dan tidak stabil, hal ini disebabkan karena resiko terjebaknya JST pada lokal minimum. Dua kelemahan JST dipengaruhi bobot awal yang dipilih secara random. ditambahkan juga oleh [3] dalam menghitung perubahan bobot algoritma *backpropagation* dapat menyebabkan masalah lokal minimum.

Beberapa cara sudah digunakan untuk mengatasi kelemahan *backpropagation* ini, banyak algoritma optimasi digunakan dalam mempelajari dan mendesain sebuah jaringan syaraf tiruan seperti mengkonstruksi JST. Menurut [4] saat ini pemilihan arsitektur JST dilakukan dengan cara *trial and error* untuk menemukan jumlah *hidden layer* dan *neuron* yang sesuai dengan masalah yang ada. Penelitian [5] membandingkan optimasi menggunakan *particle swarm optimization* dan menggunakan algoritma genetika, dimana algoritma genetika digunakan untuk menyediakan pola bobot yang baik dalam meningkatkan pembelajaran dari *backpropagation*, dan *particle swarm optimization* digunakan untuk mengamati *kecepatan convergence* dan akurasi klasifikasi dari *feedforward neural network*. Saat ini pemilihan arsitektur JST dilakukan dengan cara *trial and error* untuk menemukan jumlah *hidden layer* dan *neuron* yang sesuai dengan masalah yang ada.. Performa belajar JST bergantung pada arsitektur, fungsi aktivasi dan bobot awal, Maka kombinasi arsitektur dan bobot serta bias awal yang baik akan menentukan hasil dari sebuah neuron yang akan dirambatkan pada jaringan diatasnya yang kemudian akan menjadi keluaran dari JST [6]. Algoritma genetika akan digunakan untuk menentukan kombinasi arsitektur dan bobot serta bias awal terhadap parameter JST *backpropagation* ini sehingga bisa mendapatkan kemampuan belajar yang baik. Menurut [7] algoritma genetika memulai dengan multiple random point sebagai insial populasi ketika mencari solusi. Setiap solusi kemudian dievaluasi berdasarkan fungsi objektif, setelah selesai solusi – solusi tersebut kemudian dipilih untuk generasi selanjutnya berdasarkan fitness mereka. Bahkan [8] menggunakan algoritma genetika untuk menghindari stuck pada lokal minimum, dan memberikan hasil yang lebih stabil dengan cara menentukan bobot jaringan yang bisa beradaptasi setiap iterasi terhadap model arsitektur yang telah ditentukan secara manual. Berdasarkan permasalahan yang ada penelitian ini mencoba untuk menentukan hubungan antara

arsitektur dengan bobot awal JST agar mendapatkan kombinasi yang optimal terhadap parameter JST backpropagation sehingga bisa mendapatkan kemampuan belajar yang baik.

