

Penerapan Pso-Lssvm Dalam Prediksi dan Analisis Slow Drilling (Rate Of Penetration) Pada Proses Pengeboran Studi Kasus Sumur X Lapangan Y

Geovanny Branchiny Imasuly¹, Wilma Latuny², Zannetta A. Timotius³

Program Studi Teknik Perminyakan
Universitas Pattimura Ambon, Maluku

Email: wlatuny@gmail.com (korespondensi)

Manfaat pengeboran antara lain untuk mengurangi total waktu, mempertahankan risiko serendah mungkin, menghemat biaya, dan meningkatkan efisiensi, yang terjadi dalam (tahap perencanaan dan eksplorasi). *Slow drilling* mengacu pada *rate of penetration* (ROP) yang tidak berada pada tingkat yang diinginkan. ROP mencirikan kecepatan mata bor memecah batuan di bawahnya untuk memperdalam lubang bor, karena secara langsung mengontrol kecepatan dan efisiensi pengeboran dan pada akhirnya mempengaruhi biaya pengembangan. Memprediksi ROP adalah langkah yang sangat penting untuk mengoptimalkan pengeboran dengan *Machine Learning* yang dapat membantu dalam memecahkan masalah yang kompleks dengan semaksimal mungkin dan efisiensi. Model yang digunakan adalah *PSO-LSSVM* memperlakukan penetrasi *drill bit* sebagai proses yang berkesinambungan. Dibutuhkan ROP pengeboran secara berurutan dan memprediksi ROP secara terus menerus serta mencapai hasil prediksi ROP yang lebih baik. Dalam kasus ini, *Hole Depth*, *weight on bit (WOB)*, *Bit Rotation per minute (RPM)*, *Torque*, *Bit Depth*, *Time of Penetration*, *Hook Load*, *Standpipe Pressure*, menunjukkan pengaruh dalam menjaga ROP pada level tinggi. Menurut hasil, algoritma *PSO-LSSVM* dapat digunakan untuk prediksi ROP pada sumur X. sehingga memberikan solusi untuk prediksi serta mengontrol efek operasi yang dapat menghasilkan tingkat penetrasi yang cepat dan efisiensi dalam pengeboran yang lebih baik.

Pendahuluan

Salah satu tujuan utama pengeboran adalah untuk mengurangi total waktu, mempertahankan risiko serendah mungkin, menghemat biaya, dan meningkatkan efisiensi, (tahap perencanaan dan eksplorasi). (Sobhi, Dobbi and Hachana, 2022a).

Slow drilling mengacu pada *rate of penetration* (ROP) yang tidak pada tingkat yang diinginkan dan ROP paling menarik dalam operasi pengeboran. ROP mencirikan kecepatan mata bor memecah batuan di bawahnya untuk memperdalam lubang bor, karena secara langsung mengontrol kecepatan dan efisiensi pengeboran dan pada akhirnya mempengaruhi biaya pengembangan (HOSSAIN, M.E., 2018). ROP berarti seberapa cepat mata bor mengebor melalui formasi. Menangkap kecepatan atau pergerakan mata bor saat memecah batuan, dan dalam satuan lapangan dikenal sebagai ft/jam. (Elkatatny, Al-Abduljabbar and Abdelgawad, 2020).

Diketahui bahwa dalam industri minyak dan gas, sebagian besar biaya sumur diambil dari operasi pemboran. Jadi, sangat penting untuk mengebor dengan hati-hati dan meningkatkan proses pengeboran, namun demikian sulit untuk mengetahui pengaruhnya dari setiap parameter karena sebagian besar parameter pengeboran bergantung satu sama lain, dan ada banyak parameter yang mempengaruhi ROP. Parameter ini dikategorikan menjadi lima jenis yang mana adalah sifat formasi, sifat fluida pemboran, parameter hidrolik, parameter mekanik dan efisiensi rig (Elkatatny, 2017). Kelima kategori ini juga dapat diklasifikasikan menjadi dua faktor utama, yaitu: lingkungan dan terkendali (Hossain dan Al-Majed, 2015).

Faktor lingkungan adalah faktor seperti sifat formasi dan sifat lumpur. Faktor yang dapat dikontrol adalah faktor yang dapat diubah seperti RPM, WOB dan hidrolik. (Abdulmalek Ahmed, 2019).

