

## ***Prediction Of Clay Mining Production Value Using Linear Regression Model With Multi-Swarm Particle Swarm Optimization***

**Gusti Eka Yulastuti<sup>1\*</sup>, Muchamad Kurniawan<sup>2</sup>, Dimas Pratikto<sup>3</sup>, Mochamad Rizky Moneter<sup>4</sup>**

<sup>1,2,3,4</sup>Informatics, Faculty of Electrical Engineering and Information Technology, Adhi Tama Institute of Technology Surabaya, Indonesia

Email: [gustiekay@itats.ac.id](mailto:gustiekay@itats.ac.id)

Received : Sep 7, 2024; Revised : Nov 30, 2024; Accepted : Dec 17, 2024; Published : Jun 10, 2025

### **Abstract**

*The progress of a nation or a country can be recognized from its income through various industries inside. Mining refers to one of the most advanced industries in Indonesia. The majority of mining in Indonesia is open-pit mining which is exposed directly to the sky. This study focuses on modeling data from rainfall, working hours, and production yields. It employed the Multi-Swarm Particle Swarm Optimization (MSPSO) algorithm to find multiple linear regression modeling by minimizing the Mean Squared Error (MSE) value. The value for the production results was then predicted using the existing multiple linear regression model. In terms of testing, the best model having an MSE of 288.0656 occurred at the parameters of Npop 180, acceleration coefficient 1 by 0.7, acceleration coefficient 2 by 0.7, acceleration coefficient 3 by 0.7, wmin 4, wmax 9 within 100 iterations.*

**Keywords:** linear regression, mining production, multi-swarm, particle swarm optimization

**This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License**



## **1. PENDAHULUAN**

Industri pertambangan merupakan salah satu industri yang paling unggul di Indonesia. Efektifitas kerja dan kualitas material dalam industri pertambangan sangat dipengaruhi oleh faktor cuaca yang beriklim tropis yakni musim kemarau dan hujan. Faktor cuaca tersebut berdampak pada metode penambangan dimana metode penambangan langsung terpapar oleh langit karena diatas permukaan bumi [1].

Adanya faktor yang tidak menentu tersebut memberikan dampak pada jumlah produksi tambang salah satu contohnya yakni tanah liat. Faktor yang tidak dapat diatur dan diprediksi tersebut menjadi faktor utama dimana terjadi ketidakstabilan nilai produksi tambang. Berdasarkan latar belakang tersebut, pentingnya memprediksi jumlah produksi agar perusahaan tidak mengalami ketidakstabilan serta meminimalisir biaya produksinya. Diharapkan dengan melakukan prediksi nilai produksi tambang, perusahaan dapat meningkatkan keuntungan yang dihasilkan.

Penelitian ini dilakukan di PT. United Tractors Semen Gresik (PT. UTSG) yang berada di Kabupaten Tuban, Jawa Timur. Berdasarkan data yang ada pada perusahaan PT. UTSG, dapat diketahui bahwa produksi tanah liat pada periode tahun 2013-2015 mengalami ketidakstabilan atau cenderung menurun. Dengan demikian dibutuhkan sebuah teknologi berdasarkan kecerdasan buatan yang dapat melakukan prediksi terhadap nilai produksi tambang salah satunya produksi tanah liat tersebut.

Kecerdasan buatan merupakan bagian dari ilmu komputer, dimana mempelajari cara membuat mesin (komputer) yang dapat melakukan tugas lebih baik serta dapat membantu manusia [2]. Semakin banyak pengetahuan dan pengalaman yang dimiliki mesin cerdas ini, tentu akan menjadi lebih mampu

dalam menyelesaikan permasalahan. Semakin besar data yang diolah berbanding lurus dengan semakin meningkatnya permasalahan yang harus diselesaikan, sehingga muncul banyak permintaan analisis data dengan memanfaatkan kecerdasan buatan [3].

Data terdiri dari fakta dan gambaran yang secara umum tidak dapat digunakan oleh *user*. Dengan adanya hasil pengukuran, fakta-fakta dan metode pengujian yang telah disimpan, menghasilkan sebuah data eksperimen yang besar. Mengakibatkan manusia tidak bisa memprosesnya secara langsung dan bersamaan. Dimana komputer belajar tentang cara mengajar diri sendiri, maka muncul berbagai macam algoritma kecerdasan buatan untuk menjembatani tugas yang sulit bagi manusia tetapi mudah untuk komputer [4]. Algoritma kecerdasan buatan yang dimiliki manusia ini yang nantinya dimodelkan pada mesin dan diprogram untuk terus belajar atau sering kita sebut machine learning [5].

## 2. METODE PENELITIAN

Adapun algoritma yang akan digunakan pada penelitian ini yakni model regresi linier dengan Multi Swarm Particle Swarm Optimization.

