

Metode Algoritma Genetika dan Darwinian Particle Swarm Optimization dengan Variable Acceleration Factor Untuk Fungsi Multimodal

Ariadi Retno Tri Hayati

Manajemen Informatika, Politeknik Negeri Malang

Jl. Soekarno Hatta No 9, Malang

E-mail: faniri4education@gmail.com

ABSTRAK

Penerapan metode optimasi untuk mengotomatiskan parameter dimana semakin sedikit kesalahan saat proses pembelajaran maka dengan harapan semakin mendapatkan nilai yang diharapkan. Pada metode optimasi dengan algoritma genetika mencari nilai optimasi dengan proses *mutation* dan *crossover* agar mendapatkan nilai yang tepat sedangkan pada metode Particle Swarm Optimization menerapkan pencarian arah nilai yang akan dioptimasi dengan *velocity*. Pada penelitian sebelumnya menerapkan kedua metode dengan harapan mendapatkan nilai optimasi yang lebih baik dengan menerapkan karakter proses pencarian nilai yang dioptimasi dengan masing-masing metode. Selanjutnya, penggabungan proses metode dari kedua metode optimasi dianalisa dengan menelaah karakter dari setiap gen untuk mendapatkan optimasi gen yang lebih baik dengan menerapkan konsep Darwinian GA-PSO (DGA-PSO) ternyata kesalahan untuk nilai variabel yang dioptimasi berkurang jika dibandingkan dengan kesalahan dengan metode GA-PSO. Pada penelitian ini mengembangkan metode optimasi dari penelitian sebelumnya dengan pengaruh *variabel acceleration factor* (VA). Berdasarkan hasil uji coba pada penelitian ini maka didapatkan bahwa hasil penghitungan dengan menerapkan metode GA-DPSO yang dipengaruhi *variabel acceleration factor* (GA-DPSO-VA) menghasilkan nilai kesalahan minimum atau paling sedikit jika dibandingkan dengan GA-DPSO, GAPSOVA dan GAPSO untuk penerapan analisa di fungsi multimodal pada setiap iterasinya.

Kata kunci: *Algoritma Genetika, Particle Swarm Optimization, MultiModal Function, Variable Acceleration Factor.*

ABSTRACT

Application of optimization methods to automate parameter where the fewer mistakes during the learning process it with the hopes of getting getting the expected value. In the optimization method and genetic algorithm are looking for value optimization with mutation and crossover process in order to get the right value while the Particle Swarm Optimization methods of finding direction applying the value to be optimized with velocity. In previous studies applying both methods in hopes of getting a better value optimization by implementing code search process value is optimized by each method. Furthermore, the incorporation process of the method of the optimization methods is analyzed by examining the characteristics of each gene to obtain optimization better genes by applying Darwinian concept GA-PSO (DGA-PSO) turned out to be a mistake for the variable values that are optimized reduced when compared to an error by the method GA -PSO. In this research to develop methods of optimization of previous studies the influences of acceleration factor (VA). Based on trial results on this study, it was found that the calculation results by applying the GA-DPSO influenced variable acceleration factor (GA-DPSO-VA) generating an error value minimum or at least when compared with the GA-DPSO, GAPSOVA and GAPSO for application analysis in multimodal function at each iteration.

Keywords: *Genetic Algorithm, Particle Swarm Optimization, Multimodal Function, , Variable Acceleration Factor.*

PENDAHULUAN

Metode optimasi telah diterapkan untuk optimasi variabel yang diharapkan dapat mengotomatisasi masalah dengan bermacam permasalahan misalkan permasalahan untuk menyelesaikan persamaan matematika fungsional sebagaimana penelitian ini. Metode optimasi diterapkan untuk mengoptimasi variabel dari suatu metode misalkan optimasi *clustering* dengan mengoptimasi variabel bebas, ataupun optimasi suatu metode *Artificial Neural Network* untuk mengoptimasi hasil klasifikasi dari suatu data. Pada penelitian ini mengoptimalkan metode optimasi sebelumnya yaitu *GADPSO* dengan menggabungkan karakteristik setiap metode dengan harapan meminimumkan nilai kesalahan variabel agar mendapatkan nilai variabel yang lebih tepat.

