Jurnal Sains dan Matematika Vol. 20 (4): 81-88 (2012)

Perbandingan Algoritma *Particle Swarm Optimization* dan *Differential Evoluitonal Algorithm* untuk Perancangan Umpan Balik Keadaan : Studi Kasus Gerak Lateral Pesawat F-16

[1]Madchan Anis, [2]Widowati, [3]R. Heru Tjahjana
[1,2,3]Jurusan Matematika Universitas Diponegoro
Jl. Prof. Soedharto, SH, Tembalang Semarang 54275
Email : [1]anis.madchan@gmail.com, [2]widowati_math@undip.ac.id, [3]heru_tjahjana@undip.ac.id

ABSTRAK

The purpose of *Linear Quadratic Regulator* (LQR) optimal control system is to stabilize the system, so that the output of the system towards a steady state by minimizing the performance index. LQR-*invinite horizon* is a special case of LQR in thecontinuous time area where the terminal time of the performance index value for infinite time and infinite outputsystem is zero. Performance index will be affected by the weighting matrix. In this paper will be discussed about the application of *Particle Swarm Optimization algorithm* (PSO) and *Differential Evolution Algorithm* (DEA) to determine the state feedback of a closed loop system and weighting matrices in the LQR to minimize performance index. PSO algorithm is a computational algorithm inspired by social behavior of flocks of birds and fishes in searching of food. While the DEA is an optimization algorithm that is adopted from evolution and genetics of organisms. Simulations of the PSO algorithm will be compared with DEA. From the simulations results is found thatDEA is faster then PSO to get convergence to the optimal solution.

Keywords: LQR-invinite horizone, Particle Swarm Optimization (PSO), Differential Evolution Algorithm (DEA), umpan balik keadaan, sistem lup tertutup

PENDAHULUAN

Teori kontrol optimum linier kuadratik merupakan metode yang mudah diimplementasikan dalam masalah teknis dan merupakan dasar dari teori kontrol lainnya. Metode kontrol optimum yang sering digunakan adalah *Linear Quadratic Regulator (LQR)*. Dalam LQR masalah dasarnya adalah menentukan matriks pembobotan untuk menemukan kondisi optimal sistem dalam meminimalkan indeks performansi. Masalah pemilihan matriks pembobotan yang tepat dalam perancangan pengontrol telah diperkenalkan dalam berbagai macam metode.

Pemilihan matriks pembobotan pada LQR adalah sangat penting dan akan mempengaruhi input kontrol. Algoritma *Particle Swarm Optimization (PSO)* dan *Differential Evolution (DE)* merupakan algoritma optimasi dan dapat digunakan untuk menentukan matriks pembobotan dalam meminimumkan indeks performansi pada perancangan LQR. Algoritma PSO diinspirasi oleh sekawanan burung dan ikan dalam mencari sumber makanan. Sedangkan algoritma *Differential Evolution (DE)* diadopsi dari evolusi dan genetika pada makhluk hidup. PSO dan DEA dipilih dalam perancangan LQR, karena PSO dan DEA cukup sederhana dan dianggap mempunyai kecepatan komputasi yang tinggi. Algoritma PSO dan DEA telah banyak diaplikasikan dalam sistem landing pesawat [1,2,4,5].

ALGORITMA *PARTICLE SWARM OPTIMIZATION*

Proses di dalam algoritma PSO dapat dijelaskan sebagai berikut. Sebanyak p partikel disebar secara acak pada ruang solusi yang ada. Posisi partikel i saat waktu t , yaitu $x_i(t)$ akan diperbaiki menurut persamaan posisi sebagai berikut.

$$x_i(t+1) = x_i(t) + v_i(t+1), \qquad (2.1)$$

dengan$v_i(t+1)$ adalah kecepatan partikel yang dihitung dengan persamaan berikut.

$$v_i(t+1) = wv_i(t) + r_1 n_1 \left(p_{best_i}(t) - x_i(t)\right) + r_2 n_2 (g_{best_i}(t) - x_i(t)) , \quad (2.2)$$