Industri minyak & gas sedang mengalami revolusi dalam istilah otomatisasi dan transformasi digital (Pandey, 2020, Balaji, 2018). *Artificial Intelligence* telah menjadi aplikasi dalam berbagai aspek industri minyak dan gas, dari eksplorasi hingga produksi dan pengelolaan reservoir (Bizhani and Kuru, 2022), begitu banyak upaya telah dilakukan untuk memprediksi dan mengoptimalkan dengan menggunakan model *Machine learning* Untuk meningkatkan efisiensi dan akurasi prediksi ROP (Ji, 2023).

Machine Learning (ML) dapat membantu dalam memecahkan masalah yang kompleks dengan semaksimal mungkin dan efisiensi. *ML* dapat digunakan sebagai *case-based reasoning tool* (Shah, Kshirsagar, and Panchal, 2022).

Algoritma PSO digunakan untuk mengoptimalkan parameter yang super dalam pembangunan model LSSVM untuk memprediksi ROP, Selain itu menggunakan metode analisis statistik.

Metode analisis statistik digunakan untuk mengevaluasi kinerja dari model, ini umumnya dilakukan dengan membandingkan prediksi model dengan nilai-nilai eksperimental dengan memperkenalkan berbagai perhitungan atau pendekatan, dan ada beberapa metode dalam analisis statistik yaitu *Mean absolute error (MAE)*, *Mean squared error (MSE)*, *Root mean squared error (RMSE)* dan koefisien korelasi (R^2) (Sobhi, Dobbi and Hachana, 2022b)

Masalah terpenting yang dihadapi industri minyak dan gas, khususnya adalah waktu pengeboran yang bisa meningkatkan biaya pengeboran. (Riazi et al. 2022), dan untuk memperkirakan tingkat pengeboran berdasarkan variabel seperti karakteristik formasi, parameter operasi, dan faktor lain yang dapat memengaruhi ROP.

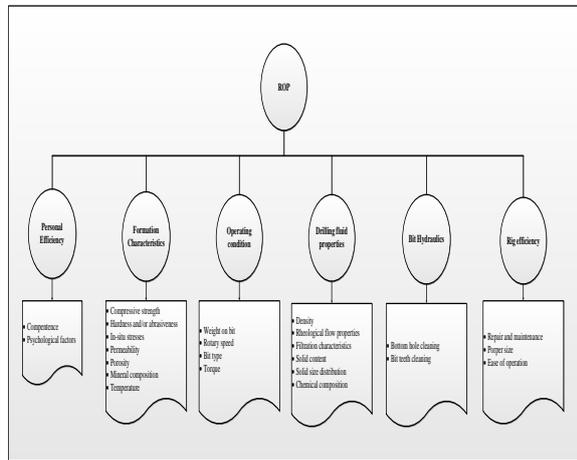
Sehingga salah satu upaya dalam *drilling engineering* untuk memprediksi dan menganalisis ROP dengan melakukan penerapan *ML* untuk memperoleh nilai akurasi dalam proses pengeboran, dengan demikian berdasarkan uraian diatas, maka penulisan ini diberi judul **PENERAPAN PSO-LSSVM DALAM PREDIKSI DAN ANALISIS SLOW DRILLING (RATE OF PENETRATION) PADA PROSES PENGEBORAN, STUDI KASUS SUMUR X LAPANGAN Y.**

Metode

a) Rate of penetration

ROP merupakan salah satu indikator dan parameter operasional untuk mengevaluasi kinerja pengeboran. *Slow drilling* adalah hasil dari kinerja ini. Selain itu, efisiensi Pengeboran akan memiliki efek yang diinginkan pada biaya ketika semua parameter operasional yang kritis diidentifikasi dan dianalisis. Parameter ini disebut sebagai *performance qualifiers (PQs)*. *PQs* mencakup rekaman yang *drilled per bottomhole assembly (BHA), downhole tool life, vibrations control, durability, steering efficiency, directional responsiveness, ROP, borehole quality,* dan lain- lainnya. (HOSSAIN, M.E. 2018). Dalam bentuk yang paling sederhana, *rate of penetration R(m/hr), (ft/hr)* (Mitchell and Miska, 2011):

$$R = (k) \cdot WOB \cdot (N) \dots\dots\dots (1)$$



Gambar.1 Parameter dari efek ROP (Anemangely. 2018)