Pada penelitian ini merupakan pengembangan dari penelitian sebelumnya dimana pada penelitian ini mengkaji pengaruh *variabel acceleration factor* terhadap metode Genetic Algorithm Darwinian Particle Swarm Optimization yang merupakan penelitian yang telah saya lakukan sebelumnya[1]. Untuk metode optimasi pada matematika fungsional bertujuan mendapatkan nilai variabel yang dicari dengan tingkat kesalahan paling minimum, selain dipengaruhi oleh nilai variabel juga dipengaruhi oleh jumlah iterasi pembelajaran.

Pada metode Algoritma genetika dari penelitian sebelumnya menunjukkan karakteristik mencari nilai variabel berdasarkan pengaruh sifat algoritma genetika yaitu crossvalidation dan mutasi, sedangkan nilai akhir kesalahan dengan metode Particle Swarm Optimization berdasarkan arah velocity. Ternyata jika dibandingkan GAPSO[4] kedua metode tersebut memiliki kesalahan yang lebih tinggi, sedangkan jika GADPSO[1] dibandingkan GAPSO akan menghasilkan kesalahan yang lebih sedikit. Hal ini menunjukkan karakteristik nilai yang dihasilkan dengan metode GADPSO memiliki

kecenderungan karakteristik nilai kesalahan lebih sedikit jika dibandingkan dengan GAPSO.

Pengaruh *variabel acceleration factor* pada hasil penelitian ini (GADPSO) akan ditampilkan pada uji coba, dimana berpengaruh pada jumlah iterasi yang dibutuhkan untuk mendapatkan nilai minimum lebih sedikit jika dibandingkan dengan GAPSO.

Kajian Pustaka

Algoritma genetika

Algoritma genetika adalah salah satu metode optimasi dimana menerapkan operator crossover dan mutasi untuk mendapatkan nilai variabel yang akan dioptimasi berdasarkan nilai fitness yang dipengaruhi oleh variabel yang diptimasi. Nilai fitness pada penelitian ini dipengaruhi oleh persamaan matematika yang diterapkan untuk uji coba. Secara konsep metode crossover dan mutasi akan mempengaruhi nilai pembelajaran dari algoritma genetika untuk mendapatkan nilai variabel dengan hasil jumlah kesalahan paling minimum, dimana cara mengetahui nilai kesalahan akan didapatkan dari nilai berdasarkan persamaan untuk fitness di algoritma genetika. Operator algoritma genetika untuk:

Crossover[1][3]

Proses crossover diterapkan sebagaimana rumusan berikut:

$$\begin{aligned} x_i &= \text{Uniform}(0,1)x_i + (1 - \text{Uniform}(0,1))x_{i+1} & i = 1,2,\dots,N-1(a) \\ x_i &= \text{Uniform}(0,1)x_i + (1 - \text{Uniform}(0,1))x_1 & i = N(b) \end{aligned} \quad (1)$$

Dimana dilakukan pengurutan data terlebih dahulu setelah itu dilakukan proses crossover. Pada Persamaan 1 terdapat Persamaan 1.a dan 1.b, untuk Persamaan 1.a dan 1.b terdapat rumusan Uniform (0,1) artinya melakukan random secara seragam antara nilai 0 dan 1, dan proses crossover antara variabel yang dioptimasi pada Persamaan 1.a dan 1.b.

Mutasi[1][3]

Untuk penelitian ini metode mutasi yang digunakan dengan random gaussian, sebagaimana berikut:

$$x_k^i = x_k + \text{normrand}(0,1, [\text{jumlah gen}]) \quad (2)$$

Pada Persamaan 2 terdapat persamaan untuk mutasi dimana berpengaruh terhadap nilai variabel dengan menambahkan random pada variabel.

DPSO dengan Variable Acceleration Factor

Pada penelitian ini menerapkan metode Particle Swarm Optimization dengan dipengaruhi metode Darwinian(DPSO) [1][5] dan *Variable Acceleration Factor*. Pada metode DPSO dari metode penelitian sebelumnya ternyata menghasilkan pengaruh metode darwinian terhadap metode PSO memberikan pengaruh nilai kesalahan pada setiap iterasi berkurang sehingga berpengaruh pada kebenaran optimasi nilai variabel yang dicari.

