

OPTIMASI PARAMETER MULTI-PASS MILLING MENGGUNAKAN HYBRID PSO-GA: STUDI AWAL

Fauzan¹, Muhammad Ikhwanus², T. Iqbal Faridiansyah³, Salahuddin⁴

¹Teknik Mesin, Universitas Malikussaleh, Aceh

^{2,3,4}Teknik Elektro Universitas Malikussaleh, Aceh

e-mail: fauzan@unimal.ac.id

Abstract: Optimizing multi-pass milling parameters is crucial for improving production efficiency. This study proposes a Hybrid Particle Swarm Optimization–Genetic Algorithm (HPSO-GA) featuring a co-evolutionary architecture—allocating 80% PSO for exploitation and 20% GA for exploration—to minimize total production time (T_{pr}). The mathematical model is adopted from prior work by Wang et al. (2022). Experiments conducted across four machining strategies over 30 independent runs show that HPSO-GA achieves the best T_{pr} of 3.081 minutes for Strategy 2, outperforming the baseline IPSO by 4.67%. Wilcoxon signed-rank test results confirm that HPSO-GA significantly outperforms standard PSO ($p < 0.05$), though it does not show a statistically significant difference compared to pure GA. Notably, for the more complex Strategy 3, pure GA proves to be superior. These preliminary findings suggest that HPSO-GA holds promise as a competitive optimization technique, with the caveat that its effectiveness is highly dependent on the underlying problem structure.

Keywords: parameter optimization, multi-pass milling, hybrid PSO-GA, production time.

Abstrak: Optimasi parameter pemesinan multi-pass milling penting untuk meningkatkan efisiensi produksi. Penelitian ini mengusulkan algoritma Hybrid Particle Swarm Optimization–Genetic Algorithm (HPSO-GA) dengan arsitektur ko-evolusi (80% PSO untuk eksploitasi, 20% GA untuk eksplorasi) untuk meminimalkan total waktu produksi (T_{pr}). Model matematis diadopsi dari penelitian sebelumnya (Wang et al., 2022). Eksperimen pada empat strategi pemesinan dengan 30 run menunjukkan HPSO-GA menghasilkan T_{pr} terbaik 3,081 menit pada Strategi 2, mengungguli baseline IPSO sebesar 4,67%. Uji Wilcoxon menegaskan HPSO-GA signifikan lebih baik dari PSO ($p < 0,05$) namun tidak berbeda signifikan dari GA murni. Pada Strategi 3 yang kompleks, GA murni justru lebih unggul. Hasil awal ini menunjukkan potensi HPSO-GA sebagai metode optimasi yang kompetitif, dengan catatan efektivitasnya bergantung pada struktur masalah.

Kata kunci: optimasi parameter, multi-pass milling, hybrid PSO-GA, waktu produksi.

PENDAHULUAN

Proses pemesinan milling merupakan salah satu operasi manufaktur yang paling umum digunakan dalam industri untuk membentuk komponen dengan geometri kompleks. Biasanya proses milling dilakukan dalam beberapa lintasan (multi-pass) untuk mencapai kedalaman pemotongan total yang diinginkan. Parameter pemesinan merupakan aspek utama untuk

dioptimalkan, meliputi kecepatan potong (cutting speed, V), kedalaman potong (depth of cut, a), dan gerak makan per gigi (feed per tooth, f_z) dengan konstrain berupa efisiensi, kualitas permukaan, dan biaya pemesinan (Tolouei-Rad & Bidhendi, 1997).

Permasalahan optimasi parameter multi-pass milling bersifat non-linear, multi-variabel, dan multi-batasan, sehingga sulit diselesaikan menggunakan metode optimasi dengan pendekatan

biasa. Pendekatan matematis klasik seperti pemrograman geometrik (geometric programming) telah diaplikasikan (Sönmez et al., 1999). Namun metode tersebut biasanya akan terjebak pada optimum lokal dan memerlukan asumsi penyederhanaan fungsi objektif.

Perkembangan algoritma metaheuristik membuka peluang baru dalam menyelesaikan permasalahan optimasi pemesinan yang kompleks. Algoritma Genetika (Genetic Algorithm, GA) yang diperkenalkan oleh Holland (Holland, 1992) telah berhasil diaplikasikan untuk optimasi parameter milling (Wang et al., 2022). Particle Swarm Optimization (PSO) yang dikembangkan oleh Kennedy dan Eberhart (Kennedy & Eberhart, 1995) juga menunjukkan performa kompetitif dalam optimasi parameter pemesinan (Rao & Pawar, 2010; Wang et al., 2022). Dalam rentang beberapa dekade, penelitian tentang optimasi multi-pass milling telah banyak dilakukan dengan berbagai pendekatan. Rao dan Pawar (Rao & Pawar, 2010) membandingkan algoritma ABC, PSO, dan SA untuk meminimalkan waktu produksi. Untuk optimasi multi-objektif multi-pass end milling, (Cai et al., 2024) mengintegrasikan firefly algorithm dan Markov clustering dengan tujuan meminimalkan waktu produksi serta kekasaran permukaan. Sebagai pembandingan dan dasar model, penelitian ini mengadopsi Improved PSO (IPSO) yang telah dikembangkan (Wang et al., 2022).