2. METODE PENELITIAN

Desain Penelitian

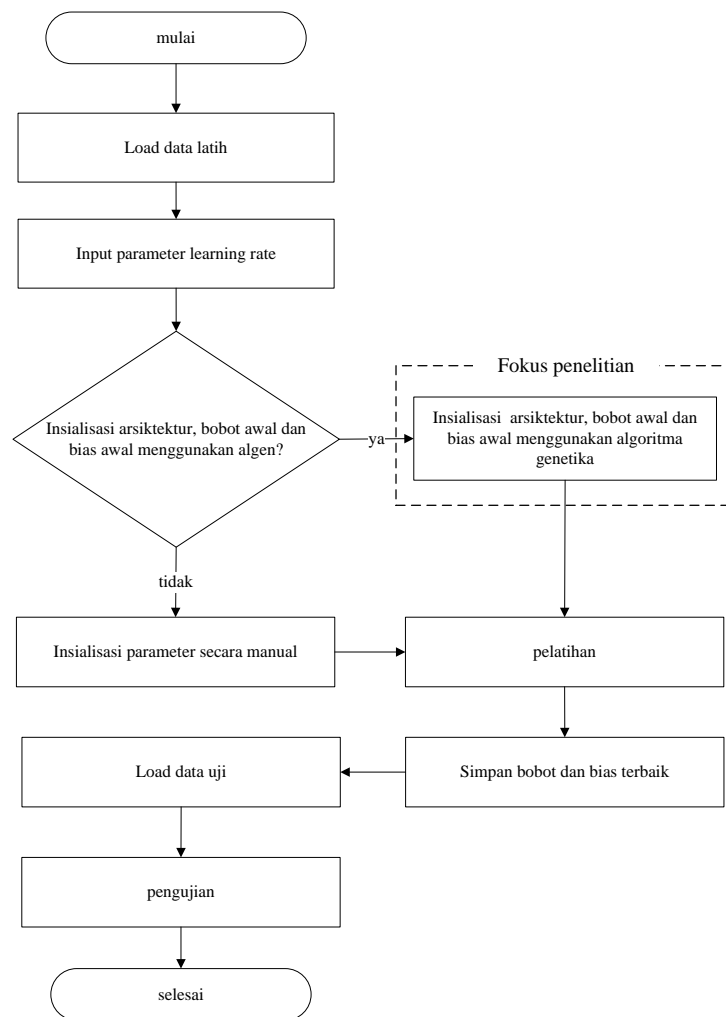
Secara umum sistem yang akan dibuat dalam penelitian ini adalah sistem aplikasi penentuan parameter arsitektur pada jaringan syaraf tiruan *backpropagation* menggunakan algoritma genetika. Proses pelatihan JST dilakukan seperti biasanya dimana kita terlebih dahulu mengatur setiap parameter ada di JST kemudian dilakukan pelatihan. Pada pembelajaran JST setiap parameter saling terkait satu sama lain, dan penentuan parameter seperti arsitektur dan bobot awal dilakukan secara acak. setiap parameter pada JST akan berbeda untuk setiap datanya, maka setiap data yang akan dilatih perlu untuk mengetahui parameter mana yang ideal untuk menghasilkan kemampuan belajar JST yang baik.

Pada penelitian akan membandingkan antara metode ini dengan metode standart dari jaringan syaraf tiruan tanpa modifikasi untuk itu data yang digunakan adalah dataset yang sudah bisa diakses dari internet maupun beberapa dataset dari penelitian sebelumnya. data klasifikasi yang digunakan adalah data iris flower, data user knowledge, data wine quality, data – data ini diambil dari <http://archive.ics.uci.edu/ml/>.

Tahap ini setelah melihat kekurangan pada pelatihan JST yaitu dengan metode trial and error sering mengalami kesulitan dalam menentukan parameter awal. Kegiatan yang dilakukan pada tahap ini adalah menganalisis metode pengoptimalan parameter awal JST yang digunakan pada pelatihan menggunakan algoritma genetika. Pada tahap ini dilakukan desain arsitektur jaringan backpropagation, dan desain operator – operator yang digunakan pada algoritma genetika seperti inialisasi populasi, mendesain representasi kromosom, menentukan fungsi objektif dan fungsi fitness untuk menghasilkan nilai parameter learning rate yang nantinya akan dipakai pada proses pembelajaran JST selanjutnya untuk menghasilkan *error* yang minimal.

Proses pengujian sistem dilakukan dengan membandingkan antara metode yang dikembangkan dengan metode standart dari JST *backpropagation* tanpa dimodifikasi. Data yang digunakan untuk pengujian adalah data iris flower, data user knowledge, dan data wine quality. Ketiga data ini dibandingkan berdasarkan SSE, akurasi, dan lama pembelajaran.

Gambar 1 menunjukkan pada proses insialisasi parameter pengguna akan diberi pilihan untuk membangkitkan parameter secara manual atau dengan menggunakan algoritma genetika. Hasil dari kedua cara ini akan dibandingkan untuk dapat melihat perbedaan dari sisi besar *error ratio*, tingkat akurasi dan kecepatan pembelajaran dengan tujuan untuk melihat apakah metode ini bisa memberikan kemampuan belajar yang lebih baik jika dibandingkan dengan metode standart tanpa modifikasi.