Metode PSO dipengaruhi oleh beberapa operator untuk mendapatkan nilai yang dioptimasi, yaitu position dan velocity. Position pada metode PSO dengan variabel x diasumsikan sebagai nilai variabel saat ini, sedangkan nilai variabel V adalah nilai velocity yang mengarahkan nilai variabel yang akan dioptimasi ke arah nilai yang lebih baik dengan nilai kesalahan yang berkurang pada setiap iterasinya, nilai position dan velocity sebagaimana rumusan berikut [1]:

$$x_{id}^{New} = x_{id}^{old} + V_{id}^{New} \quad (3)$$

$$V_{id}^{New} = w \times V_{id}^{old} + c_1 \times r \times (p_{id} - x_{id}^{old}) + c_2 \times r \times (p_{gd} - x_{id}^{old}) \quad (4)$$

Sebagaimana Persamaan 3, maka untuk memperbarui nilai variabel x yang dipengaruhi oleh nilai arah velocity sebelumnya. Sebagaimana Persamaan 4, maka untuk mengoptimasi suatu variabel dipengaruhi oleh perbaikan nilai velocity (V) dengan dipengaruhi oleh nilai variabel w yaitu nilai weight, nilai V old

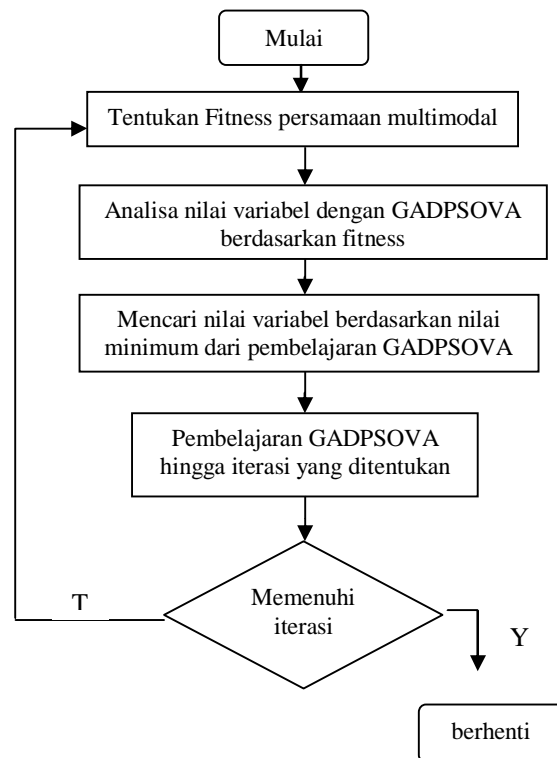
yaitu nilai velocity sebelumnya, nilai c1 dan c2 yaitu nilai konstanta, P_{best} yaitu nilai terbaik dari setiap particle dan G_{best} yaitu nilai terbaik dari group.

Paper sebelumnya telah menerapkan konsep Darwinian PSO dengan metode Algoritma Genetika dan berhasil memberikan pengaruh yang baik untuk mengurangi nilai kesalahan, pada penelitian ini menganalisa pengaruh variable acceleration factor terhadap penelitian sebelumnya.

METODE

Pada penelitian ini menerapkan *Variable Acceleration Factor* pada GADPSO dengan konsep metode GADPSO sebagaimana dipengaruhi oleh *Variable Acceleration Factor* pada DPSO dimana penelitian ini adalah pengembangan dari penelitian sebelumnya [1].

Rancangan sistem pada aplikasi penelitian ini dengan mengoptimasi nilai fitness dari persamaan matematika fungsional yang akan dioptimasi sebagaimana diagram Gambar 1 berikut:



Gambar 1. Diagram Optimasi GADPSOVA

Prosedur penelitian data yang akan dioptimasi dengan metode GADPSOVA yang merupakan metode GADPSO dipengaruhi *Variable Acceleration Factor* sebagaimana berikut:

1. Inisialisasi
2. Evaluasi dan ranking

$$\text{Mean Square Error (MSE)} = \frac{1}{N} \sum_1^N (y - f(x))^2 \quad (5)$$

3. Menerapkan GA dari M/2 data terbaik yaitu 2 nilai fitness terkecil dari M. Crossover M/2 data dengan operasi sebagaimana berikut :

$$x'_i = \alpha * x_i + (1 - \alpha) x_{i+1} \quad i = 1, 2, \dots, (M / 2) - 1 \dots \dots \dots (6)$$

$$x'_i = \alpha * x_i + (1 - \alpha) x_1 \quad i = M / 2, \dots \dots \dots (7)$$

4. DPSO pada (M/2)+1 data dengan *Variable Acceleration Factor*. Setengah data dibelajarkan pada metode DPSOVA.

Pada Persamaan 5 menghitung *mean square error* dimana bertujuan untuk mengetahui tingkat nilai kesalahan setiap data. Persamaan 6 adalah persamaan untuk crossover untuk urutan data 1 hingga jumlah data yang digunakan algoritma genetika yaitu M/2-1. Pada persamaan 7 adalah rumus crossover untuk urutan data ke M/2. Update nilai velocities dan position dengan DPSO dipengaruhi *Variable Acceleration Factor*

Jika belum memenuhi *stopping criteria*, maka data-data hasil pembelajaran DPSO dipengaruhi *Variable Acceleration Factor* dan GA digabungkan dan dievaluasi dengan kembali pada langkah ke-2.