Titik $pbest_i(t)$ adalah solusi lokal terbaik yang dicapai oleh partikel i sampai saat t, dan merepresentasikan kontribusi kognitif terhadap vector $v_i(t+1)$. Titik $gbest_i(t)$ adalah solusi global terbaik yang telah dicapai diantara partikel-partikel sampai saat t dan merepresentasikan kontribusi sosial terhadap vektor kecepatan .$gbest_i(t)$ merepresentasikan kontribusi sosial terhadap vektor kecepatan artinya bahwa $gbest_i(t)$ akan dijadikan sebagai acuan setiap partikel i untuk mengupdate kecepatannya. Bilangan acak r_1 dan r_2 terdistribusi seragam pada interval [0,1]. Faktor skala kognitif (n_1) dan faktor skala sosial (n_2) pada algoritma PSO biasanya bernilai 2 [7]. Faktor skala kognitif (n_1) merupakan percepatan konstan partikel yang mendorong setiap partikel tersebut menuju $pbest$nya. Sedangakan faktor skala sosial (n_2) merupakan percepatan konstan partikel yang mendorong setiap partikel tersebut menuju $gbest$. Variabel w adalah bobot inersia. Inersia yang besar memfasilitasi eksplorasi global (pencarian dalam daerah yang luas) sedangkan inersia yang kecil menghasilkan eksplorasi lokal (pencarian dalam daerah yang sempit). Oleh karena itu, nilai w merupakan faktor kritis yang menentukan perilaku konvergen algoritma PSO. Untuk itu direkomendasikan untuk memilih nilai w yang besar pada awalnya agar menghasilkan eksplorasi global pada ruang solusi, selanjutnya nilai w diturunkan secara bertahap untuk mendapatkan solusi yang lebih baik.

Menurut Xia dan Wu [8] bobot inersia w didefinisikan sebagai berikut .

$$w = w_{max} - \frac{w_{max} - w_{min}}{iterasi\ maksimum} d , \quad (2.3)$$

Dengan d adalah iterasi.

Faktor pembelajaran kognitif yang dirumuskan sebagai $r_1 n_1 \left(p_{best_i}(t) - x_i(t)\right)$ pada persamaan (2.2) merupakan memori partikel jangka pendek. Faktor pembelajaran kognitif ini menunjukkan inklinasi (kecenderungan) partikel untuk mengulang perilaku sebelumnya yang terbukti sukses pada partikel tersebut. Hal ini juga menunjukkan adanya pengaruh memori partikel tersebut. Faktor pembelajaran sosial yang diberikan oleh $r_2 n_2 (g_{best_i}(t) - x_i(t))$ merupakan *"peer presure"* bagi sebuah partikel. Faktor pembelajaran sosial tersebut menunjukkan inklinasi (kecenderungan) partikel untuk meniru atau mengemulasi perilaku partikel lain yang telah sukses. Hal ini menunjukkan adanya pengaruh tetangga partikel. Setiap iterasi, sekawanan partikel dievaluasi nilai *fitness*-nya dan berdasarkan nilai tersebut, kecepatan dan posisi partikel diperbaruhi [8]. Proses algoritma PSO dapat disajikan dengan diagram alir pada Gambar 1.

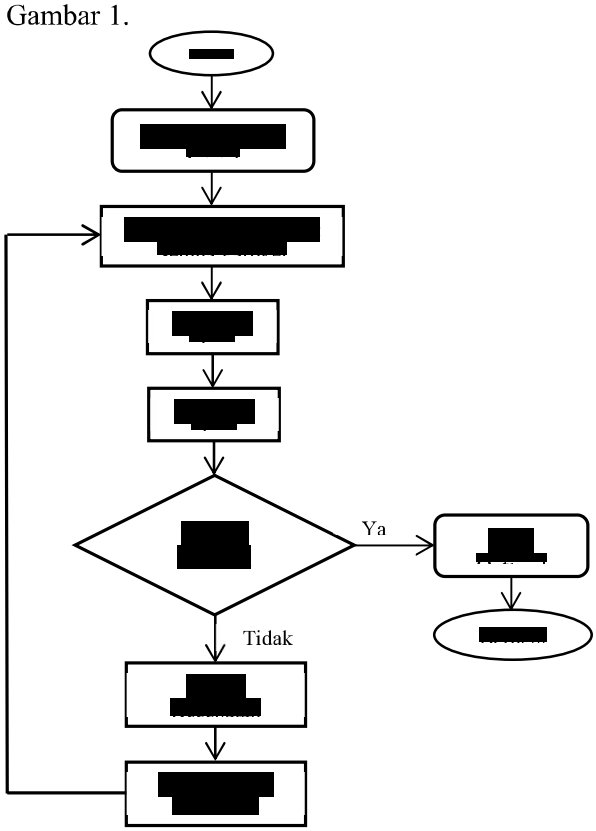

Gambar 1. Diagram Alir Algoritma PSO

ALGORITMA *DIFFERENTIAL EVOLUTION* (DE)