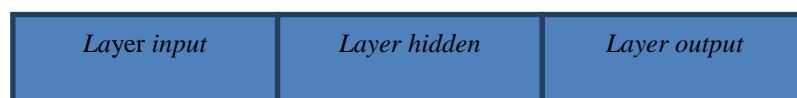


Gambar 1 Desain penelitian

Berdasarkan analisa terhadap terhadap rumusan masalah untuk menentukan arsitektur dan bobot awal pada JST backpropagation maka algoritma genetika dapat digunakan untuk mencari kombinasi yang ideal untuk dipakai pada pelatihan JST backpropagation

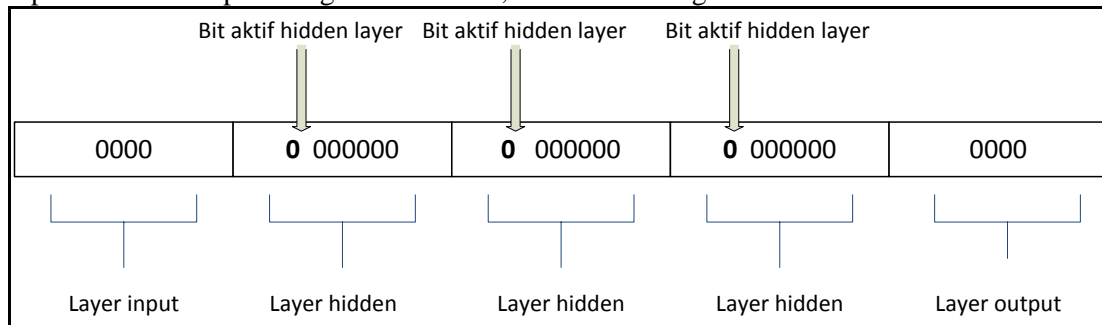
Representasi kromosom

Representasi Kormosom dalam penelitian ini menggunakan skema dengan representasi integer. Skema yang digunakan pada penelitian ini ditunjukkan pada Gambar 2.

Gambar 2 Skema pengkodean *phenotype* individu

Berdasarkan skema yang diperkenalkan oleh John Holland pada tahun 1975 pengkodean pada penelitian ini didasari pada sebuah skema yang dibentuk. Skema pengkodean *phenotype* yang ditunjukkan pada Gambar 2 merupakan arsitektur standart yang terdapat pada JST multilayer yang terdiri dari input, output dan sebuah *hidden layer*. Nilai – nilai yang terdapat dalam layer input, layer hidden dan layer output merupakan banyaknya neuron pada pada layer tersebut. Sedangkan untuk pengkodean *genotype* dari individu ditunjukkan pada Gambar 3. Pada

pengkodean genotype panjang kromosom yang digunakan sebanyak 29 bit yang terdiri dari 4 bit input dan 4 bit output sebagai bit asteriks, dan 18 bit sebagai bit non-asteriks.



Gambar 3 Skema pengkodean *genotype* individu

Gambar 3 menunjukkan skema pengkodean berdasarkan pengkodean *phenotype* pada Gambar 2. sebuah individu akan memiliki dengan struktur maksimal hidden layer yang terjadi adalah 3 *hidden layer* dan *neuron* pada masing – masing hidden layer sebanyak 68 *neruon*. Berdasarkan Gambar 3 individu dengan panjang kromosom 29 akan terbagi menjadi 4 bagian yaitu 4 bit untuk neuron pada layer input, 21 bit untuk neuron pada layer hidden, dan 4 bit pada layer output. 21 bit pada layer hidden akan terbagi menjadi 3 bagian yang mewakili jumlah *hidden layer* masing – masing 7 bit. Bit aktif hidden layer pada awal bit masing – masing hidden layer merupakan sebuah bit yang pengaktif yang jika bernilai 1 maka *hidden layer* tersebut digunakan dan jika bernilai 0 maka *hidden layer* tersebut tidak digunakan. Tabel 1 menunjukkan daftar tabel pengkodean neuron yang ada pada hidden layer.