### 2.1. Regresi Linier Sederhana

Regresi linier sederhana merupakan hubungan dua variabel, yaitu variabel dependen (terikat) dan variabel independen (bebas) [5]. Regresi linier sederhana adalah persamaan regresi yang menggambarkan hubungan antara variabel bebas (X) dan variabel terikat (Y), dengan hubungan antara kedua variabel tersebut dapat digambarkan sebagai garis lurus [6]. Hubungan kedua variabel tersebut dapat dituliskan dalam bentuk persamaan 1.

$$Y = \alpha + \beta X + \varepsilon \quad (1)$$

Bentuk persamaan penduga dari persamaan 1 dapat dituliskan seperti persamaan 2.

$$\hat{Y} = \hat{\alpha} + \hat{\beta}X \text{ atau } Y = a + bX \quad (2)$$

Dimana,

Y = Peubah tak bebas (*dependent variable*)

X = Peubah bebas (*independent variable*)

a = Perpotongan kurva dengan sumbu tegak (sumbu Y) atau Konstanta

B = Kemiringan atau gradient kurva linier

$\varepsilon$  = Pengaruh kesalahan/ galat

$\alpha$  = Penduga bagi  $\alpha$

b = Penduga bagi  $\beta$

Penaksir kuadrat terkecil dari parameter regresi dapat diperoleh dengan meminimalkan nilai kesalahan atau *error*. Dengan menggunakan perhitungan diperoleh nilai estimasi parameter regresi seperti persamaan 3 dan 4.

$$\alpha = \frac{(\sum_{i=1}^n X_i^2)(\sum_{i=1}^n Y_i) - (\sum_{i=1}^n X_i)(\sum_{i=1}^n X_i Y_i)}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \quad (3)$$

$$b = \frac{n \sum_{i=1}^n X_i Y_i - \sum_{i=1}^n X_i \sum_{i=1}^n Y_i}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \quad (4)$$

Rumus lain untuk mencari nilai koefisien a, jika koefisien b dihitung terlebih dahulu ditunjukkan seperti persamaan 5.

$$a = \bar{Y} - b\bar{X} \quad (5)$$

Dimana  $\bar{Y}$  dan  $\bar{X}$  untuk mencari penentuan koefisien regresi. Besarnya nilai a dapat diinterpretasikan: pada saat X bernilai nol, besarnya dugaan nilai Y adalah sebesar a, sedangkan besarnya nilai b dapat diinterpretasikan: besarnya perubahan nilai Y jika terjadi perubahan satu satuan pada nilai X.

## 2.2. Regresi Linier Berganda

Jika pada regresi linier sederhana melibatkan satu peubah bebas, pada regresi linier berganda melibatkan lebih dari satu peubah bebas dalam pembuatan persamaannya [7]. Pada teknik regresi linier berganda, membuat persamaan penduga yang memiliki hubungan variabel terikat (Y) terhadap variabel bebas ( $X_1, X_2, X_3, \dots, X_k$ ) untuk menaksir nilai Y. Hubungan antara variabel-variabel tersebut dapat dirumuskan dalam bentuk persamaan 6.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_k \quad (6)$$

Bentuk persamaan penduga dari persamaan 6 dapat dituliskan seperti persamaan 7.

$$\hat{Y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_k \quad (7)$$

Dimana,

Y = Peubah tak bebas

$X_1, X_2, X_3, \dots, X_k$  = Peubah bebas

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$  = Koefisien Regresi/ parameter

$b_1, b_2, b_3, \dots, b_k$  = Koefisien penduga dari parameter

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$  = Variabel kesalahan(galat)

Dengan melakukan pencarian nilai koefisien dari  $(\beta_0, \beta_1, \beta_2, \dots, \beta_k)$  menggunakan rumus tersebut, maka akan diperoleh sebuah nilai dari koefisien regresi yang kemudian dapat membentuk sebuah model atau persamaan regresi.

## 2.3. Particle Swarm Optimization

*Particle Swarm Optimization* (PSO) merupakan algoritma yang berfokus pada penyelesaian masalah optimasi dalam melakukan pencarian ruang untuk mendapatkan solusi optimal [8]. PSO terinspirasi dari perilaku sosial hewan, seperti sekawanan burung saat mencari sumber makanannya [9]. Setiap individu dalam PSO akan dianggap sebagai partikel yang berperilaku menggunakan kecerdasannya dan juga dipengaruhi oleh kelompok kawanannya [10]. Faktor utama yang mempengaruhi sebuah partikel atau seekor burung dalam pencarian jalan yang tepat untuk mendapatkan sebuah sumber makanan yaitu posisi partikel dan kecepatan partikel [11]. Adapun persamaan yang menggambarkan posisi dan kecepatan seperti ditunjukkan pada persamaan 8 dan 9.

$$x_j(i) = x_1(1), x_2(1), \dots, x_{jN}(i) \quad (8)$$

$$v_j(i) = v_1(1), v_2(1), \dots, v_{jN}(i) \quad (9)$$

Dimana,

$x_j$  = Posisi partikel

$v_j$  = Kecepatan partikel

$i$  = Iterasi ke  $i$

$j$  = Indeks Partikel

$N$  = Jumlah Partikel

Langkah-langkah penyelesaian suatu permasalahan dengan menggunakan algoritma PSO yakni sebagai berikut [12]:

1. Menentukan jumlah partikel yang akan digunakan.
2. Menentukan posisi dan kecepatan partikel secara random.
3. Mengevaluasi nilai *fitness* menggunakan rumus persamaan yang telah ditentukan sebelumnya dari masing-masing partikel berdasarkan posisinya.
4. Menentukan partikel dengan *fitness* terbaik untuk dijadikan *Gbest*.
5. Menentukan *Pbest* awal sama dengan posisi awal.
6. Menggunakan *Pbest* dan *Gbest* yang ada, kemudian memperbarui kecepatan partikel dengan menggunakan persamaan 10.

$$V_i(t) = V_i(t-1)C_1R_1(X_i^L - X_i(t-1)) + C_2R_2(X^G - X_i(t-1)) \quad (10)$$

Dimana,

V = Kecepatan partikel

X = Posisi partikel

$V_i$  = Kecepatan partikel pada suatu indeks

T = Iterasi ke-t

I = Indeks partikel

R1 dan R2 = Nilai *random* dengan *range* antara 0 sampai 1

C1 dan C2 = Konstanta yang bernilai positif yang biasanya disebut sebagai *learning factor*

XL = *Local best* dari suatu partikel

XG = *Global best* dari seluruh kawanan

7. Memperbarui posisi masing-masing partikel dengan menggunakan persamaan 11.

$$X_i(t) = V_i(t) + X_i(t-1) \quad (11)$$

8. Mengevaluasi kembali nilai *fitness* dari tiap partikel.
9. Menentukan partikel dengan *fitness* terbaik untuk dijadikan sebagai *Gbest*. Pada setiap partikel, menentukan *Pbest* dengan membandingkan posisi sekarang dengan *Pbest* pada iterasi sebelumnya.
10. Mengecek apakah semua posisi partikel konvergen. Jika ya, maka berhenti. Partikel dinyatakan konvergen apabila semua posisi partikel berada pada posisi yang sama atau sangat berdekatan dengan partikel *Gbest* dan tidak memiliki perkembangan posisi pada iterasi berikutnya. Posisi partikel yang konvergen menandakan bahwa solusi telah ditemukan.

## 2.4. Multi-Swarm Particle Swarm Optimization

*Multi-Swarm Particle Swarm Optimization* (MSPSO) merupakan inspirasi dari kawanan yang ada di ekosistem alami, dimana total dari seluruh populasi terdiri dari kawanan master dan kawanan anak [13]. Setiap kawanan anak akan bergerak sebagai satu PSO, sementara kawanan master bergerak sesuai pengetahuannya sendiri [14]. MSPSO terdiri dari banyak kawanan yang berbagi informasi tentang nilai terbaik di setiap kawanan [15]. Adapun rumus untuk pembaruan kecepatan untuk mendapatkan nilai *Pbest*, *Gbest* dan *Mbest* seperti ditunjukkan pada persamaan 12 dan 13.

$$V_{k_{id}}(t+1) = WV_{k_{id}}(t) + C_1R_1(Pk_{id}(t) - Xk_{id}(t)) + C_2R_2(Pk_{gd}(t) - Xk_{gd}(t)) + C_3R_3(P_{wd}(t) - Xk_{id}(t)) \quad (12)$$

$$Xk_{id}(t+1) = Xk_{id}(t) + V_{k_{id}}(t-1) \quad (13)$$

Dimana,

$K$  = Tiap kawanan

$D$  = Dimensi partikel

$R1, R2, R3$  = Nilai random dengan range antara 0 sampai 1


$C1, C2, C3$  = Konstanta yang bernilai positif / learning factor

$W$  = Berat Partikel

$V$  = Kecepatan partikel

$X$  = Posisi partikel

Adapun alur proses dari algoritma optimasi yaitu Multi-Swarm Particle Swarm Optimization (MSPSO) seperti ditunjukkan pada Gambar 1. Proses awal yaitu inialisasi sebuah populasi beberapa swarm dan populasi. Selanjutnya proses menghitung nilai fitness menggunakan fungsi objektif serta menentukan nilai pbest dan gbest dari suatu partikel swarm. Selanjutnya update nilai velocity dan posisi swarm. Langkah terakhir yaitu perulangan jika iterasi yang telah ditentukan telah sesuai.



Gambar 1 Flowchart Alur MSPSO

### 3. HASIL DAN PEMBAHASAN

Pengujian ini dilakukan untuk mengetahui parameter algoritma *Multi-Swarm Particle Swarm Optimization* (MSPSO) yang paling optimal dalam menentukan model regresi linier untuk prediksi nilai produksi tanah liat. Parameter MSPSO yang diuji coba adalah ukuran populasi tiap *swarm* dan kombinasi koefisien akselerasi. Dimana nantinya terdapat nilai parameter yang bernilai acak.