Variable Acceleration Factor

Variable Acceleration Factor [2] memiliki Persamaan sebagaimana berikut:

$$C_{1f} = (C_{1f} - C_{1i}) \frac{iter}{iter_{max}} + C_{1f} \quad (8)$$

$$C_{2f} = (C_{2f} - C_{2i}) \frac{iter}{iter_{max}} + C_{2f} \quad (9)$$

Pada persamaan 8 adalah persamaan untuk mengupdate nilai konstanta C1, Persamaan 9 adalah persamaan untuk mengupdate variabel C2 dimana kedua nilai variabel mempengaruhi nilai velocity. Sedangkan nilai C_{1f} dan C_{1i} adalah nilai inisial awal, demikian nilai C_{2f} dan C_{2i}.

HASIL DAN PEMBAHASAN

Pada hasil dan pembahasan pada penelitian ini akan membandingkan analisa setiap iterasi dari metode GAPSO, GADPSO, GAPSOVA, GADPSOVA. Data yang digunakan sebagai pembanding sama pada setiap metode sebagaimana berikut:

- a. Inisialisasi nilai populasi awal dengan matrix 20x2 sebagian data sebagaimana Gambar 2 berikut:

0.8064	0.9165
0.4015	0.4326
0.3214	0.4270
0.3788	0.0293
0.7190	0.5104
0.1931	0.9637
0.4900	0.2754
0.1208	0.7434
0.1399	0.1168
0.9472	0.7693
0.6309	0.7657
0.4387	0.5408
0.7078	0.1693
0.5296	0.9301
0.6524	0.2082
0.7782	0.0198
0.6180	0.6016
0.5021	0.6074
0.4854	0.4689
0.1101	0.5963

Gambar 2. Data Inisialisasi Penelitian

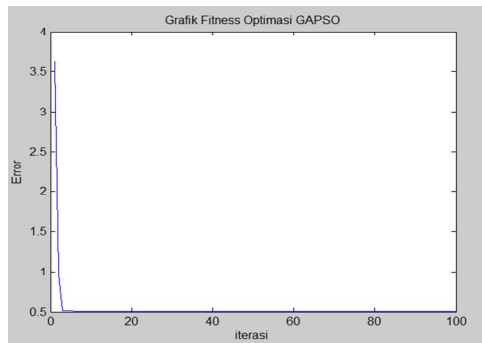
- b. Kesamaan nilai random untuk data pembelajaran pada metode GADPSOVA.

Nilai variabel yang akan dioptimasi terdapat dua variabel sebagaimana desain nilai yang akan dioptimasi terdapat 20 nilai kemungkinan untuk 2 variabel sehingga matrix berordo 20x2

Hasil dan Analisa Untuk Uji Coba pada Fungsi Rossenbrock

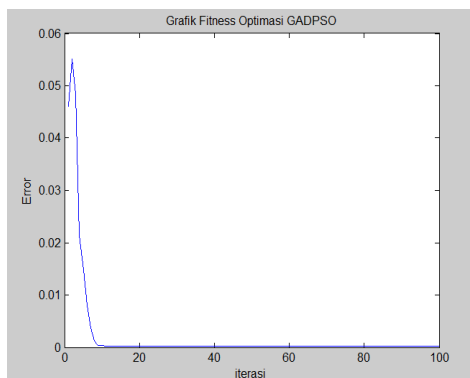
Hasil uji coba fungsi rossenbrock

Dengan fungsi Rossenbrock metode optimasi untuk GADPSOVA akan dibandingkan dengan metode optimasi GAPSO, GAPSOVA dan GADPSO sebagaimana hasil uji coba pada Gambar 3 berikut:



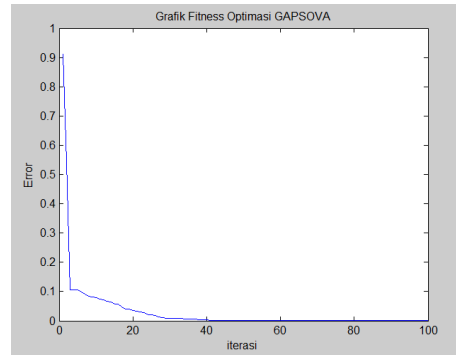
Gambar 3. Hasil uji coba fungsi Rossenbrock GAPSO

Pada Gambar 3, nilai awal hasil pembelajaran bernilai 3.6176 dan mengalami penurunan nilai pada setiap iterasinya.

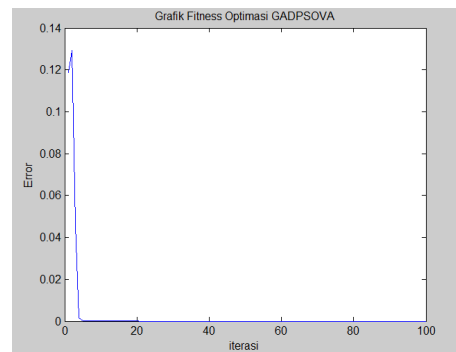


Gambar 4. Hasil uji coba fungsi Rossenbrock GADPSO

Pada Gambar 4, nilai awal hasil pembelajaran bernilai 0.0461 dan mengalami penurunan nilai pada setiap iterasinya. Sementara pada Gambar 5, nilai awal hasil pembelajaran bernilai 0.9107 dan mengalami penurunan nilai pada setiap iterasinya.



Gambar 5. Hasil uji coba fungsi Rossenbrock GAPSOVA



Gambar 6. Hasil uji coba fungsi Rossenbrock GADPSOVA

Pada Gambar 6, nilai awal hasil pembelajaran bernilai 0.1188 dan mengalami penurunan nilai pada setiap iterasinya.

Analisa uji coba fungsi rossenbrock

Berdasarkan uji coba fungsi Rossenbrock, analisa pada setiap iterasinya sebagaimana Tabel 1

Tabel 1. Nilai Iterasi Fungsi Rossenbrock

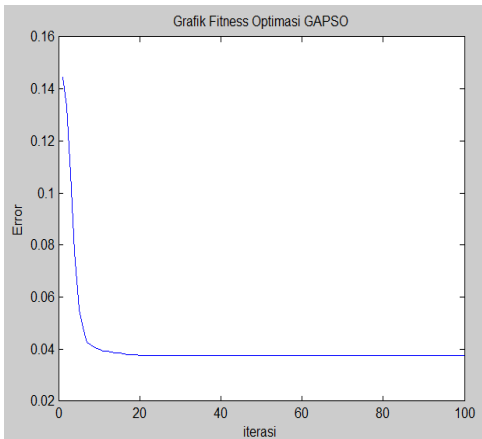
iterasi	GAPSO	GADPSO	GAPSOVA	GADPSOVA
1	3.6176	0.0461	0.9107	0.1188
2	0.9703	0.0551	0.5402	0.1292
3	0.5112	0.0484	0.1056	0.0462
4	0.5112	0.0214	0.1056	0.0015
5	0.5112	0.0148	0.1056	4.9649e-005
6	0.5056	0.0080	0.0977	2.4272e-006
7	0.5049	0.0037	0.0917	6.9813e-007
8	0.5041	0.0013	0.0829	3.6124e-007
9	0.5039	0.0004	0.0817	2.7684e-008
10	0.5037	0.0003	0.0785	7.3687e-009
11	0.5036	0.0002	0.0745	3.4647e-009
12	0.5035	0.0002	0.0712	1.4594e-009
13	0.5035	0.0002	0.0670	4.9011e-010
14	0.5035	0.0002	0.0642	4.9959e-011
15	0.5035	0.0002	0.0571	2.7030e-011
16	0.5035	0.0002	0.0569	2.2404e-012
17	0.5035	0.0002	0.0479	5.7730e-013
18	0.5035	0.0002	0.0402	1.1773e-014
19	0.5035	0.0002	0.0402	1.5938e-017
20	0.5035	0.0002	0.0346	1.0026e-017

Berdasarkan Tabel 1, dengan uji coba menggunakan fungsi Rossenbrock maka nilai kesalahan pada setiap iterasinya pada metode GADPSOVA memiliki tingkat kesalahan yang minimum dibandingkan metode yang lain.