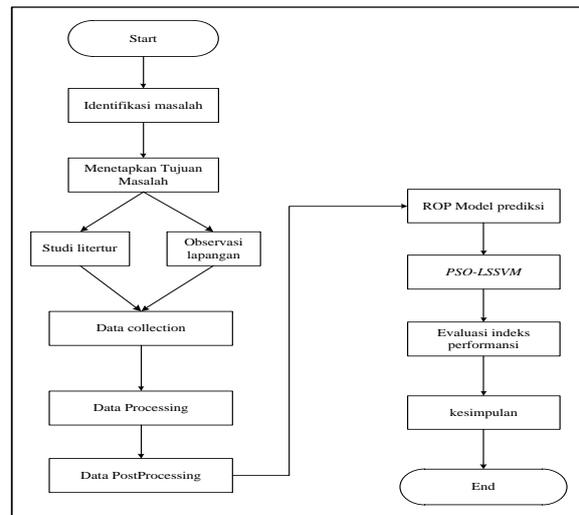
b) Particle swarm optimization (PSO)

Salah satu algoritma optimasi stokastik yang banyak digunakan adalah *Particle Swarm Optimization (PSO)* yang didasarkan pada pola populasi yang berbeda seperti burung, serangga, dan ikan (Baylar, Hanbay and Batan, 2009),(Pelckmans et al., 2002). *PSO* memanfaatkan gagasan evolusi populasi awal untuk menemukan solusi masalah optimisasi, juga dikenal sebagai partikel (Eberhart and Kennedy, 1995). Karena segerombolan adalah kumpulan partikel, istilah "kawanan" dan "partikel" mewakili populasi dan individu, secara bersamaan (Onwunalu and Durlofsky, 2010). Juga, karena setiap partikel harus bergerak dalam

domain masalah optimisasi, lingkungan topologi partikel digunakan untuk tujuan ini. Ada berbagai jenis lingkungan seperti lingkungan fisik, dan lingkungan social (Anurag Sharma & Godfrey Onwubolu, 2009) (Lekomtsev et al., 2022).

c) Least square support vector machine (LSSVM)

Least square support vector machine yang menempatkan sistem linier kuadrat terkecil saat fungsi kerugian dioptimalkan memerlukan model mesin vektor dukungan (Guo.2019). Dia memecahkan masalah dengan mengganti kendala ketidaksetaraan dengan persamaan kendala, menggunakan prinsip minimalisasi risiko struktural. Dengan cara ini, kita dapat memperoleh hasil hanya dengan menyelesaikan sistem persamaan linier saja, yang mengurangi kompleksitas komputasi dan meningkatkan efisiensi solusi (Jiu.2018).



Gambar.2 Flowchart Penelitian

Hasil Kerja/Analisa

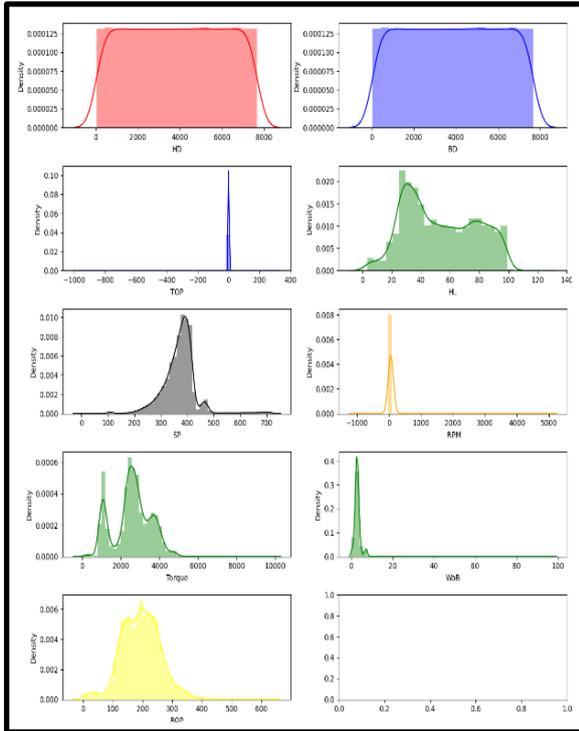
a) Data processing

Studi ini menggunakan data lapangan dan kumpulan data yang terdiri dari parameter operasi pemboran yang meliputi *Hole Depth (ft), weight on bit (klbf), Rotation per minute (RPM), Torque (lbft), Bit Depth (ft), Time of Penetration (hr), Hook Load (lbf), Standpipe Pressure (psig), rate of penetration (ft/h)*, selama operasi pemboran, yang sesuai dengan parameter pemboran. Gambar.3 merangkum informasi dasar parameter-parameter tersebut, meliputi satuan, nilai rata-rata (*mean*), standar deviasi (*std*), nilai minimum (*min*) dan nilai maximum (*max*). Data tersebut terangkum setelah mengalami tahapan *processing* yang telah dilakukan.