Dari hasil pengujian populasi tiap *swarm* akan diambil parameter terbaiknya untuk pengujian kombinasi nilai koefisien akselerasi pada pengujian berikutnya. Untuk memperoleh hasil pengujian yang lebih maksimal, maka nilai acak tersebut harus diinisialisasikan secara langsung dalam kode program. Parameter yang akan diinisialisasi/statis adalah *NDim* sebesar 3 dan *NSwarm* sebesar 3. Hal ini dilakukan supaya penelitian sesuai dengan harapan pada setiap percobaan, sehingga nilai *fitness* yang diperoleh terhindar dari nilai yang fluktuatif.

#### 3.1. Pengujian Ukuran Populasi MSPSO

Penulis melakukan pengujian ukuran populasi *Npop* pada tiap *swarm* yang tepat guna mendapatkan kombinasi model regresi linier yang optimal. Pengujian ini dilakukan dengan menghitung rata-rata nilai MSE percobaan pada tiap kategori ukuran populasi *swarm*. Adapun beberapa parameter yang digunakan untuk menguji ukuran populasi seperti ditunjukkan Tabel 1.

Tabel 1 Parameter Pengujian Ukuran Populasi MSPSO

| No | Nama                                | Nilai    |
|----|-------------------------------------|----------|
| 1  | Bobot inersia Minimum ( $W_{min}$ ) | 0,4      |
| 2  | Bobot inersia Maximum ( $W_{max}$ ) | 0,9      |
| 3  | Koefisien akselerasi 1 ( $C_1$ )    | 0,5      |
| 4  | Koefisien akselerasi 2 ( $C_2$ )    | 0,7      |
| 5  | Koefisien akselerasi 3 ( $C_3$ )    | 0,9      |
| 6  | Ukuran Populasi (Npop)              | 20 - 200 |
| 7  | Jumlah Iterasi (MaxIt)              | 20       |

Beberapa parameter yang telah diinisialisasi dalam kode program adalah jumlah dimensi sebesar 3 dan jumlah *swarm* sebesar 3. Pengujian dilakukan sebanyak 10 kali dan pada setiap data uji ukuran populasi *swarm* dilakukan pengulangan pengujian sebanyak 5 kali percobaan. Hasil pengujian ukuran populasi *swarm* seperti ditunjukkan pada Tabel 2.

Tabel 2 Hasil Pengujian Ukuran Populasi

| Pop | Percobaan Ke- |        |        |        |        | Avg<br>Mse | Std  | Avg<br>Time |
|-----|---------------|--------|--------|--------|--------|------------|------|-------------|
|     | 1             | 2      | 3      | 4      | 5      |            |      |             |
| 20  | 306,09        | 307,87 | 307,74 | 305,30 | 306,05 | 306,61     | 1,14 | 6,0         |
| 40  | 307,81        | 306,99 | 305,27 | 307,08 | 305,61 | 306,55     | 1,07 | 11,7        |
| 60  | 307,03        | 305,09 | 307,16 | 305,38 | 306,42 | 306,22     | 0,94 | 17,9        |
| 80  | 289,37        | 307,85 | 305,55 | 302,61 | 308,33 | 302,75     | 7,81 | 30,4        |
| 100 | 306,91        | 305,22 | 307,01 | 304,46 | 306,67 | 306,05     | 1,15 | 38,7        |
| 120 | 302,33        | 304,62 | 307,36 | 306,43 | 307,44 | 305,64     | 2,17 | 38,1        |
| 140 | 304,55        | 302,96 | 300,26 | 304,46 | 303,47 | 303,14     | 1,74 | 45,8        |
| 160 | 307,32        | 305,51 | 303,06 | 303,98 | 295,83 | 303,14     | 4,39 | 55,5        |
| 180 | 304,79        | 303,29 | 296,48 | 288,10 | 304,01 | 299,33     | 7,10 | 58,3        |
| 200 | 300,37        | 305,26 | 307,14 | 307,22 | 294,64 | 302,93     | 5,40 | 111,5       |

Berdasarkan Tabel 2, analisis dari 5 kali percobaan pada *dataset* produksi tanah liat dapat ditarik kesimpulan bahwa setiap adanya penambahan populasi menghasilkan nilai *error* yang bermacam-macam. Dari tabel hasil pengujian tersebut didapatkan ukuran populasi terbaik sebesar 180 dengan memperoleh nilai *error* terkecil sebesar 299,33.

Pada saat ukuran populasi sebesar 180, hasil tersebut dianggap sudah konvergen atau nilai *error* dianggap stabil. Bertambahnya jumlah partikel juga mempengaruhi ruang pencarian tiap iterasi menjadi semakin luas, sehingga mengakibatkan semakin besar peluang untuk memperoleh solusi yang optimal. Langkah selanjutnya yaitu mendapatkan nilai parameter optimal seperti ditunjukkan pada Tabel 3.