Tabel 1 Pengkodean neuron pada *hidden layer*

Encoding	Decoding	Encoding	Decoding	Encoding	Decoding
000000	5	010110	27	101100	49
000001	6	010111	28	101101	50
000010	7	011000	29	101110	51
000011	8	011001	30	101111	52
000100	9	011010	31	110000	53
000101	10	011011	32	110001	54
000110	11	011100	33	110010	55
000111	12	011101	34	110011	56
001000	13	011110	35	110100	57
001001	14	011111	36	110101	58
001010	15	100000	37	110110	59
001011	16	100001	38	110111	60
001100	17	100010	39	111000	61
001101	18	100011	40	111001	62
001110	19	100100	41	111010	63
001111	20	100101	42	111011	64
010000	21	100110	43	111100	65
010001	22	100111	44	111101	66
010010	23	101000	45	111110	67
010011	24	101001	46	111111	68
010100	25	101010	47		
010101	26	101011	48		

Inisial populasi

Ukuran populasi didefinisikan sebagai banyaknya kromosom yang dibangkitkan secara acak. Jika populasi awal selesai dibangkitkan maka algoritma genetika dapat bekerja untuk menentukan penyelesaian terbaik diantara populasi tersebut. Pada penelitian ini populasi awal dibangkitkan secara acak sebanyak ukuran populasi dengan panjang kromosom setiap individu merupakan range antara 3 sampai dengan 10 element dimana element awal pada kromosom merupakan *element input* dan element akhir pada individu merupakan *element output*.

Gambar 4 menunjukkan populasi awal dengan panjang kromosom yang berbeda tiap individu namun masih sesuai dengan skema yang ditentukan. Setiap individu akan dibangkitkan bobot jaringan secara random untuk mewakili sebuah arsitektur. Sebuah arsitektur memungkinkan untuk memiliki lebih dari satu bobot yang berbeda.

Ukuran Populasi = 5	
Individu 1	010001001111100110011110010
Individu 2	010011010111100101010110010
Individu 3	010011110010100111010110010
Individu 4	010011010111100000110110010
Individu 5	010011011101110100110110010

Gambar 4 Populasi awal kromosom

Fungsi objektif dan fungsi fitness.

Fungsi obyektif dari permasalahan optimasi algoritma genetika pada jaringan syaraf tiruan yaitu dengan meminimalkan nilai error. Pada penelitian ini error yang digunakan adalah sum of square error (SSE)

Secara umum fungsi *fitness* merupakan pemetaan fungsi objektif dan merupakan fungsi yang digunakan untuk mengukur tingkat baik atau buruknya nilai individu yang dipilih terhadap permasalahan yang telah didefinisikan. Fungsi fitness yang digunakan adalah persamaan untuk mencari nilai SSE, seperti yang ditunjukkan pada persamaan (1).

$$SSE = \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^N (t_{ij} - o_{ij})^2 \quad (1)$$

Dimana :

N = jumlah *output*

M = jumlah data

SSE = sum of square *error*

t_{ij} = target yang pada data ke i

o_{ij} = *output* yang dihasilkan

i = indeks data

j = indeks neuron *output*

Berdasarkan persamaan (1), parameter dari fungsi *fitness* ini adalah bobot jaringan, bobot bias, serta data latih. Fungsi *fitness* ini digunakan untuk melihat individu mana yang dapat menghasilkan nilai SSE yang lebih.

Seleksi

Pada penelitian ini proses seleksi yang dipakai menggunakan seleksi *roulette wheel* yang merupakan seleksi yang didasari oleh probabilitas kemunculan individu terbaik untuk dipilih sebagai calon orang tua, semakin besar probabilitas sebuah individu maka kesempatan individu tersebut dipilih kembali semakin besar.

Crossover

Dalam penelitian ini metode *crossover* yang digunakan adalah *crossover* 2 titik. Titik yang menjadi titik potong ditentukan secara random dan tidak diperbolehkan berada pada posisi yang sama

Mutasi

Pada penelitian ini probabilitas mutasi P_m digunakan untuk menentukan individu yang akan mengalami proses mutasi, dengan membandingkan nilai random pada individu hasil *crossover* dengan nilai probabilitas P_m . Gen pada kromosom yang akan dimutasi ditentukan berdasarkan aturan acak. Pada penelitian ini probabilitas mutasi tersebut menjadi *input* dari pengguna. Operator mutasi dapat memungkinkan terjadinya penghapusan atau penambahan *hidden layer*.