Meskipun PSO memiliki keunggulan dalam kecepatan menuju konvergensi, algoritma ini dianggap rapuh karena terjadi stagnasi prematur pada optimum local. Hal ini disebabkan karena kehilangan diversitas populasi di fase akhir iterasi. Adapun GA memiliki kemampuan eksplorasi yang lebih baik berkat operator crossover dan mutasinya (Shi & Eberhart, 1999). Konsep hybridisasi yang menggabungkan

kekuatan kedua algoritma telah diusulkan sebagai paradigma untuk meningkatkan performa optimasi (Abraham et al., 2007).

Berdasarkan latar belakang tersebut, penelitian ini mengusulkan algoritma Hybrid PSO-GA (HPSO-GA) untuk optimasi parameter proses multi-pass plain milling. Kontribusi penelitian ini meliputi: (1) desain arsitektur hybrid yang memisahkan operasi PSO pada 80% populasi terbaik dan operasi GA pada 20% populasi terburuk; (2) implementasi time-varying inertia weight dan velocity clamping untuk meningkatkan stabilitas konvergensi; (3) validasi statistik awal menggunakan uji Wilcoxon; dan (4) analisis komparatif terhadap PSO, GA, dan IPSO pada model matematis identik. Hasil penelitian ini diharapkan dapat memberikan alternatif metode optimasi yang lebih efektif dan menjadi referensi bagi penelitian selanjutnya di bidang optimasi pemesinan.

METODE

Desain Penelitian

Penelitian ini menggunakan pendekatan komputasional dengan desain eksperimen komparatif. Tiga algoritma (PSO, GA, dan HPSO-GA) dievaluasi pada empat strategi pemesinan dengan 30 run independen untuk setiap algoritma. Ruang lingkup penelitian adalah optimasi parameter multi-pass plain milling dengan total kedalaman potong 5 mm pada material baja karbon struktural.

Model Matematis

Model matematis yang digunakan mengacu pada (Wang et al., 2022) dengan fungsi tujuan meminimalkan total waktu produksi per komponen (T_{pr}), yang terdiri dari waktu persiapan (T_1) dan waktu produksi efektif (T_2):

$$T_{pr} = T_1 + T_2 \quad (1)$$

$$T_1 = \frac{T_s}{N_b} + T_L \quad (2)$$

$$T_2 = (n_r + 1)T_a + \sum T_{m,i} + T_d \sum \frac{T_{m,i}}{T_i} \quad (3)$$

dengan T_s adalah waktu setup, N_b ukuran batch, T_L waktu bongkar-muat, n_r jumlah rough pass, T_a waktu bantu, $T_{m,i}$ waktu pemesinan, T_d waktu ganti pahat, dan T_i umur pahat. Waktu pemesinan dihitung dari kecepatan potong (V), gerak makan per gigi (f_z), dan parameter geometri pahat (Tolouei-Rad & Bidhendi, 1997). Kendala yang diperhatikan meliputi daya motor, kekuatan arbor, dan defleksi arbor, yang ditangani dengan fungsi penalti adaptif (Wang et al., 2022).

Algoritma HPSO-GA

Arsitektur HPSO-GA mengintegrasikan PSO dan GA dalam satu populasi (Abraham et al., 2007):

1. Sorting: Evaluasi fitness seluruh individu, urutkan dari terbaik ke terburuk.
2. Fase PSO (80% terbaik): Perbarui posisi dan kecepatan partikel terbaik dengan time-varying inertia weight (0.9→0.4) dan velocity clamping (Shi & Eberhart, 1999). Pendekatan hybrid PSO dengan mekanisme serupa telah terbukti efektif dalam optimasi numerical control machining (Li et al., 2024)
3. Fase GA (20% terburuk): Proses individu terburuk dengan tournament selection, one-point crossover (prob. 0.8), dan Gaussian mutation (prob. 0.1) (Holland, 1992).
4. Re-evaluasi dan elitism: Update pbest untuk offspring GA, reset velocity, dan pertahankan global best di populasi.