Hasil dan Analisa Untuk Uji Coba pada Fungsi Zakharov

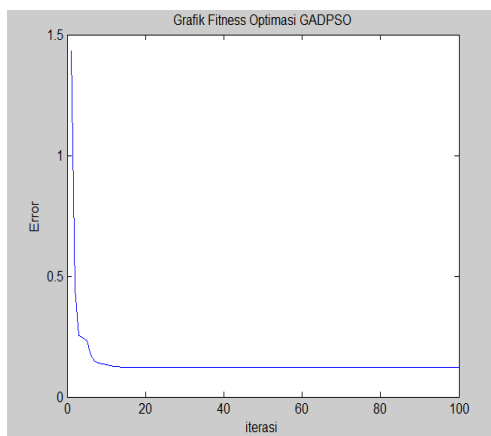
Hasil uji coba fungsi zakharov

Sebagaimana fungsi Rossenbrock, pada fungsi Zakharov akan membandingkan fungsi GAPSO, GAPSOVA, GADPSO dan GADPSOVA.




Gambar 7. Hasil uji coba fungsi Zakharov GAPSO

Pada Gambar 7, nilai awal hasil pembelajaran bernilai 0.1446 dan mengalami penurunan nilai pada setiap iterasinya.



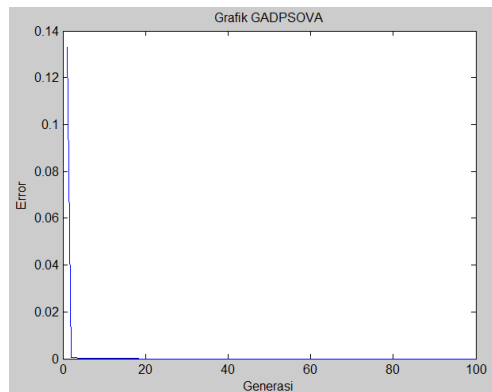
Gambar 8. Hasil uji coba fungsi Zakharov GADPSO

Pada Gambar 8, nilai awal hasil pembelajaran bernilai 1,4309 dan mengalami penurunan nilai pada setiap iterasinya.



Gambar 9. Hasil uji coba fungsi Zakharov GAPSOVA

Pada Gambar 9, nilai awal hasil pembelajaran bernilai 0,1833 dan mengalami penurunan nilai pada setiap iterasinya.



Gambar 10. Hasil uji coba fungsi Zakharov GADPSOVA

Pada Gambar 10, nilai awal hasil pembelajaran bernilai 0,1329 dan mengalami penurunan nilai pada setiap iterasinya.

Analisa uji coba fungsi zakharov

Analisa percobaan fungsi zakharov berdasarkan nilai iterasinya, pada setiap iterasi nilai kesalahan dengan metode GADPSOVA memiliki nilai minimum jika dibandingkan dengan metode GAPSO, GADPSO dan GAPSOVA sebagaimana nilai pada Tabel 2.

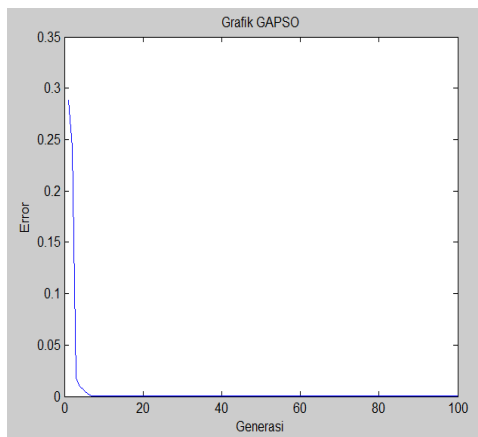
Tabel 2. Analisa Kesalahan Iterasi Fungsi Zakharov