Elitism

Proses elitism ini merupakan proses penyalinan individu terbaik agar tetap terjaga. Hal ini dilakukan karena proses pindah silang dan mutasi setelah dievaluasi belum tentu menghasilkan individu terbaik.

3. HASIL DAN PEMBAHASAN

Bagian ini akan membahas mengenai hasil pengujian yang telah dilakukan terhadap data yang dilatih menggunakan JST *backpropagation*. Algoritma genetika digunakan untuk menentukan Parameter JST *backpropagation* seperti arsitektur, bobot awal dan bias awal. Parameter hasil dari algoritma genetika tersebut akan diuji untuk dilihat nilai SSE, tingkat akurasi dan lama pembelajaran yang dihasilkan.

Percobaan terhadap data *iris flower*

Tabel 2 Penentuan arsitektur menggunakan algen untuk data *iris flower*

data	Ukuran populasi	Jumlah generasi	Arsitektur BP		Fitness	SSE	akurasi
			hidden layer	neuron			
<i>Iris flower</i>	10	10	1	63	0.0437	22.872	86.66%
	10	20	1	35	0.0438	22.807	87.50%
	10	30	1	42	0.0442	22.616	87.50%
	10	40	1	30	0.0447	22.326	90.47%
	10	50	1	21	0.0460	21.758	90.47%

Tabel 2 menunjukkan hasil yang telah didapat melalui proses algoritma genetika. Dari tabel ukuran populasi 10 dan jumlah generasi 50 menghasilkan individu dengan nilai fitness terbaik yaitu 0.0460 dan menghasilkan arsitektur yang dapat memberikan nilai SSE yang lebih baik dibandingkan dengan jumlah generasi lainnya yaitu 21.758 dengan jumlah hidden layer 1

dan jumlah neuron 21. Setelah dilakukan pembelajaran menggunakan arsitektur tersebut JST mampu menghasilkan tingkat akurasi sebesar 90.47% dengan lama pembelajaran 246010.

Tabel 3 Perbandingan hasil pengujian antara JST algen dan JST *data iris*

data	Arsitektur		SSE		epoch		akurasi	
	Hidden layer	Neuron	Algen	standart	Algen	standart	Algen	standart
Iris flower	1	63	22.872	25.168	296315	473796	86.66%	86.54%
	1	35	22.807	26.034	304108	458828	87.50%	87.50%
	1	42	22.616	25.371	286290	327989	87.50%	87.50%
	1	30	22.326	24.878	281567	392637	90.47%	90.47%
	1	21	21.758	25.167	246010	3141315	90.47%	90.47%

Tabel 3 SSE akhir yang didapatkan baik pengujian menggunakan parameter hasil algoritma genetika dan parameter yang ditentukan secara acak manual menunjukkan hasil yang sama 0.999999923573617, sehingga bobot akhir yang dihasilkan dari pelatihan JST menggunakan parameter yang dihasilkan dari proses algoritma genetika dengan proses standart menunjukkan hasil yang sama.

Percobaan terhadap data *user knowledge*

Tabel 4 Penentuan arsitektur menggunakan algen untuk data *user knowledge*

Data	Ukuran populasi	Jumlah generasi	Arsitektur BP		Fitness	SSE	Akurasi	epoch
			hidden layer	neuron				
User knowledge	10	10	1	62	0.0384	26.01	96.50%	315648
	10	20	1	38	0.0385	25.96	96.50%	448184
	10	30	2	26-25	0.0386	25.90	99.04%	410753
	10	40	1	28	0.0384	26.07	96.50%	412444
	10	50	2	20-30	0.0386	25.90	99.04%	428998

Berdasarkan Tabel 4 individu yang memiliki fitness terbaik 0.0386 dihasilkan pada generasi ke 30 dengan 2 hidden layer dan masing neuron tiap hidden layer adalah 26 untuk hidden layer pertama dan hidden layer kedua 25 neuron, untuk bobot awal dan bias awal terdapat pada lampiran 2. Arsitektur ini menghasilkan nilai SSE yaitu 25.90 dengan tingkat akurasi 99.04%.