Tabel 3 Parameter Optimal MSPSO

| Parameter Optimal |            |             |
|-------------------|------------|-------------|
| A                 | B          | C           |
| 1.12595223        | 0.92031011 | -0.00918389 |


Setelah melalui tahapan optimasi dan mendapatkan nilai parameter yang optimal, selanjutnya parameter tersebut dijadikan sebagai nilai masukan parameter model regresi linier berganda dan

dilanjutkan perhitungan untuk mendapatkan hasil peramalan. Adapun hasil peramalan ditunjukkan pada Tabel 4.

Tabel 4 Hasil Peramalan Regresi Linier Berganda

| Bulan | Aktual  | Prediksi |
|-------|---------|----------|
| 1     | 82,359  | 80,741   |
| 2     | 103,086 | 84,462   |
| 3     | 109,17  | 94,002   |
| 4     | 84,213  | 86,056   |
| 5     | 77,31   | 95,235   |
| 6     | 30,942  | 29,538   |
| 7     | 5,022   | 7,057    |
| 8     | 1,224   | 3,882    |
| 9     | 77,373  | 52,651   |
| 10    | 96,426  | 33,075   |
| 11    | 79,695  | 64,455   |
| 12    | 0       | -0,568   |
| 13    | 63,747  | 58,406   |
| 14    | 6,282   | 8,716    |
| 15    | 18,036  | 20,149   |
| 16    | 9,846   | 19,988   |
| 17    | 68,067  | 62,923   |
| 18    | 30,411  | 46,199   |
| 19    | 52,146  | 71,811   |
| 20    | 42,19   | 35,641   |
| 21    | 0       | 1,508    |
| 22    | 0       | 1,481    |
| 23    | 86,445  | 85,812   |
| 24    | 75,447  | 83,818   |
| 25    | 95,949  | 93,707   |
| 26    | 74,817  | 83,905   |
| 27    | 111,366 | 98,782   |
| 28    | 75,546  | 79,517   |
| 29    | 137,574 | 99,289   |
| 30    | 110,61  | 109,915  |
| 31    | 126,855 | 111,796  |
| 32    | 103,923 | 140,145  |
| 33    | 110,882 | 139,733  |
| 34    | 118,855 | 128,340  |
| 35    | 109,627 | 111,267  |
| 36    | 116,235 | 122,173  |

Hasil peramalan memiliki tingkat akurasi yang cukup baik dibandingkan dengan data aktual yang sebelumnya. Hasil peramalan diperuntukkan 3 tahun dari data aktual. Adapun gambar grafik hasil peramalan ditunjukkan seperti Gambar 2.




Gambar 2 Grafik Hasil Peramalan

Grafik pada Gambar 2 merupakan hasil peramalan. Terlihat pada tahun pertama mengalami penurunan, tahun kedua konstan dengan nilai aktual, namun pada tahun terakhir mengalami kenaikan dari nilai aktual sebelumnya. Setelah dilakukan perhitungan nilai ramalan selanjutnya didapatkan nilai *error* dan *time/second*. Hasil nilai *error* dengan ukuran populasi *swarm* terbaik sebesar 180 seperti ditunjukkan pada Tabel 5.

Tabel 5 Nilai Error MSPSO Ukuran Populasi Swarm Terbaik

| Nilai Error  |        |
|--------------|--------|
| MSE          | 304,79 |
| Time/seconds | 52,25  |

Nilai *error* yang dihasilkan cukup optimal dalam memberikan solusi permasalahan optimasi yang dihadapi. Adapun grafik nilai MSE dengan ukuran populasi terbaik yang berguna untuk mengetahui nilai *error* konstan pada iterasi ditunjukkan seperti pada Gambar 3.



Gambar 3 Grafik Nilai Error Hasil Uji Ukuran Populasi Swarm Terbaik

Berdasarkan Gambar 3, hasil uji ukuran populasi *swarm* terbaik memperoleh nilai MSE konstan pada iterasi ke 16.

### 3.1. Pengujian Koefisien Akselerasi MSPSO

Pengujian pada *Multi-Swarm Particle Swarm Optimization* (MSPSO) terdapat penambahan koefisien akselerasi yakni *Master Best*. Untuk mendapatkan kombinasi koefisien akselerasi 1 ( $C_1$ ), 2 ( $C_2$ ) dan 3 ( $C_3$ ) yang tepat sehingga dapat memberikan solusi optimal pada model regresi linier berganda untuk prediksi nilai produksi tambang salah satunya tanah liat. Pengujian dilakukan dengan menghitung nilai rata-rata *error* setiap data uji koefisien akselerasi. Pada nilai ukuran populasi yang diambil dari hasil pengujian ukuran populasi terbaik sebelumnya yakni sebesar 180. Adapun parameter yang digunakan dalam pengujian koefisien akselerasi seperti ditunjukkan pada Tabel 6.