Pada bagian ini dibahas langkah-langkah algorima *differential evolution*, proses mutasi, rekombinasi, dan seleksi. Pada Tabel 1 [6] diberikan langkah-langkah algorima *differential evolution.*

Tabel 1. Tabel Algoritma DEA

Step 1. Initialization
Step 2. Evaluation
Step 3. REPEAT
Mutation

Recombination
Evaluation
Selection
UNTIL (stop criteria are met)

Suatu hal yang perlu dipahami sebelum membahas konsep DEA adalah bahwa suatu individu yang berisi nilai-nilai real bisa dipandang sebagai suatu vektor.Selanjutnya menghitung perbedaan antara dua individu sebagai jarak antara dua vektor. DEA menggunakan sejumlah *NP* vektor parameterSebagai suatu populasi pada setiap generasi G. Selama proses pencarian nilai minimum (minimasi), vektor parameter tetap berjumlah NP. Populasi awal dibangkitkan secara acak.

$$\underline{x}_{i,G},\ i = 0,1,2,\dots,NP-1 \qquad (3.1)$$

Selanjutnya, DEA membangkitkan suatu vektor parameter (individu) baru dengan melibatkan tiga individu sebagi orang tua. Pemilihan orang tua dilakukan dengan probabilitas yang sama untuk setiap individu tanpa memperhatikan nilai fungsi objektifnya. Pembangkitan vektor baru dilakukan dengan menambahkan vektor perbedaan antara dua vektor (orang tua ke-1 dan ke-2) kepada vektor lainnya (orang tua ke-3).Vektor yang dilibatkan dalam pembangkitan individu baru disebut orang tua.Pembangkitan vektor baru ini disebut mutasi *(mutation)*. Pada DEA, suatu bobot *(weight)* diberikan terhadap perbedaan antara dua vektor orang tua. Jika vektor baru yang dihasilkan memberikan nilai fungsi objektif yang lebih kecil daripada suatu vektor lainnya dalam populasi, maka vektor baru ini akan menggantikan vektor tersebut. Vektor yang dijadikan bandingan bisa (tetapi tidak harus) berasal dari ketiga vektor orang tua tersebut. Untuk menjaga jalur perkembangan yang dibuat selama proses minimasi, vektor parameter $\underline{x}_{best,G}$ dievaluasi pada setiap generasi G [9].

Pembangkitan vektor baru (mutasi) bisa dilakukan dengan beragam skema.Saat ini sudah banyak skema yang diusulkan oleh para ahli.Pertama kali Rainer Storn dan Kenneth Price [6] mengusulkan sebagai berikut.

Untuk setiap vektor $\underline{x}_{i,G}, i = 0,1,2,\dots,NP-1$, suatu vektor baru $\underline{v}$ dibangkitkan dengan rumus berikut ini.

$$\underline{v}_{i,G+1} = \underline{x}_{r1,G} + F.(\underline{x}_{r2,G} - \underline{x}_{r3,G}), \qquad (3.2)$$

dengan$r_1, r_2, r_3 \epsilon [0, NP-1]$ adalah integer berbeda dan $F > 0$.

Ketiga bilangan bulat r_1, r_2, r_3 harus berbeda satu sama lain dan dipilih secara acak dalam interval $[0, NP-1]$. Ketiga bilangan tersebut menyatakan indeks orang tua dan bisa berbeda untuk setiap proses pembangkitan individu baru. F adalah suatu bilangan real dan merupakan konstanta yang mengontrol penguatan *differential variation* $(\underline{x}_{r2,G} - \underline{x}_{r3,G})$. Proses pembentukan individu baru ini disebut *differential mutation* [9].