iterasi	GAPSO	GADPSO	GAPSOVA	GADPSOVA
1	0.1446	1.4309	0.1833	0.1329
2	0.1333	0.4456	0.0263	6.5511e-004
3	0.1073	0.2542	0.0042	6.5511e-004
4	0.0773	0.2481	0.0004	1.1451e-004
5	0.0553	0.2310	1.0930e-005	3.4400e-006
6	0.0481	0.1747	4.7004e-007	1.9688e-006
7	0.0425	0.1496	1.1414e-007	7.9068e-008
8	0.0415	0.1404	4.7743e-008	2.8259e-009
9	0.0406	0.1384	3.0379e-008	6.9123e-010
10	0.0400	0.1317	1.7750e-008	1.9594e-010
11	0.0394	0.1287	9.1309e-009	2.9954e-012
12	0.0392	0.1260	4.6891e-009	4.9513e-013
13	0.0389	0.1245	3.5415e-009	4.9513e-013
14	0.0386	0.1241	2.0266e-009	4.2376e-014
15	0.0385	0.1237	6.5687e-010	9.2791e-015
16	0.0383	0.1235	6.2704e-010	2.2504e-015
17	0.0380	0.1233	4.0941e-010	7.6091e-017
18	0.0378	0.1231	2.9790e-010	2.1053e-017
19	0.0377	0.1229	1.8355e-010	4.9870e-019
20	0.0376	0.1227	8.6118e-011	5.9424e-020

Hasil dan Analisa Untuk Uji Coba pada Fungsi DeJoung

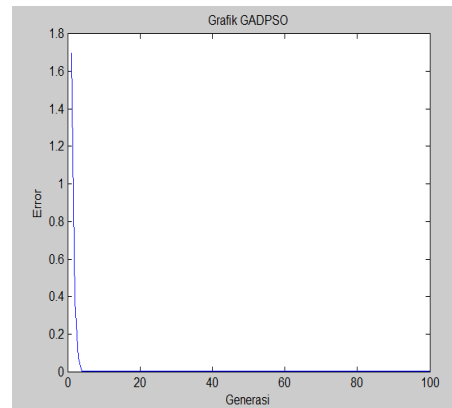
Hasil uji coba fungsi dejoung

Sebagaimana fungsi sebelumnya, pada fungsi DeJoung akan membandingkan fungsi GAPSO, GAPSOVA, GADPSO dan GADPSOVA.

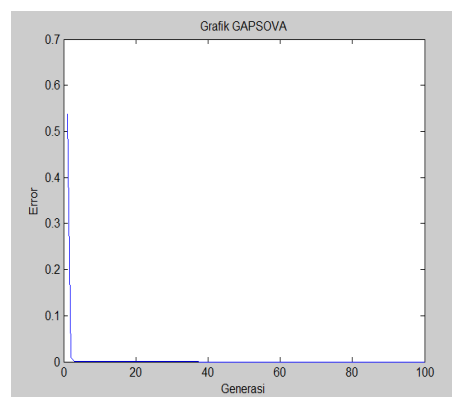


Gambar 11. Hasil uji coba fungsi DeJoung GAPSO

Pada Gambar 11, nilai awal hasil pembelajaran bernilai 0.2879 dan mengalami penurunan nilai pada setiap iterasinya. Sementara pada Gambar 12, nilai awal hasil pembelajaran bernilai 0.5367 dan mengalami penurunan nilai pada setiap iterasinya.

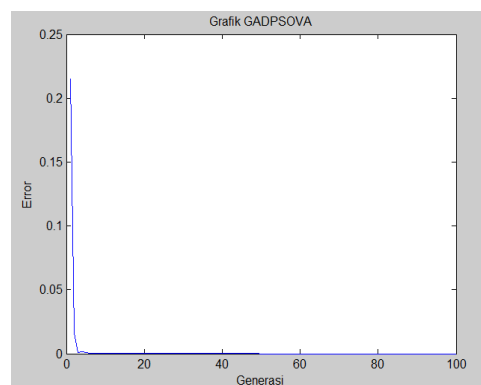


Gambar 12. Hasil uji coba fungsi DeJoung GADPSO



Gambar 13. Hasil uji coba fungsi DeJoung GAPSOVA

Pada Gambar 13, nilai awal hasil pembelajaran bernilai 1.6957 dan mengalami penurunan nilai pada setiap iterasinya.



Gambar 14. Hasil uji coba fungsi DeJoung GADPSOVA

Pada Gambar 14, nilai awal hasil pembelajaran bernilai 0.2148 dan mengalami penurunan nilai pada setiap iterasinya.

Analisa uji coba fungsi deJoung

Analisa percobaan fungsi DeJoung berdasarkan nilai iterasinya, pada setiap iterasi nilai kesalahan nilai minimum dengan fungsi DeJoung tidak seluruhnya iterasi memiliki nilai kesalahan minimum sebagaimana percobaan sebelumnya, tetapi pada akhirnya pada iterasi ke-18 hingga 20 telah memiliki nilai minimum dibandingkan dengan metode lainnya sebagaimana Tabel 2.