Tabel 6 Parameter Pengujian Koefisien Akselerasi MSPSO

| No | Nama | Nilai |
|----|------|-------|
|----|------|-------|

|   |                                     |                  |
|---|-------------------------------------|------------------|
| 1 | Bobot inersia Minimum ( $W_{min}$ ) | 0,4              |
| 2 | Bobot inersia Maximum ( $W_{max}$ ) | 0,9              |
| 3 | Koefisien akselerasi 1 ( $C_1$ )    | 0,5; 0,7;<br>0,9 |
| 4 | Koefisien akselerasi 2 ( $C_2$ )    | 0,5; 0,7;<br>0,9 |
| 5 | Koefisien akselerasi 3 ( $C_3$ )    | 0,5; 0,7;<br>0,9 |
| 6 | Ukuran Populasi (Npop)              | 180              |
| 7 | Jumlah Iterasi (MaxIt)              | 100              |

Pengujian koefisien akselerasi 1, 2 dan 3 dengan nilai 0,5 ; 0,7 ; 0,9 dilakukan pada setiap pengujian sebanyak 5 kali percobaan. Hasil pengujian koefisien akselerasi MSPSO seperti ditunjukkan pada Tabel 7.

Tabel 7 Hasil Pengujian Koefisien Akselerasi MSPSO

| Koefisien |     |     | Percobaan Ke - |    |    |    |            | Avg Mse     | Std     | Avg Time |
|-----------|-----|-----|----------------|----|----|----|------------|-------------|---------|----------|
|           |     |     | 1              | .. | .. | .. | 5          |             |         |          |
| C1        | C2  | C3  | Mse            | .. | .. | .. | Mse        |             |         |          |
| 0,5       | 0,7 | 0,9 | 288,065582     | .. | .. | .. | 288,065583 | 288,0655810 | 1,5E-06 | 264,5    |
| 0,5       | 0,5 | 0,9 | 288,065579     | .. | .. | .. | 288,065579 | 288,0655795 | 1,7E-06 | 263,1    |
| 0,5       | 0,5 | 0,5 | 288,065585     | .. | .. | .. | 288,065579 | 288,0655799 | 3,0E-06 | 265,2    |
| 0,7       | 0,7 | 0,9 | 288,065580     | .. | .. | .. | 288,065582 | 288,0655807 | 2,2E-06 | 266,1    |
| 0,7       | 0,5 | 0,9 | 288,065579     | .. | .. | .. | 288,065578 | 288,0655793 | 1,3E-06 | 284,4    |
| 0,7       | 0,7 | 0,7 | 288,065579     | .. | .. | .. | 288,065579 | 288,0655789 | 3,7E-07 | 263,9    |
| 0,9       | 0,7 | 0,9 | 288,065578     | .. | .. | .. | 288,065579 | 288,0655792 | 1,0E-06 | 261,0    |
| 0,9       | 0,7 | 0,5 | 288,065581     | .. | .. | .. | 288,065580 | 288,0655802 | 1,5E-06 | 259,5    |
| 0,9       | 0,9 | 0,9 | 288,065591     | .. | .. | .. | 288,065580 | 288,0655847 | 4,2E-06 | 266,0    |

Berdasarkan Tabel 7, analisis dari 9 pengujian koefisien akselerasi didapatkan nilai kombinasi terbaik yakni  $C_1 = 0,7$ ,  $C_2 = 0,7$  dan  $C_3 = 0,7$  dengan rata-rata nilai MSE terkecil sebesar 288,0655789. Nilai tersebut didapatkan dengan rata-rata waktu eksekusi kode program selama 263,9 detik dimana waktu tersebut cukup optimal sebagai solusi dalam suatu penyelesaian permasalahan optimasi yang dihadapi.

Peluang untuk memperoleh hasil konvergen dengan solusi terbaik semakin kecil disebabkan adanya pengumpulan partikel dengan kemungkinan solusi terbaik ke wilayah yang akan memiliki solusi optimal. Rata-rata nilai *error* mengalami kenaikan yang disebabkan oleh koefisien *personal best*, *global best* dan *master best* semakin tinggi. Hal ini menunjukkan bahwa pengaruh koefisien akselerasi pada *personal best*, *global best* dan *master best* harus sama. Selanjutnya adalah tabel parameter optimal koefisien akselerasi MSPSO ditunjukkan seperti pada Tabel 8.

Tabel 8 Parameter Optimal Koefisien Akselerasi MSPSO


| Parameter Optimal |            |             |
|-------------------|------------|-------------|
| A                 | B          | C           |
| 9.51847773        | 0.84266018 | -0.02145765 |

Setelah melalui tahapan optimasi dan mendapatkan nilai parameter yang optimal. Nilai parameter tersebut selanjutnya dijadikan sebagai nilai masukan parameter model regresi linier berganda dan dilakukan perhitungan untuk mendapatkan hasil peramalan. Adapun hasil peramalan ditunjukkan pada Tabel 9.