Untuk meningkatkan keberagaman *(diversity)* vektor-vektor parameter, maka vektor $\underline{v}$ direkombinasi *(crossover)* dengan suatu vektor sebarang dalam populasi, misal $\underline{x}_{i,G}$. Proses *crossover* ini menghasilkan vektor $\underline{u}$ berikut ini [6].

$$\underline{u}_{i,G+1} = \begin{cases} \underline{v}_{i,G+1} & jika\ rand_j(0,1) \le Cr \vee j = k \\ (\underline{x}_{i,G}) & untuk\ lainnya \end{cases}, \qquad (3.3)$$

dengan$j = 1,2,3,\dots Drand_j$ adalah evaluasi ke-j dari generasi G yang diperoleh secara acak antara 0 dan 1, $k\epsilon\{1,2,3,..,D\}$ adalah indeks parameter acak, dan D adalah dimensi fungsi yang dioptimasi.

Selanjutnya, vektor $\underline{u}$ akan menggantikan vektor $\underline{x}_{i,G}$ pada generasi berikutnya jika $\underline{u}$ memberikan nilai lebih kecil untuk fungsi objektif tersebut daripada $\underline{x}_{i,G}$. Tetapi, jika $\underline{u}$ memberikan nilai lebih besar daripada $\underline{x}_{i,G}$, maka $\underline{u}$ tidak menggantikan $\underline{x}_{i,G}$. Dengan kata lain, $\underline{x}_{i,G}$ akan tetap muncul pada generasi berikutnya [9].

Proses seleksi dilakukan untuk memutuskan apakah individu $\underline{u}_{i,G+1}$ akan menjadi anggota populasi pada generasi (G+1).

Proses seleksi dirumuskan sebagai berikut.

$$x_{i,G+1} = \begin{cases} \underline{u}_{i,G+1}\ , jika\ f(\underline{u}_{i,G+1}) < f(x_{i,G}) \\ x_{i,G}\ , untuk\ lainnya \end{cases},$$

dengan $f(.)$ adalah fungsi *fitness* (fungsi objektif) [5].

STUDI KASUS

Dalam tugas akhir ini akan mengambil studi kasus tentang sistem dinamik gerak lateral pesawat F-16 saat kondisi terbang dengan kecepatan 502 feet/sec, tekanan 300 psf. Sistem dinamik gerak lateral pesawat F-16 saat kondisi

terbang yang telah dilinierisasi merupakan sistem LTI dan diilustrasikan dalam persamaan ruang keadaan sebagai berikut [3].

$$\dot{x} = Ax + Bu$$

dengan $x = [\beta \quad \varphi \quad p \quad r \quad \delta_a \quad \delta_r \quad x_w]^T$

$$A = \begin{bmatrix} -0.3220 & 0.0640 & 0.0364 & -0.9917 & 0.0003 & 0.0008 & 0 \\ 0 & 0 & 1 & 0.0037 & 0 & 0 & 0 \\ -30.6492 & 0 & -3.6784 & 0.6646 & -0.7333 & 0.1315 & 0 \\ 8.5396 & 0 & -0.0254 & -0.4764 & -0.0319 & -0.0620 & 0 \\ 0 & 0 & 0 & 0 & -20.2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -20.2 & 0 \\ 0 & 0 & 0 & 57.2958 & 0 & 0 & -1 \end{bmatrix}$$

$$B = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 20.2 & 0 \\ 0 & 20.2 \\ 0 & 0 \end{bmatrix} \text{ dan } u = \begin{bmatrix} u_a \\ u_r \end{bmatrix}, \quad u \text{ adalah masukan sistem.}$$

dengan kondisi awal sistem sebagai berikut

$$x(0) = [\beta(0) \quad \varphi(0) \quad p(0) \quad r(0) \quad \delta_a(0) \quad \delta_r(0) \quad x_w(0)]^T = [1 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0]^T$$

dengan x : *lateral state*, β : *sideslip angle (deg)*, φ : *bank angle (deg)*, p : *roll* rate/kecepatan sudut guling *(deg/sec)*, r : *yaw rate*/kecepatan sudut geleng *(deg/sec)*, δ_a : *aileron actuator (deg)*, δ_r : *rudder actuator (deg)*, x_w : *washout filter state (deg/sec)*, u_a : *aileron deflection (deg)*, u_r : *rudder deflection (deg)*.