Tabel 5 Perbandingan hasil pengujian antara JST algen dan JST untuk data *user knowledge*

data	Arsitektur		SSE		Epoch		akurasi	
	Hidden layer	Neuron	Algen	standart	Algen	standart	Algen	standart
User knowl edge	1	62	26.01	27.166	315648	2398171	96.50%	96.50%
	1	38	25.96	31.275	448184	3156342	96.50%	96.50%
	2	26-25	25.90	26.902	410753	2776321	99.04%	99.04%
	1	28	26.07	25.023	412444	340119	96.50%	96.50%
	2	20-30	25.90	28.089	428998	2910031	99.04%	99.04%

Tabel 5 menunjukkan SSE awal dan lama pembelajaran yang dihasilkan menggunakan arsitektur, bobot awal dan bias awal hasil proses algoritma genetika memberikan hasil yang lebih baik dibandingkan dengan yang ditentukan secara manual. SSE akhir yang didapatkan dari pelatihan dengan menggunakan dua metode ini menunjukkan perbedaan sangat kecil, sehingga

bobot akhir yang dihasilkan dari proses algoritma genetika dengan proses standart menunjukkan hasil yang berbeda.

Percobaan terhadap data *wine quality*

Tabel 6 Penentuan arsitektur menggunakan algen untuk data *wine quality*

Data	Ukuran populasi	Jumlah generasi	Arsitektur BP		Fitness	SSE	Akurasi	epoch
			hidden layer	neuron				
Wine Quality	10	10	1	48	0.0430	23.002	84.76%	8928088
	10	20	1	52	0.0436	22.734	76.92%	5525388
	10	30	1	51	0.0436	22.855	78.85%	8850222
	10	40	1	35	0.0436	22.886	77.88%	9429617
	10	50	1	40	0.0443	22.573	84.76%	2873993

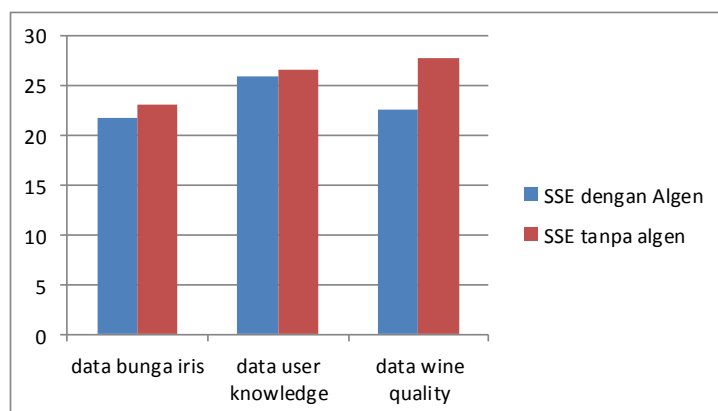
Tabel 6 menunjukkan individu dengan hidden layer 1 neuron 40 adalah individu terbaik dengan fitness 0.0443 menghasilkan nilai SSE awal 22.573, tingkat akurasi 82.69% pembelajaran yang lebih cepat mencapai stopping criteria yang ditentukan yaitu 2873993 epoch

Table 7 Perbandingan hasil pengujian antara JST algen dan JST untuk data *wine quality*

data	Arsitektur		SSE		Epoch		akurasi	
	Hidden layer	Neuron	Algen	standart	Algen	standart	Algen	standart
Wine	1	48	23.002	27.166	8928088	22781494	84.76%	84.76%
	1	52	22.734	31.275	5525388	22512447	76.92%	76.92%
	1	51	22.855	26.902	8850222	22350013	78.85%	78.85%
	1	35	22.886	25.023	9429617	23007325	77.88%	77.88%
	1	40	22.573	32.219	2873993	21707409	84.76%	84.76%