Tabel 9 Hasil Peramalan Koefisien Akselerasi

| Bulan | Aktual  | Prediksi |
|-------|---------|----------|
| 1     | 82,359  | 80,366   |
| 2     | 103,086 | 85,724   |
| 3     | 109,17  | 92,661   |
| 4     | 84,213  | 82,553   |
| 5     | 77,31   | 92,499   |
| 6     | 30,942  | 34,796   |
| 7     | 5,022   | 13,635   |
| 8     | 1,224   | 11,700   |
| 9     | 77,373  | 56,539   |
| 10    | 96,426  | 37,838   |
| 11    | 79,695  | 66,549   |
| 12    | 0       | 1,677    |
| 13    | 63,747  | 58,185   |
| 14    | 6,282   | 15,161   |
| 15    | 18,036  | 23,011   |
| 16    | 9,846   | 25,282   |
| 17    | 68,067  | 65,685   |
| 18    | 30,411  | 50,606   |
| 19    | 52,146  | 73,928   |
| 20    | 42,19   | 40,665   |
| 21    | 0       | 9,517    |
| 22    | 0       | 9,414    |
| 23    | 86,445  | 87,027   |
| 24    | 75,447  | 81,041   |
| 25    | 95,949  | 92,303   |
| 26    | 74,817  | 82,338   |
| 27    | 111,366 | 96,438   |
| 28    | 75,546  | 79,802   |
| 29    | 137,574 | 99,246   |
| 30    | 110,61  | 109,101  |
| 31    | 126,855 | 110,917  |
| 32    | 103,923 | 136,981  |
| 33    | 110,882 | 136,602  |
| 34    | 118,855 | 126,127  |
| 35    | 109,627 | 110,072  |
| 36    | 116,235 | 115,696  |

Hasil peramalan memiliki tingkat akurasi yang cukup baik dibandingkan dengan data aktual yang sebelumnya. Hasil peramalan diperuntukkan 3 tahun dari data aktual. Adapun gambar grafik hasil peramalan ditunjukkan seperti Gambar 4.




Gambar 4 Grafik Hasil Peramalan Koefisien Akselerasi

Grafik pada Gambar 4 merupakan hasil peramalan. Terlihat pada tahun pertama mengalami penurunan, tahun kedua mengalami kenaikan dengan nilai aktual dan pada tahun terakhir mengalami kenaikan konstan dari nilai aktual sebelumnya. Setelah dilakukan perhitungan nilai ramalan selanjutnya didapatkan nilai *error* dan *time/second*. Hasil nilai *error* berdasarkan nilai koefisien akselerasi terbaik seperti ditunjukkan pada Tabel 10.

Tabel 10 Nilai Error MSPSO Koefisien Akselerasi Terbaik

| Nilai Error  |         |
|--------------|---------|
| MSE          | 288,065 |
| Time/seconds | 268,8   |

Nilai *error* yang dihasilkan cukup optimal dalam memberikan solusi permasalahan optimasi yang dihadapi. Adapun grafik nilai MSE dengan koefisien akselerasi terbaik yang berguna untuk mengetahui nilai *error* konstan pada iterasi ditunjukkan seperti pada Gambar 5.



Gambar 5 Grafik Nilai Error Hasil Uji Koefisien Akselerasi Terbaik

Berdasarkan Gambar 5, hasil uji koefisien akselerasi terbaik memperoleh nilai MSE konstan pada iterasi ke 96.

#### 4. DISKUSI

Berdasarkan hasil pengujian MSPSO, dapat disimpulkan nilai MSE yang dihasilkan cukup baik. Hasil pengujian MSPSO terhadap regresi linier berganda menghasilkan nilai MSE yang cukup baik namun belum signifikan. Solusi yang diharapkan dari optimasi ini adalah dapat memperoleh kombinasi optimal model regresi linier berganda menggunakan MSPSO.

#### 5. KESIMPULAN

Berdasarkan hasil pengujian yang telah dilakukan, MSPSO termasuk algoritma yang cukup baik dalam melakukan peramalan prediksi nilai produksi tambang salah satu contohnya yakni tanah liat. Cara menyelesaikan permasalahan optimasi model regresi linier berganda pada *dataset* produksi tanah liat memperoleh hasil *error* minimum dengan nilai MSE sebesar 288,0656.

Metode MSPSO mendapatkan nilai kombinasi regresi linier berganda  $A = 9.518477$ ,  $B = 0.842660$ ,  $C = -0.021457$ . Nilai kombinasi tersebut diambil dari percobaan koefisien akselerasi sebesar  $C_1 = 0,7$ ;

$C_2 = 0,7$  dan  $C_3 = 0,7$ . Dengan adanya nilai parameter koefisien akselerasi pada MSPSO sangat berpengaruh terhadap perhitungan nilai *velocity* untuk memperoleh hasil nilai *error* yang lebih kecil.