Dalam perancangan menggunakan algoritma PSO dan DEA dengan metode *invinite horizon* dengan meminimumkan indeks performansi sebagai berikut.

$$J = \frac{1}{2}\int_0^{\infty} (x^T Q x + u^T R u)\, dt$$

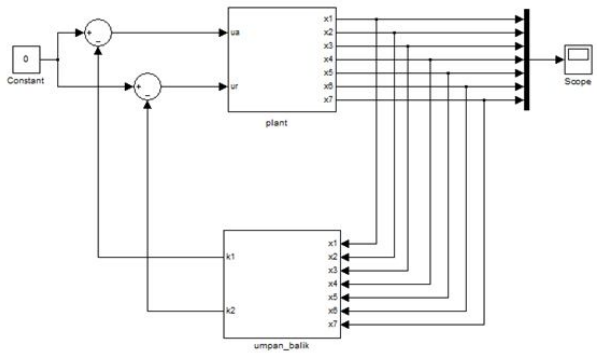

Gambar 2. Diagram Blok Keseluruhan Sistem

PERANCANGAN LQR

Dalam perancangan LQR menggunakan algoritma PSO dan DEA akan diambil nilai inisialisasi yang sama. Inisialisasi yang sama ini kemudian akan dibandingkan hasilnya apakah mempunyai perbedaan atau tidak. Inisialisasi dari algoritma PSO dan DEA diberikan sebagai berikut.

Matriks pembobotan error (Q)

$$Qawal = \begin{bmatrix} 50 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 100 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 100 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 100 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

Matriks pembobotan kontrol (R)

$$Rawal = \begin{bmatrix} 0.621 & 0 \\ 0 & 0.421 \end{bmatrix}$$

Dalam pendesaianan ini akan digunakan kriteria berhenti yang sama antara algritma PSO dan DEA yaitu *distribution based criteria*dan jumlah iterasi maksimum. Jika *distribution based criteria*tidak dipenuhi maka akan digunakan kriteria jumlah iterasi maksimum [10].

PERANCANGAN LQR-PSO

Selanjutnya untuk keperluan simulasi, parameter-parameter yang digunakan dalam algoritma PSO diberikan pada Tabel 2 sebagai berikut.

Tabel 2. Parameter Simulasi Algoritma PSO

Parameter	**Nilai**
Jumlah populasi	10
Jumlah iterasi	100
Faktor skala kognitif (n_1)	2
Faktor skala sosial (n_2)	2
r_1 dan r_1	random
w_{max}	0.9
w_{min}	0.4

Tabel 3. Nilai Indeks Performansi (J) dan *CPU Time* Setiap *Running* Menggunakan Algoritma PSO Dalam 20 Kali *Running*

Running Ke-	Nilai J	*CPU Time* (detik)	*Running* Ke-	Nilai J	*CPU Time* (detik)
1	6.579	22.5185	11	21.94	20.8362
2	15.1	21.0428	12	11.1	20.8544
3	30.82	20.7426	13	13.31	20.7519
4	41.42	21.1502	14	60.3	20.9325
5	78.66	20.9176	15	7.991	20.777
6	32.13	20.8832	16	10.35	22.0341
7	140.5	21.0776	17	86.53	21.3992
8	65.64	20.98	18	46.64	21.6435
9	73.09	20.8667	19	31.82	21.2532
10	138.9	20.8506	20	49.82	21.3688

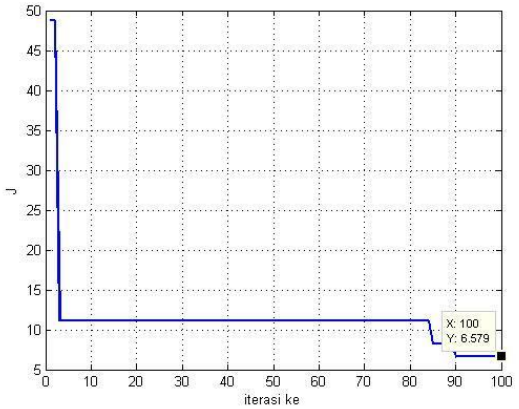

Gambar 3. Nilai Indeks Performansi Minimum Setiap Iterasi Menggunakan Algoritma PSO

Nilai indeks performansi telah konvergen dengan nilai optimum 6.579 detik dengan konstanta random $r_1 = 0.3276, r_2 = 0.6713$ dan membutuhkan waktu rata-rata kinerja CPU dalam dua puluh kali *running* sebesar 21.14403 detik. Nilai indeks performansi sudah optimum berarti matriks Q, R, dan umpan balik keadaan K telah diperoleh. Matriks Q, R, dan K optimum yang dihasilkan sebagai berikut.