Tabel 2. Analisa Kesalahan Iterasi Fungsi DeJoung

iterasi	GAPSO	GADPSO	GAPSOVA	GADPSOVA
1	0.2879	1.6957	0.5367	0.2148
2	0.2422	0.3743	0.0096	0.0163
3	0.0176	0.0708	0.0015	0.0011
4	0.0102	0.0030	0.0006	0.0018
5	0.0057	1.3921e-004	0.0008	0.0008
6	0.0017	5.5155e-005	0.0005	0.0002
7	7.6879e-004	1.7879e-005	0.0003	0.0002
8	4.7694e-005	1.1478e-006	0.0003	0.0001
9	6.2793e-006	1.1395e-006	0.0002	1.6411e-005
10	2.6103e-006	2.5142e-007	0.0001	1.0761e-005
11	1.5270e-007	2.7174e-007	0.0001	3.6738e-007
12	3.1190e-009	9.7396e-008	4.4186e-005	2.9477e-007
13	2.8118e-009	5.1440e-008	2.6142e-005	5.6319e-008
14	2.0420e-009	1.0843e-009	1.9624e-005	2.6842e-009
15	1.4999e-009	1.3454e-009	1.9284e-005	2.4363e-009
16	4.3730e-010	2.9562e-010	1.8701e-005	1.2011e-009
17	1.0941e-010	2.3247e-010	1.8087e-005	1.2325e-010
18	1.0507e-010	1.7815e-010	1.7211e-005	1.8866e-011
19	1.1329e-010	1.1994e-010	1.5946e-005	9.5546e-012
20	1.0056e-010	7.6427e-011	1.4156e-005	7.7953e-012

SIMPULAN

Metode kuantisasi sel darah putih bertumpuk menggunakan analisis distance marker lebih robust terhadap bentuk dan ukuran objek. Keberhasilan metode analisis distance marker bergantung pada hasil segmentasi, kandidat marker objek dan informasi kedalaman bertumpuknya antar objek yang baik. Tingkat keberhasilan metode analisis distance marker mencapai 94,1%. Lebih jauh lagi, metode analisis distance marker dapat dijadikan dasar dalam pemisahan dan identifikasi jenis sel darah putih bertumpuk pada tahap selanjutnya.

DAFTAR PUSTAKA

- [1] Saraswat, M. dan Arya, K. V., "Automated microscopic image analysis

for leukocytes identification: a survey". *Micron (Oxford, England : 1993)*, Vol. 65, Hal. 20–33, 2014.

- [2] Fathichah, C., Purwitasari D., Hariadi V., Effendy F., "Overlapping White Blood Cell Segmentation and Counting on Microscopic Blood Cell Images", *Int. Journal on Smart Sensing and Intelligent Systems*, Vol. 7, No. 3., Hal 1271-1286, 2014.
- [3] Nazlibilek, S., Karacor, D., Ercan, T., Sazli, M. H., Kalender, O., dan Ege, Y., "Automatic segmentation, counting, size determination and classification of white blood cells". *Measurement*, Vol. 55, Hal. 58–65, 2014.
- [4] Yu. D., Pham T.D., Zhou X., "Analysis and recognition of touching cell images based on morphological structures", *Computer in Biology and Medicine*, Vol. 39, Hal. 27-39, 2009.
- [5] Bai X., Sun C., Zhou F., "Splitting touching cells based on concave points and ellipse fitting", *Pattern Recognition*, Vol. 42, Hal. 2434–2446, 2009.
- [6] Lin. P., Chen Y.M., He Y., Hu. G.W., "A novel matching algorithm for splitting touching rice kernels based on contour curvature analysis", *Computers and Electronics in Agriculture*, Vol. 109, 124-133, 2014.
- [7] Felzenszwalb, P. dan Huttenlocher, D., "Distance Transforms of Sampled Functions", 2012.
- [8] Ghosh, M., Das, D.C., Chandan R. dan Ajoy K, "Automated leukocyte recognition using fuzzy divergence", *Micron (Oxford, England : 1993)*, Vol. 41 No.7, Hal. 840–6, 2010.
- [9] Scotti F, "Robust Segmentation and Measurement Techniques of White Blood Cells in Blood Microscope Images", *Instrumentation and Measurement Technology Conference*, Hal. 43-48, 2006.