	count	mean	std	min	25%	50%	75%	max
HD	7553.0	3854.047134	2204.094281	41.000	1945.00	3853.00	5762.00	7671.00
ROP	7553.0	195.760459	66.502382	0.000	148.97	195.26	238.19	631.49
BD	7553.0	3854.047134	2204.094281	41.000	1945.00	3853.00	5762.00	7671.00
TOP	7553.0	0.267120	17.155782	-999.250	0.25	0.31	0.40	327.21
HL	7553.0	53.121038	24.386298	3.300	32.20	49.20	74.90	120.80
SP	7553.0	370.323448	62.299246	0.000	341.00	377.00	401.00	721.00
RPM	7553.0	110.861909	485.861830	-999.250	55.00	57.00	59.00	4993.00
Torque	7553.0	2582.512330	955.995579	18.338	2147.32	2619.85	3216.26	9793.86
WoB	7553.0	3.034860	1.804787	0.000	2.30	2.90	3.50	98.50

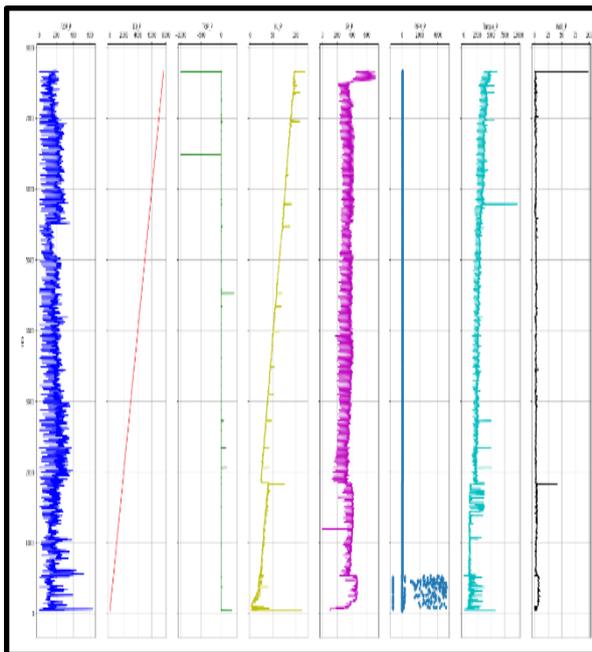
Gambar.3 Informasi statistik parameter data input dan output

Selanjutnya hasil data setiap parameter yang ada ditampilkan dalam deskriptif analisis melalui diagram histogram.



Gambar.4 Histogram parameter data input and output

Gambar.4 menunjukan sebagian besar data *Hole Depth* antara 41 ft dan 7671 ft, *Weight on bit (WOB)* sekitar 0.2 sampai 11.1 k-lbs, *Rate per minute (RPM)* 17 sampai 63 rpm. *Torsi* antara 18 sampai 9793 lbft, *Bit Depth* 2204 sampai 7671 ft, *Time of Penetration* 17 sampai 327 hr, *Hook Load* 53 sampai 120 lbf, *Standpipe Pressure* 370 sampai 721 psig, *rate of penetration* 195 sampai 631 ft/h.