$$Q = \begin{bmatrix} 0.6835 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.6639 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.2372 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.6113 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1.1375 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1.3772 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 9.5663 \times 10^{-4} \end{bmatrix}$$

$$R = \begin{bmatrix} 0.8554 & 0 \\ 0 & 0.9180 \end{bmatrix}$$

$$K^T = \begin{bmatrix} 0.3230 & 0.0022 \\ -0.7321 & -0.0643 \\ -0.2055 & -0.0156 \\ -0.7125 & -0.1196 \\ 0.5320 & 5.0026 \times 10^{-4} \\ 5.3689 \times 10^{-4} & 0.5813 \\ -3.0305 \times 10^{-4} & -1.4481 \times 10^{-4} \end{bmatrix}$$

Selanjutnya mencari nilai kontrol optimum dengan menggunakan rumus $u^* = Kx$ diperoleh

$$u^{*T} = x^T K^T$$

$$= [\beta \quad \varphi \quad p \quad r \quad \delta_a \quad \delta_r \quad x_w] \begin{bmatrix} 0.3230 & 0.0022 \\ -0.7321 & -0.0643 \\ -0.2055 & -0.0156 \\ -0.7125 & -0.1196 \\ 0.5320 & 5.0026 \times 10^{-4} \\ 5.3689 \times 10^{-4} & 0.5813 \\ -3.0305 \times 10^{-4} & -1.4481 \times 10^{-4} \end{bmatrix}$$

Jadi, kontrol optimum yang bersesuaian dengan u_a adalah

$$u^* = 0.3230\beta - 0.7321\varphi - 0.2055p - 0.7125r + 0.5320\delta_a + 5.3689 \times 10^{-4}\delta_r - 3.0305 \times 10^{-4}x_w$$

dan kontrol optimum yang bersesuaian dengan u_r adalah

$$u^* = 0.0022\beta - 0.0643\varphi - 0.0156p - 0.1196r + 5.0026 \times 10^{-4}\delta_a + 0.5813\delta_r - 1.4481 \times 10^{-4}x_w$$

PERANCANGAN LQR-DEA

Tabel 4. Parameter Simulasi Algoritma DEA

Parameter	Nilai
Jumlah populasi	10
Jumlah iterasi	100

Probabilitas *crossover* (CR)	0.5

Tabel 5. Nilai Indeks Performansi (J) dan *CPU Time* Setiap *Running* Menggunakan DEA Dalam 20 Kali *Running*

Running Ke-	Nilai J	*CPU Time* (detik)	*Running* Ke-	Nilai J	*CPU Time* (detik)
1	12.24	11.2949	11	229.7	10.3466
2	13.72	9.3652	12	91.04	8.6059
3	83.81	10.3891	13	223.8	7.7212
4	10.15	10.1041	14	58.33	11.1195
5	38.16	11.7021	15	85.45	12.5964
6	24.95	11.7818	16	6.417	8.7374
7	80.98	12.5668	17	402.6	13.9544
8	207	7.6218	18	105.6	10.8846
9	113.6	10.9281	19	12.92	8.8331
10	119.6	12.4192	20	85.01	11.0592

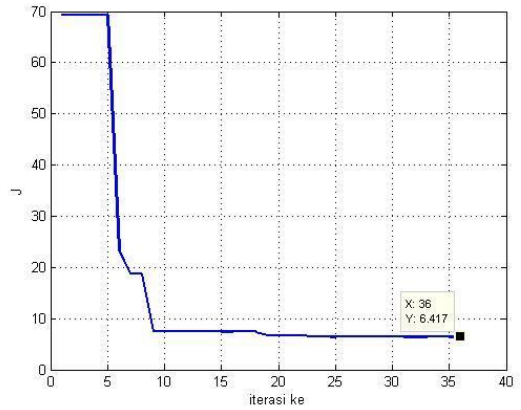

Gambar 4. Nilai Indeks Performansi Minimum Setiap Iterasi Menggunakan DEA

Pada Gambar 4 terlihat bahwanilai indeks performansi minimum sebesar 6.417.DEA membutuhkan waktu rata-rata kinerja CPU dalam dua puluh kali *running* sebesar 10.60157 detik. DEA akan dipengaruhi oleh evaluasi ke-j dari genarasi G $(rand_j)$ dalam studi kasus ini nilai $rand_j$ dilakukan secara otomatis oleh matlab dan hasil yang diperoleh adalah 0.9119. Matriks pembobotan error$Q$, matriks pembobotan kontrol$R$ yang meminimumkan fungsional objektif (indeks performansi) serta umpan balik optimum diperoleh sebagai berikut.