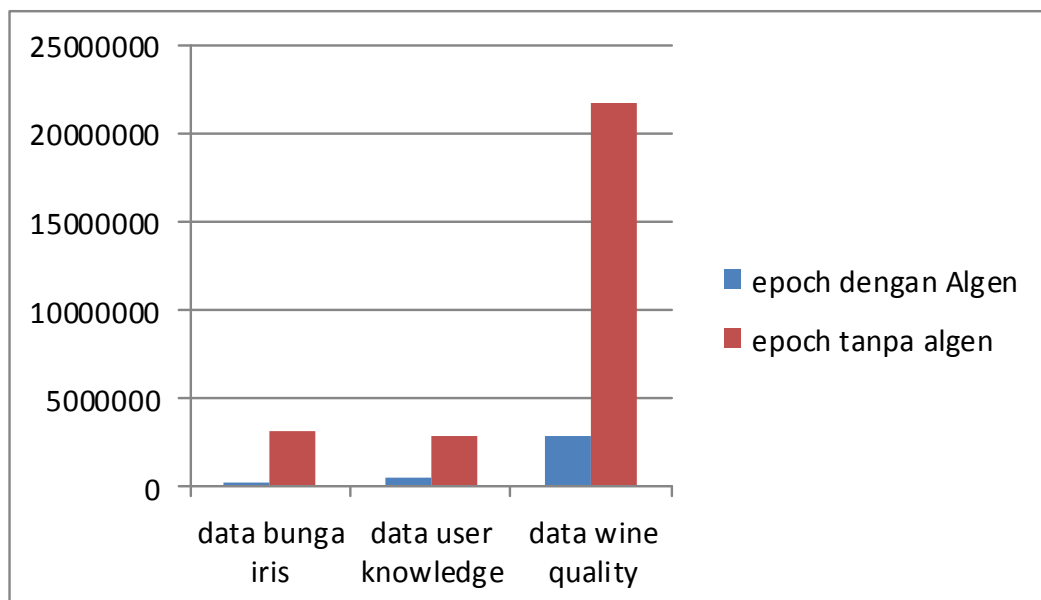
Tabel 7 menunjukkan SSE awal dan lama pembelajaran yang dihasilkan menggunakan arsitektur, bobot awal dan bias awal hasil proses algoritma genetika memberikan hasil yang lebih baik dibandingkan dengan yang ditentukan secara manual. SSE akhir yang didapatkan dari pelatihan dengan menggunakan dua metode ini menunjukkan perbedaan sangat kecil, sehingga bobot akhir yang dihasilkan dari proses algoritma genetika dengan proses standart menunjukkan hasil yang berbeda.

Pengaruh algoritma genetika terhadap JST backpropagation



Gambar 5 Grafik pengaruh algen terhadap SSE

Gambar 5 menunjukkan pengaruh algoritma genetika terhadap nilai SSE yang dihasilkan. nilai SSE hasil algoritma genetika memberikan nilai yang lebih baik yaitu nilai SSE lebih kecil untuk setiap data. Hal ini disebabkan oleh bobot yang ditentukan melalui hasil algoritma genetika dievaluasi terlebih dahulu untuk dapat memberikan nilai SSE yang lebih kecil.



Gambar 6 Grafik pengaruh algen terhadap lama pembelajaran

Gambar 6 menunjukkan pengaruh algoritma genetika terhadap lama pembelajaran. Berdasarkan pengujian terhadap ketiga data yang dapat memberikan lama pembelajaran yang lebih baik adalah parameter yang ditentukan menggunakan algoritma genetika. Meskipun lama pembelajaran bergantung pada parameter learning rate, namun bobot awal yang ditentukan pun memiliki pengaruh dalam perubahan bobot yang terjadi selama pembelajaran. Perubahan bobot tiap epoch menentukan suatu pembelajaran untuk mencapai kondisi konvergen