Gambar.5 Relasi antara Hole Depth terhadap WOB, RPM, Torsi, Db, HL, TOP, SP, dan ROP

b) Aplikasi dari PSO-LSSVM

Memprediksi ROP dengan kecerdasan buatan (*Artificial Intelligent*) yang lebih fleksibel dan dapat menyelesaikan masalah yang rumit. Dalam penelitian ini, metode AI yang digunakan yaitu *PSO-LSSVM*, untuk mengembangkan model AI, pertama, data dipisahkan secara acak menjadi dua subkelompok yang dikenal sebagai *train-set*, di mana model belajar dan mencoba menemukan model prediksi terbaik dan optimal, dan *test-set*, yang digunakan untuk menyelidiki prediksi. kemampuan model yang dikembangkan. Klasifikasi titik data untuk model cerdas dan korelasi yang dikembangkan adalah sebagai berikut:

1. 80 persen data digunakan untuk pelatihan (*train-set*)
2. 30 persen data digunakan untuk pengujian (*test-set*)

Tabel 1. Nilai optimal untuk Gaussian RBF kernel dalam PSO-LSSVM

Parameter	Test Accuracy
Variansi dari Gaussian RBF kernel	84.80%

c) Evaluasi statistik

Dalam mengevaluasi dan membandingkan model yang dikembangkan dalam penelitian ini, analisis statistik kesalahan dilakukan. Untuk tujuan ini, *Mean Average Error (MAE)*, *Mean Square Error (MSE)*, *Root Mean Square Error (RMSE)*, dan *Coefficient of Determination (R2)* yang dihitung dan hasilnya dirangkum dalam Tabel 1, dari Persamaan (2) – (5) yang mempresentasikan formulasi yang digunakan untuk menghitung parameter tersebut:

$$MAE = \frac{1}{N} \sum_{i=1}^N |ROP_i - ROP_{ipredicted}| \dots\dots\dots (2)$$

Memprediksi ROP dengan menggunakan MAE untuk menyatakan kesalahan perkiraan rata-rata dalam satuan yang sama dengan target (misalnya, *feet* per jam atau meter per jam). Semakin rendah nilai MAE, semakin tinggi kualitas prediksi, karena menunjukkan bahwa prediksi keseluruhan ROP semakin mendekati nilai sebenarnya. Oleh karena itu, dapat memperoleh informasi tentang tingkat kesalahan prediksi keseluruhan dalam memprediksi ROP.

$$MSE = \frac{1}{N} \sum_{i=1}^N |ROP_i - ROP_{ipredicted}|^2 \dots\dots\dots (3)$$

Dalam prediksi ROP dengan menggunakan MSE untuk menggambarkan rata-rata dari kuadrat kesalahan prediksi dalam satuan yang sama dengan target sama seperti MAE. Semakin rendah nilai MSE, semakin tinggi kualitas prediksi, karena menunjukkan bahwa prediksi ROP secara keseluruhan mendekati nilai sebenarnya dengan baik. sehingga dapat memperoleh informasi tentang tingkat kesalahan prediksi secara keseluruhan dalam prediksi ROP, dengan memberikan bobot lebih pada kesalahan yang lebih besar.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N |ROP_i - ROP_{ipredicted}|^2}{N}} \dots\dots\dots (4)$$

RMSE digunakan untuk mengukur akar rata-rata dari kuadrat dari selisih antara nilai prediksi dan nilai actual dalam satuan yang sama dengan target. RMSE memberikan indikasi tentang besarnya kesalahan prediksi secara relatif

terhadap skala data dengan akar kuadrat. Nilai RMSE yang lebih kecil menunjukkan kualitas prediksi yang lebih baik, karena prediksi ROP secara keseluruhan lebih akurat mendekati nilai sebenarnya, sehingga dengan menggunakan RMSE memberikan informasi tentang tingkat kesalahan prediksi secara keseluruhan dalam prediksi ROP, dengan semakin tinggi kesalahan. RMSE juga lebih interpretatif karena memiliki satuan yang sama dengan target, sehingga memudahkan pemahaman dan perbandingan.

$$R^2 = 1 - \frac{\sum_{l=1}^{Num}(ROP_{exp,l} - ROP_{pred,l})^2}{\sum_{l=1}^{Num}(ROP_{pred,l} - ROP)^2} \dots\dots\dots(5)$$

R^2 (*Coefficient of Determination*) adalah metrik evaluasi yang digunakan dalam prediksi ROP untuk mengukur seberapa cocoknya model prediksi ROP dengan data sebenarnya. Nilai R^2 berkisar antara 0 hingga 1, di mana 0 menunjukkan bahwa model tidak memberikan penjelasan untuk variasi data, dan 1 menunjukkan bahwa model memberikan penjelasan lengkap (*perfect*) untuk variasi data. R^2 mengukur proporsi variasi dalam variabel target yang dapat dijelaskan oleh model.