$$Q = \begin{bmatrix} 1.0765 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.7041 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.2399 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.4999 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.3699 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.3407 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 9.5063 \times 10^{-4} \end{bmatrix}$$

$$R = \begin{bmatrix} 0.2009 & 0 \\ 0 & 0.3477 \end{bmatrix}$$

$$K^T = \begin{bmatrix} 0.9830 & -0.0150 \\ -1.6538 & -0.1035 \\ -0.4828 & -0.0231 \\ -1.6320 & -0.2676 \\ 0.6974 & 7.6128 \times 10^{-4} \\ -0.0013 & 0.4075 \\ -0.0011 & -4.1573 \times 10^{-4} \end{bmatrix}$$

Selanjutnya mencari nilai kontrol optimum dengan menggunakan rumus $u^* = Kx$ diperoleh

$$u^{*T} = x^T K^T$$

$$= [\beta \quad \varphi \quad p \quad r \quad \delta_a \quad \delta_r \quad x_w] \begin{bmatrix} 0.9830 & -0.0150 \\ -1.6538 & -0.1035 \\ -0.4828 & -0.0231 \\ -1.6320 & -0.2676 \\ 0.6974 & 7.6128 \times 10^{-4} \\ -0.0013 & 0.4075 \\ -0.0011 & -4.1573 \times 10^{-4} \end{bmatrix}$$

Jadi, kontrol optimum yang bersesuaian dengan u_a adalah

$$u^* = 0.9830\beta - 1.6538\varphi - 0.4828p - 1.6320r + 0.6974\delta_a - 0.0013\delta_r - 0.0011x_w$$

dan kontrol optimum yang bersesuaian dengan u_r adalah

$$u^* = -0.0150\beta - 0.1035\varphi - 0.0231p - 0.2676r + 7.6128 \times 10^{-4}\delta_a + 0.4075\delta_r - 4.1573 \times 10^{-4}x_w$$

HASIL SIMULASI

Pada bagian ini diberikan perbandingan kinerja sistem lup tertutup dengan umpan balik keadaan yang dirancang dengan menggunakan algritma PSO dan DEA.

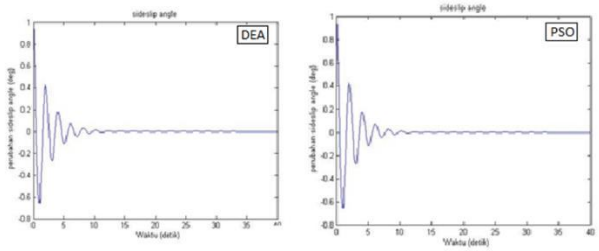

Gambar 5. Respon waktu dari sideslip angle

Gambar 5 menunjukkan simulasi *sideslip angle* menggunakan DEA dan PSO. Hasil simulasi DEA mempunyai respon waktu yang lebih cepat untuk mencapi keadaan steady state (stabil) dengan memerlukan waktu sekitar 9.3detik, dengan menggunakan toleransi 2%. Sedangkan dengan PSO, *sideslip angle*akan mencapai keadaan stabil dalam waktu kurang lebih 9.4 detik.

Simulasi *bank angle* menggunakan algoritma PSO dan DEA ditunjukkan pada Gambar 6. Hasil dari PSO menunjukkan bahwa *bank angle*akan mencapai keadaan stabil dalam waktu sekitar 15, 9 detik.%. Sedangkan dengan DEA, *bank angle* akan mencapai keadaan stabil dalam waktu kurang lebih 15, 4 detik.