#### DAFTAR PUSTAKA

- [1] L. Utamakno, A. Budianto, and E. Priambodo, "Analisa Penurunan Produksi Lempung Terhadap Pengaruh Curah Hujan dengan Metode Regresi Linier," *Promine*, vol. 6, no. 2, pp. 1–4, 2019, doi: 10.33019/promine.v6i2.777.
- [2] B. Karyadi, "Pemanfaatan Kecerdasan Buatan dalam Mendukung Pembelajaran Mandiri," *Educ. J. Teknol. Pendidik.*, vol. 8, no. 2, pp. 253–258, 2023, doi: 10.32832/educate.v8i02.14843.
- [3] T. P. Nugrahanti, N. Puspitasari, and I. R. Andaningsih, "Transformasi Praktik Akuntansi Melalui Teknologi: Peran Kecerdasan Buatan, Analisis Data, dan Blockchain dalam Otomatisasi Proses Akuntansi," *J. Akunt. Dan Keuang. West Sci.*, vol. 2, no. 03, pp. 213–221, 2023, doi: 10.58812/jakws.v2i03.644.
- [4] P. Yang, S. Untuk, and P. Mahasiswa, "Pemanfaatan Kecerdasan Buatan pada Algoritma K-Means Klustering dan Sentiment Analysis Terhadap Strategi Promosi yang Sukses untuk Penerimaan Mahasiswa Baru," *J. Sist. Inf. Univ. Suryadarma*, vol. 11, no. 1, pp. 1–6, 2014, doi: 10.35968/jsi.v11i1.1120.
- [5] A. A. Permana *et al.*, *Machine Learning*, vol. 45, no. 13, 2023.
- [6] Harsiti, Z. Muttaqin, and E. Srihartini, "Penerapan Metode Regresi Linier Sederhana untuk Prediksi Persediaan Obat Jenis Tablet," *JSiI (Jurnal Sist. Informasi)*, vol. 9, no. 1, pp. 12–16, 2022, doi: 10.30656/jsii.v9i1.4426.
- [7] C. A. Rahmat, K. Kurniabudi, and Y. Novianto, "Penerapan Metode Regresi Linier Berganda Untuk Mengestimasi Laju Pertumbuhan Penduduk Kabupaten Musi Banyuasin," *J. Inform. dan Rekayasa Komput.*, vol. 3, no. 1, pp. 359–369, 2023, doi: 10.33998/jakakom.2023.3.1.732.
- [8] T. M. Shami, A. A. El-Saleh, M. Alswaiti, Q. Al-Tashi, M. A. Summakieh, and S. Mirjalili, "Particle Swarm Optimization: A Comprehensive Survey," *IEEE Access*, vol. 10, pp. 10031–10061, 2022, doi: 10.1109/ACCESS.2022.3142859.
- [9] D. Chaerullah, I. Chalid, and A. Solichin, "Analysis of Implementation of Particle Swarm Optimization (PSO) Method on Lecturers Assignments to Students," *J. Tek. Inform.*, vol. 4, no. 5, pp. 1151–1156, 2023, doi: 10.52436/1.jutif.2023.4.5.1002.
- [10] A. M. Rizki and A. L. Nurlaili, "Algoritme Particle Swarm Optimization (PSO) untuk Optimasi Perencanaan Produksi Agregat Multi-Site pada Industri Tekstil Rumahan," *J. Comput. Electron. Telecommun.*, vol. 1, no. 2, 2021, doi: 10.52435/complete.v1i2.73.
- [11] A. M. Rizki, G. E. Yuliasuti, W. F. Mahmudy, and I. P. Tama, "Hybridization of Particle Swarm Optimization and Variable Neighborhood Search for Multi-Site Aggregates Production Planning in the Home Textile Industry," in *Proceeding - IEEE 9th Information Technology International Seminar, ITIS 2023*, 2023, pp. 1–5, doi: 10.1109/ITIS59651.2023.10420362.
- [12] A. P. Wibawa, W. F. Mahmudy, A. M. Rizki, G. E. Yuliasuti, and I. P. Tama, "Multi-Site Aggregate Production Planning Using Particle Swarm Optimization," *J. Eng. Proj. Prod. Manag.*, vol. 12, no. 1, pp. 62–69, 2022, doi: 10.32738/JEPPM-2022-0006.
- [13] H. Zhou, Z.-H. Zhan, Z.-X. Yang, and X. Wei, "AMPSO: Artificial Multi-Swarm Particle Swarm Optimization," *Neural Evol. Comput.*, no. 112, 2020.
- [14] D. F. Surco, D. H. Macowski, J. G. L. Coral, F. A. R. Cardoso, T. P. B. Vecchi, and M. A. S. S. Ravagnani, "Multi-Swarm Optimizer Applied in Water Distribution Networks," *Desalin. Water Treat.*, vol. 161, pp. 1–13, 2019, doi: 10.5004/dwt.2019.24146.
- [15] O. Niyomubeyi, T. E. Sicaio, J. I. D. González, P. Pilesjö, and A. Mansourian, "A Comparative Study of Four Metaheuristic Algorithms, AMOSA, MOABC, MSPSO, and NSGA-II for Evacuation Planning," *Algorithms*, vol. 13, no. 1, 2020, doi: 10.3390/a13010016.