4. KESIMPULAN

1. Berdasarkan nilai SSE, akurasi, dan lama pembelajaran yang dihasilkan, algoritma genetika berhasil menyelesaikan masalah penentuan parameter arsitektur JST(bobot awal dan bias awal) dan menghasilkan hasil yang lebih baik dibandingkan dengan dengan tanpa optimasi.
2. Hasil pelatihan JST *backpropagation* tanpa optimasi sangat bergantung pada proses inialisasi yang dilakukan secara acak, sehingga perlakuan terhadap ketiga parameter yang diuji akan berbeda setiap kali dilakukan pelatihan.
3. Jumlah generasi menentukan individu yang dihasilkan semakin besar jumlah populasi maka semakin baik algoritma genetika mendapatkan kondisi konvergennya.
4. Akurasi yang dihasilkan dari pembelajaran JST menggunakan bobot awal dan bias awal yang ditentukan secara acak namun dengan struktur arsitektur yang sama dengan arsitektur yang ditentukan oleh algen menunjukkan nilai yang sama namun dengan jumlah *epoch* yang lebih banyak. Hal ini disebabkan perbedaan bobot awal dan bias awal yang menghasilkan SSE yang berbeda.
5. Bobot akhir yang dihasilkan oleh kedua metode yang memiliki SSE akhir yang sama menunjukkan nilai yang sama.

6. Hasil algoritma genetika untuk data *iris flower* menghasilkan individu terbaik dengan nilai fitness 0.0460 untuk arsitektur 1 hidden layer dan jumlah neuron 21 dengan nilai SSE 21.758, untuk data *user knowledge* menghasilkan individu terbaik dengan nilai fitness 0.0386 untuk arsitektur 2 hidden layer dan jumlah neuron masing – masing 26 dan 25 dengan nilai SSE 25.90, dan untuk data *wine quality* menghasilkan individu terbaik dengan nilai fitness 0.0443 untuk arsitektur 1 hidden layer dan jumlah neuron 40 dengan nilai SSE 22.573.

5. SARAN

1. Penggunaan momentum dalam fungsi fitness dan dalam pelatihan JST kemungkinan dapat memberikan perubahan bobot yang lebih baik, sehingga dapat mempercepat suatu pembelajaran untuk bisa mencapai kondisi konvergen.
2. Sebaiknya diterapkan jenis fungsi aktivasi, dan parameter *learning rate* dalam merepresentasikan kromosom untuk mengetahui fungsi aktivasi, dan *learning rate* mana yang sesuai dengan data yang akan dilatih.
3. Data yang digunakan sebaiknya diperbanyak, sehingga dapat memberikan hasil yang pasti tentang pengaruh penentuan arsitektur, bobot awal dan bias awal terhadap pembelajaran JST.

DAFTAR PUSTAKA

- [1] Habib, T, Md. dan Rokonuzzaman, M., 2013, An Empirical Approach to Optimize Design of Backpropagation Neural Network Classifier for Textile Defect Inspection, *British journal of Mathematics & Computer Science*, 3(4), pp 617-634
- [2] Nawi,N,M., Khan, A., Rehman, M, Z., 2013, A New Backpropagation Neural Network Optimized with Cuckoo Search Algorithm, *Computational Science and Its Applications-ICCSA*, volume 7971, pp 413-426.
- [3] Burse, K., Manoria, M., Kirar, V, P, S., 2010, Improved Back Propagation Algorithm to Avoid Local Minima in Multiplicative Neuron Model, *World Academy of Science , Eginering and Technology*, vol. 4, no. 12, pp 367-370.
- [4] Zarei, M dan Dzalilov, Z., 2009, Optimization of back-propagation neural networks architecture and parameters with a hybrid PSO/SA approach, *International on Soft Computing, Computing with Words and Perception in system analysis, decision and control-ICSCCW*, Famagusta, North Cyprus.
- [5] Nuzly, H., 2006 Particel Swarm Optimization For Neural Network Learning Enhancement, *Tesis*, Faculty of Computer Science and Information System Univesiti Teknologi Malaysia.
- [6] Nikelshpur, D. dan Tappert, C., 2013, Using Particle Swarm Optimization to Pre-train Artificial Neural Networks: Selecting Initial Training Weights for Feed-Forward Back-Propagation Neural Networks, *Proceedings of Student-Faculty Research Day*, New York.

- [7] Randall, S. S. dan Naheel, A. S., 2001, Data Mining Using a Genetic Algorithm-Trained Neural Network, *International Journal of Intelligent Systems in Accounting, Finance & Management* .10, 201–210.
- [8] Ding, S., Su, C., Yu, J., 2011, An optimizing Neural Network Algorithm based on Genetic Algorithm, China, *Artif intell*, vol 36, 153-162