Hasil nilai prediksi. Semakin besar nilai R^2 (mendekati 1), semakin kecil MAE, MSE, dan RMSE, menunjukkan kinerja prediksi model yang lebih baik. Indeks evaluasi kinerja model sebelum dan sesudah optimasi juga ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Metrik Evaluasi Kinerja Model

	MAE	MSE	RMSE	R^2	R
ROP Train	19.18	692.1	26.31	0.85	0.92
ROP Test	24.43	1240.4	35.22	0.73	0.85

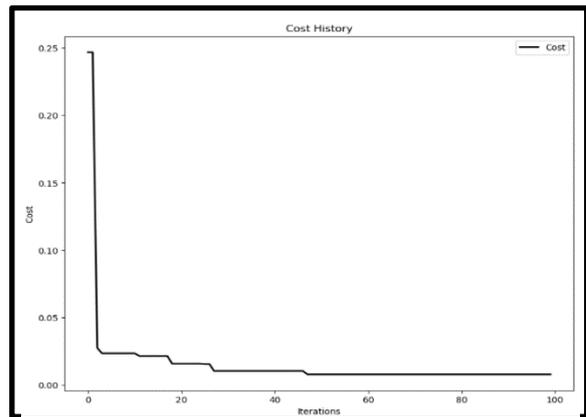
Nilai R^2 yang lebih tinggi menunjukkan bahwa model memiliki kemampuan yang lebih baik dalam menjelaskan variasi dalam data. Namun, perlu diingat bahwa R^2 tidak memberikan informasi tentang kualitas prediksi secara keseluruhan, tetapi lebih fokus pada sejauh mana variasi dalam data dapat dijelaskan oleh model. Oleh karena itu, R^2 sebaiknya digunakan bersama dengan metrik evaluasi lain seperti MAE, MSE, dan RMSE untuk mendapatkan pemahaman yang lebih komprehensif tentang performa prediksi ROP.

Proses PSO diinisialisasi dengan populasi partikel acak, dan algoritme kemudian mengeksekusi pencarian solusi optimal dengan terus memperbarui generasi. c_1 dan c_2 adalah *acceleration constant*, *inertia weight* w mengontrol dampak dari kecepatan partikel sebelumnya pada partikel saat ini. Secara umum, bobot inersia menurun secara linear dari 0,9 menjadi 0,4 selama proses pencarian untuk secara efektif menyeimbangkan kemampuan pencarian lokal dan global dari *swarm*.

Tabel 3. parameter dalam PSO-LSSVM

<i>Population size</i>	20
<i>Acceleration c_1</i>	2
<i>Acceleration c_2</i>	2
<i>Inertia weight w</i>	0.9
<i>Number of iteration</i>	100

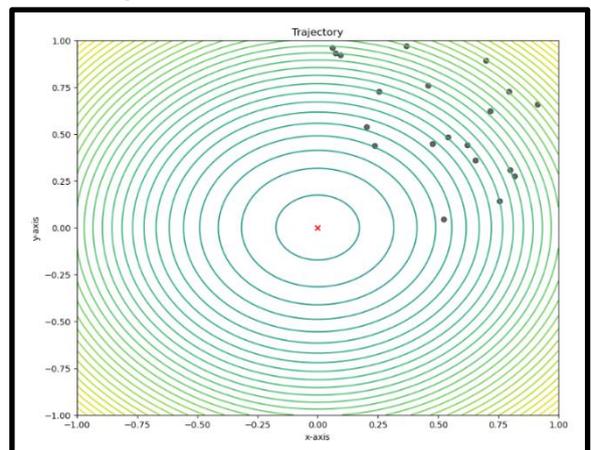
Contoh trajectory dan kriteria kinerja selama pengoptimalan ditunjukkan pada Gambar. 6 dan 7, masing-masing parameter diperoleh selama 100 iterasi.



Gambar. 6 Iterasi PSO, saat digunakan untuk melatih model LSSVM

Dalam konteks *PSO (Particle Swarm Optimization)* yang digunakan dengan *LSSVM (Least Squares Support Vector Machine)* dalam prediksi ROP, "iterasi" merujuk pada jumlah siklus atau langkah yang dijalankan oleh algoritma *PSO* untuk mencari solusi yang optimal. Setiap iterasi melibatkan pembaruan posisi dan kecepatan partikel dalam ruang pencarian dengan nilai optimum (*best pos*): -0.0875, -0.0118, dan nilai optimum (*best cost*): 0.0079.