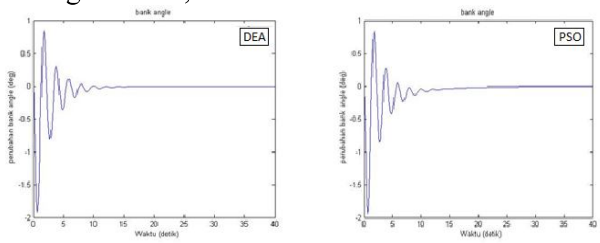

Gambar 6. Respon waktu dari bank angle

Berdasarkan hasil-hasil diatas dapat diperoleh bahwa kinerja sistem lup tertutup dengan umpan balik keadaan yang dieroleh dengan DEA lebih baik daripada dengan algoritma PSO.

KESIMPULAN DAN SARAN

Algoritma PSO dan DEA merupakan algoritma berbasis komputasi yang digunakan untuk menyelesaikan masalah optimasi. Salah satu contoh aplikasi dari algoritma PSO dan DEA adalah menentukan matriks pembobotan Q dan R dalam masalah LQR. Berdasarkan studi kasus, Algoritma DEA mempunyai kecepatan komputasi yang lebih tinggi dibandingkan dengan PSO. Dalam studi kasus ini, secara umum DEA mempunyai respon waktu yang lebih baik dibanding PSO dimana sistem akan lebih cepat menuju keadaan *steady state*. Algoritma PSO menghasilkan indeks performansi optimum sebesar 6.579 dengan membutuhkan waktu kinerja rata-rata CPU (*CPU Time*) dalam dua puluh kali *running* sebesar 21.14403 detik dan DEA menghasilkan indeks performansi optimum sebesar 6.417 dengan membutuhkan waktu kinerja rata-rata *CPU Time* dalam dua puluh kali *running* sebesar 10.60157 detik. Perbedaan kecepatan komputasi algoritma PSO dan DEA dipengaruhi oleh parameter-parameter yang terlibat di dalamnya. Namun, tidak menutup kemungkinan untuk studi kasus yang berbeda dan penggunaan nilai parameter yang berbeda akan menunjukkan pola hasil yang berbeda pula. Aplikasi dari algoritma PSO dan DEA dapat dikembangkan dalam masalah kontrol optimum lainnnya seperti maslah LQR-*tracking*.

DAFTAR PUSTAKA

[1] Ghoereishi, S. Amir. Arash Ahmadivand.March 2012. *State Feedback Design Aircraft Landing System With Using Differential Evolition Algorithm*. Advances in Computer Science and its Applications, Vol. 1, No 1.pp. 16-20.

[2] Hamidi, J. 2012. *Control System Design Using Particle Swarm Optimization (PSO)*. International Journal of Soft Computing and Engineering (IJSCE).Volume 1.Isssue 6. Pp 116-119

[3] Masten, Michael. K.et all. 1995. *Modern Control Systems*. Institute of Electrical and Electronics Engineers, Inc. USA.

[4] Mobayen S., Mohamady B.,H. Ghorbani, A. Rabii. January 2012. *Optimal Control Design Using Evolutary Algorithms With Application to an Aircraft Landing System*. Journal of Basic and Applied Scientiffic Research. Vol 2.pp 1876-1882

[5] Mobayen.S, A. Rabiei. M. Morabi, and B. Mohammady.November 2011. *Linier Quadratic Optimal Control System Design Using Particle Swarm Optimization Algoritm*. International Journal of The

Physical Sciences. Vol. 6(30). Pp. 6958-6966

[6] Nuri Seyman Muhammet, Taspinar Necmi. 2012. *Optimization of Pilot Tones Using Differential Evolution Algorithm in MIMO-OFDM Systems*. Journal Electronics Engineering and Computer Science.Vol 20.No 1. pp 15-23

[7] Ogata, Katsuhiko. 1990. *Teknik Kontrol Automatik (Sistem Pengaturan) jilid I*. Alih Bahasa Oleh Edi Leksono. Penerbit Erlangga : Jakarta

[8] Ratna wati, Dwi Ana. 2011. *Sistem Kendali Cerdas*. Penerbit Graha Ilmu : Yogyakarta

[9] Suyanto. 2008. *Evolutionary Computation : Komputasi Berbasis "Evolusi" dan "Genetika"*. Penerbit Informatika : Bandung

[10] Zeilinski, Karin. Rainer, Laur. 2007. *Stopping Criteria for a Constrained Single-Objective Particle Swarm Optimization Algorithm*. Journal Informatica.Vol. 31. Pp 51-59