Pseudocode HPSO-GA:

- 1 Inisialisasi populasi dan velocity
Evaluasi fitness awal, tentukan pbest dan gbest
- 2
- 3 Untuk t=1 sampai T_max:
- 4 $w = 0.9 - (0.9-0.4)t/T_max$
- 5 Evaluasi fitness, update pbest & gbest
- 6 Urutkan populasi
- 7 // PSO: 80% terbaik
- 8 Untuk i dalam 80% terbaik:
- 9 update kecepatan & posisi, clip ke bounds
- 10 // GA: 20% terburuk
- 11 Offspring = Crossover + Gaussian Mutation (20% terburuk)
- 12 Ganti 20% terburuk, reset velocity
- 13 Re-evaluasi fitness, update pbest
- 14 Jika gbest tidak dalam populasi, ganti individu terburuk

Teknik Pengumpulan dan Analisis Data

Data dikumpulkan dari 30 run independen untuk setiap kombinasi algoritma dan strategi. Parameter algoritma ditetapkan: populasi 20, iterasi 40, $c_1 = c_2 = 2.0$, $w_{start} = 0.9$, $w_{end} = 0.4$. Performa diukur dari nilai minimum (best), rata-rata (mean), dan standar deviasi (std) T_{pr} . Analisis statistik menggunakan uji Wilcoxon signed-rank test untuk membandingkan performa HPSO-GA terhadap PSO dan GA. Studi komparatif terbaru menunjukkan bahwa pendekatan metaheuristik seperti GA, SA, dan PSO memiliki karakteristik performa yang berbeda tergantung pada kompleksitas masalah optimasi pemesinan (Majeed et al., 2024).

HASIL DAN PEMBAHASAN

Hasil Optimasi

Empat strategi pemesinan (Tabel 1) dievaluasi. Hasil optimasi (Tabel 2) menunjukkan HPSO-GA unggul pada Strategi 1 dan 2, namun pada Strategi 3 GA murni lebih baik, dan pada Strategi 4

PSO sedikit unggul. Strategi 2 memberikan Tpr minimum secara keseluruhan, konsisten dengan penelitian sebelumnya (Rao & Pawar, 2010; Wang et al., 2022).

Tabel 1. Strategi Pemesinan

Strategi	Rough Pass (mm)	Finish Pass (mm)
1	2,0+2,0	1,0
2	1,5+1,5+1,5	0,5
3	2,0+1,0+1,0	1,0
4	1,0+1,0+1,0+1,0	1,0

Tabel 2. Hasil Optimasi Tpr (menit)

Strategi	Algoritma	Best	Mean	Std
1	PSO	3,050	8,823	2,731
	GA	3,135	5,843	2,222
	HPSO-GA	3,017	6,661	2,347
2	PSO	3,090	8,606	4,090
	GA	3,101	4,790	2,236
	HPSO-GA	3,081	5,900	3,590
3	PSO	3,603	10,548	3,496
	GA	3,569	7,258	3,196
	HPSO-GA	3,836	7,955	3,040
4	PSO	3,167	9,433	5,109
	GA	3,169	4,437	2,114
	HPSO-GA	3,184	5,821	3,114

Perbandingan dengan Baseline

Tabel 3 membandingkan hasil terbaik HPSO-GA pada Strategi 2 dengan baseline dari Wang (Wang et al., 2022). HPSO-GA (3,081 menit) mengungguli IPSO (3,232) sebesar 4,67%, bahkan PSO murni dan GA murni juga lebih baik dari

IPSO, menunjukkan pengaruh tuning parameter yang tepat.

Tabel 3. Perbandingan dengan Baseline Wang et al. (Wang et al., 2022)

Metode	Tpr (min)	Peningkatan vs IPSO
IPSO	3,232	-
PSO (penelitian ini)	3,090	4,39%
GA (penelitian ini)	3,101	4,05%
HPSO-GA (usulan)	3,081	4,67%

Parameter optimal pada Strategi 2: rough pass $f_z = 0,185$ mm/tooth, $V = 142,35$ m/min; finish pass $f_z = 0,092$ mm/tooth, $V = 198,72$ m/min.

Uji Statistik

Uji Wilcoxon signed-rank test (Tabel 4) menunjukkan HPSO-GA signifikan lebih baik dari PSO pada semua strategi ($p < 0,05$), namun tidak berbeda signifikan dengan GA murni ($p > 0,05$). Ini menegaskan bahwa hibridisasi berhasil mengatasi kelemahan PSO, tetapi GA murni tetap kompetitif.