Tujuan iterasi dalam *PSO* dengan *LSSVM* adalah untuk menemukan set parameter yang menghasilkan model *LSSVM* yang memberikan prediksi ROP yang paling akurat. Selama iterasi, partikel bergerak melalui ruang pencarian, mencoba berbagai kombinasi parameter, dan secara bertahap mendekati solusi yang optimal. Proses ini dilakukan hingga mencapai kriteria penghentian yang ditentukan sebelumnya, seperti mencapai jumlah maksimum iterasi atau mencapai tingkat konvergensi yang diinginkan. Dalam praktiknya, jumlah iterasi yang optimal dapat bervariasi tergantung pada kompleksitas masalah dan ukuran dataset yang digunakan. Beberapa faktor seperti ukuran populasi partikel, faktor pembelajaran, dan konfigurasi *PSO* lainnya juga dapat memengaruhi performa dan konvergensi iterasi.



Gambar.7 Iterasi PSO, saat digunakan untuk melatih model LSSVM (2D)

Setelah menentukan fungsi kernel dan nilai optimal dari koefisien konstan dari algoritma pengoptimalan, 70% titik data yang sesuai dengan fitur yang dipilih dikelompokkan ke dalam subset pelatihan, dengan 30% sisanya dianggap sebagai subset pengujian. Gambar.6 menunjukkan tren kesalahan pada iterasi berbeda dari algoritma

pengoptimalan yang disematkan ke dalam model LSSVM-PSO. Seperti terlihat pada gambar ini, nilai error pada iterasi akhir model LSSVM-PSO. Pada proses pemodelan ini, algoritma PSO menunjukkan tingkat pengurangan kesalahan yang paling lambat. Meskipun algoritme ini dapat mencapai beberapa tingkat kesalahan yang lebih rendah.

Kesimpulan

Dalam paper ini, metodologi dalam memprediksi ROP dikembangkan dengan menggunakan teknik *machine learning*. Model yang digunakan adalah PSO-LSSVM memperlakukan penetrasi mata bor sebagai proses yang berkesinambungan. Dibutuhkan data pengeboran secara berurutan dan memprediksi ROP secara terus menerus serta mencapai hasil prediksi ROP yang lebih baik. Dalam kasus ini, *Hole Depth (ft)*, *weight on bit (klbf)*, *Rotation per minute (RPM)*, *Torque (lbft)*, *Bit Depth (ft)*, *Time of Penetration (hr)*, *Hook Load (lbf)*, *Standpipe Pressure (psig)* menunjukkan pengaruh besar dalam menjaga ROP pada level tinggi. Kemudian menggunakan model prediksi PSO-LSSVM untuk memprediksi hasil set pengujian. Seperti yang dapat kita lihat bahwa $R^2=0.85$, dan $R=0.92$ dalam ROP train, $R^2=0.73$, dan $R=0.85$ dalam ROP test, menunjukkan bahwa akurasi prediksi tinggi karena semakin kecil RMSE, MAE, MSE, dan RMSE, menunjukkan kinerja prediksi model yang lebih baik. Menurut hasil, algoritma PSO-LSSVM dapat digunakan untuk prediksi ROP pada sumur X. sehingga memberikan solusi untuk prediksi serta mengontrol efek operasi yang dapat menghasilkan tingkat penetrasi yang cepat dan efisiensi dalam pengeboran yang lebih baik.

Ucapan Terimakasih

Pertama-tama saya mengucapkan Terima kasih kepada Tuhan yang Maha Esa sehingga penulisan ini dapat selesai, kepada Universitas Pattimura, Ambon, Jurusan Geologi, Program Studi Teknik Perminyakan, dan Universitas Pembangunan Nasional "Veteran", Yogyakarta. dan terspesial bagi keluarga.

Referensi

- Anemangely, M. et al. (2018) 'Drilling rate prediction from petrophysical logs and mud logging data using an optimized multilayer perceptron neural network', *Journal of Geophysics and Engineering*, 15(4), pp. 1146–1159. Available at: <https://doi.org/10.1088/1742-2140/aaac5d>.
- Baylar, A., Hanbay, D. and Batan, M. (2009) 'Application of least square support vector machines in the prediction of aeration performance of plunging overfall jets from weirs', *Expert Systems with Applications*, 36(4), pp. 8368–8374. Available at: <https://doi.org/10.1016/j.eswa.2008.10.061>.
- Bizhani, M. and Kuru, E. (2022) 'Towards drilling rate of penetration prediction: Bayesian neural networks for uncertainty quantification', *Journal of Petroleum Science and Engineering*, 219(September), p. 111068. Available at: <https://doi.org/10.1016/j.petrol.2022.111068>.
- Eberhart, R. and Kennedy, J. (1995) 'New optimizer using particle swarm theory', *Proceedings of the International Symposium on Micro Machine and Human Science*, pp. 39–43. Available at: <https://doi.org/10.1109/mhs.1995.494215>.
- Elkatatny, S., Al-Abduljabbar, A. and Abdelgawad, K. (2020) 'A new model for predicting rate of penetration using an artificial neural network', *Sensors (Switzerland)*, 20(7). Available at: <https://doi.org/10.3390/s20072058>.
- Guo, T. et al. (2019) 'An improved LSSVM model for intelligent prediction of the daily water level', *Energies*, 12(1), pp. 1–11. Available at: <https://doi.org/10.3390/en12010112>.
- HOSSAIN, M.E., I.M.R. (2018) 'Drilling Engineering Problems and Solution', p. 627.
- Ji, H. et al. (2023) 'An Advanced Long Short-Term Memory (LSTM) Neural Network Method for Predicting Rate of Penetration (ROP)'. Available at: <https://doi.org/10.1021/acsomega.2c06308>.
- Liu, J. X., & Jia, Z. H. (2018). Telecommunication traffic prediction based on improved LSSVM. *International Journal of Pattern Recognition and Artificial Intelligence*, 32(03), 18 50007. Available at: <https://doi.org/10.1142/s0218001418500076>.
- Lekomtsev, A. et al. (2022) 'On the prediction of filtration volume of drilling fluids containing different types of nanoparticles by ELM and PSO-LSSVM based models', *Petroleum*, 8(3), pp. 424–435. Available at: <https://doi.org/10.1016/j.petlm.2021.04.002>.
- Mitchell, R.F. and Miska, S.Z. (2011) *Fundamentals of Drilling Engineering, Fundamentals of Drilling Engineering*. Available at: <https://doi.org/10.2118/9781555632076>.
- Onwunalu, J.E. and Durlofsky, L.J. (2010) 'Application of a particle swarm optimization algorithm for determining optimum well location and type', *Computational Geosciences*, 14(1), pp. 183–198. Available at: <https://doi.org/10.1007/s10596-009-9142-1>.
- Pelckmans, K. et al. (2002) 'LS-SVMlab: a Matlab/C toolbox for Least Squares Support Vector Machines. Posted at <http://www.esat.kuleuven.be/sista/lssvmlab/>, (May 2013).
- Riazi, Mohsen et al. (2022) 'Modelling rate of penetration in drilling operations using RBF, MLP, LSSVM, and DT models', *Scientific Reports*, 12(1), pp. 1–24. Available at: <https://doi.org/10.1038/s41598-022-14710-z>.
- S, A.A. et al. (2019) 'IPTC-19548-MS Rate of Penetration Prediction in Shale Formation Using Fuzzy Logic Fuzzy Logic (FL)'. Available at: <https://doi.org/10.1007/s13202-021-01394-w>.
- Shah, M., Kshirsagar, A. and Panchal, J. (no date) *Applications of Artificial Intelligence (AI) and Machine Learning (ML) in the Petroleum Industry*.
- Sobhi, I., Dobbi, A. and Hachana, O. (2022a) 'Prediction and analysis of penetration rate in drilling operation using deterministic and metaheuristic optimization methods', *Journal of Petroleum Exploration and Production Technology*, 12(5), pp. 1341–1352. Available at: <https://doi.org/10.1007/s13202-021-01394-w>.
- Sobhi, I., Dobbi, A. and Hachana, O. (2022b) 'Prediction and analysis of penetration rate in drilling operation using deterministic and metaheuristic optimization methods', *Journal of Petroleum Exploration and Production Technology*, 12(5), pp. 1341–1352. Available at: <https://doi.org/10.1007/s13202-021-01394-w>.