Tabel 4. Hasil Uji Wilcoxon (p-value)

Strategi	HPSO-GA vs PSO	HPSO-GA vs GA
1	0,0029	0,9270
2	0,0068	0,6649
3	0,0015	0,8689
4	0,0033	0,9975

Hasil penelitian menunjukkan bahwa HPSO-GA efektif dalam mengatasi kelemahan PSO—yakni konvergensi prematur dan variansi tinggi—melalui mekanisme hibridisasi dengan GA. Berdasarkan uji coba pendahuluan, PSO diterapkan pada 80% populasi terbaik untuk memungkinkan eksploitasi intensif, sementara GA diterapkan pada 20% populasi terburuk untuk menjaga diversitas populasi.

Meskipun demikian, pada Strategi 3 dengan kedalaman rough pass bervariasi ([2,0; 1,0; 1,0] mm), GA murni (3,569 menit) mengungguli HPSO-GA (3,836 menit). Hal ini mengindikasikan bahwa efektivitas HPSO-GA bergantung pada struktur masalah; pada lanskap fitness yang tidak beraturan, GA dengan mekanisme crossover lebih fleksibel

SIMPULAN

Penelitian ini mengembangkan HPSO-GA untuk optimasi multi-pass milling. Hasil awal menunjukkan:

1. HPSO-GA menghasilkan Tpr terbaik 3,081 menit pada Strategi 2, mengungguli IPSO sebesar 4,67%.
2. HPSO-GA secara signifikan lebih baik dari PSO ($p < 0,05$), tetapi tidak berbeda signifikan dengan GA murni ($p > 0,05$).
3. Efektivitas HPSO-GA bergantung pada struktur strategi; pada strategi kompleks, GA murni lebih unggul.
4. Parameter optimal untuk Strategi 2 telah diidentifikasi dan dapat dijadikan referensi industri.

Penelitian selanjutnya direkomendasikan untuk mengintegrasikan optimasi jumlah pass, multi-objective (energi + kekasaran) (Kant & Sangwan, 2014), serta validasi eksperimental.

DAFTAR PUSTAKA

- Aqila, M. N., Roslita, I., Anisa, R., & Farhurohman, O. (2025). Analisis Model Discovery Learning Terhadap Kemampuan Berpikir Kritis Siswa Di Sekolah Dasar. *Jurnal Pengajaran Sekolah Dasar*, 4(2), 454–465. <https://doi.org/10.56855/jpsd.v4i2.1466>
- Asni, A., Wildan, W., & Hadisaputra, S. (2020). Pengaruh Model

dibandingkan PSO yang cenderung linier. Temuan ini sejalan dengan penelitian terbaru yang menunjukkan bahwa optimasi multi-pass memerlukan pendekatan yang disesuaikan dengan karakteristik operasi pemesinan (Benjdidia et al., 2023)

- Pembelajaran Inkuiri Terbimbing Terhadap Hasil Belajar Kimia Siswa Materi Pokok Hidrokarbon. *Chemistry Education Practice*, 3(1), 17. <https://doi.org/10.29303/cep.v3i1.14>
- Ayu Utami, R., & Sri Giarti. (2020). EFEKTIVITAS MODEL PEMBELAJARAN PROBLEM BASED LEARNING (PBL) DAN DISCOVERY LEARNING DITINJAU DARI KETERAMPILAN BERPILIR KRITIS SISWA KELAS 5 SD. *PeTeKa (Jurnal Penelitian Tindakan Kelas Dan Pengembangan Pembelajaran)*, 3(1), 8. <https://doi.org/10.31604/ptk.v3i1.1-8>
- Dwiyanti, W. A., Sabtiawan, W. B., & Mujiyanto. (2025). IMPLEMENTASI MODEL PEMBELAJARAN DISCOVERY LEARNING TERINTEGRASI TARL UNTUK MENINGKATKAN MOTIVASI DAN HASIL BELAJAR IPA. *Jurnal Pendidikan IPA*, 15(1), 17–26. <https://doi.org/10.24929/lensa.v15i1.496>
- Setianingsih, R., Novita, M., & Patonah, S. (2022). Kemampuan Berpikir Kritis Peserta Didik pada Pembelajaran Kimia dalam Pokok Bahasan Laju Reaksi di SMA Negeri 1 Bantarbolang. *Media Penelitian Pendidikan: Jurnal Penelitian Dalam Bidang Pendidikan Dan Pengajaran*, 16(1), 5–9. <https://doi.org/10.26877/mpp.v16i1.1806>
- Yuliati, C. L., & Susianna, N. (2023). Penerapan Model Pembelajaran Discovery Learning Dalam

Meningkatkan Keterampilan Proses
Sains, Berpikir Kritis, dan Percaya
Diri Siswa. *Scholaria: Jurnal*