

CLASSIFICATION OF COAL MINE PILLAR STABILITY USING EXTREME LEARNING MACHINE AND PARTICLE SWARM OPTIMIZATION ADAPTIVE WEIGHT DELAY VELOCITY

Nadhilah Farhana^{*1}, Gatot Fatwanto Hertono^{*2}, Bevina Desjwiandra Handari³

^{1,2,3}Magister Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Indonesia, Indonesia
Email: ¹nadhilahfarhana@ui.ac.id, ²gatot-fl@ui.ac.id, ³bevina@sci.ui.ac.id

(Article received: June 29, 2024; Revision: July 05, 2024; published: December 29, 2024)

Abstract

In underground mining, pillars are prime structural parts for supporting the overburden. Precise prediction of pillar stability is necessary because pillar failure might cause catastrophic events that could endanger mining personnel and equipment. This research aims to classify the stability of underground coal mining pillars using the Extreme Learning Machine model with Particle Swarm Optimization Adaptive Weight Delay Velocity that used to optimize the model's input weights and bias. Extreme Learning Machine is a model for training artificial neural networks using a single-layer feedforward Network architecture. Performance comparison is presented between the proposed model and the Particle Swarm Optimization-Extreme Learning Machine. The dataset originated from South African coal mining with two pillar stabilities: failed and intact. The pillar stability of the dataset expanded into five categories: failed upper, failed lower, intact upper, intact lower slender, intact lower not-slender. Out of the five pillar stability categories, the failed lower category is the most dangerous pillar category, with the rest are non-dangerous pillar category. The expanded categories are according to the Probability of Failure of the pillar and the type of pillar (slender, intermediate, and squat). The results showed that the AUC 91,4%; F_1 74,3%; F_2 72,6%, and G-mean 82,2% were all at least 10% higher in the proposed model. The proposed model successfully classified 91.24% of non-dangerous pillar stability category, but only 36% of the most dangerous pillar stability category. The results of this study are expected could give assistance to provide information as a consideration in predicting pillar.

Keywords: *adaptive weight delay velocity, extreme learning machine, particle swarm optimization, pillars stability classification, underground mining.*

KLASIFIKASI KESTABILAN PILAR TAMBANG BATU BARA MENGGUNAKAN EXTREME LEARNING MACHINE DAN PARTICLE SWARM OPTIMIZATION ADAPTIVE WEIGHT DELAY VELOCITY

Abstrak

Pada penambangan bawah tanah, pilar merupakan struktur bagian penting yang digunakan untuk menopang lapisan permukaan. Ketepatan prediksi kestabilan pilar menjadi sangat penting karena kegagalan pilar dapat menyebabkan bencana besar yang dapat mengancam para pekerja dan peralatan pertambangan. Penelitian ini bertujuan untuk mengklasifikasikan kestabilan pilar penambangan batu bara bawah tanah menggunakan model Extreme Learning Machine dengan optimasi Particle Swarm Optimization Adaptive Weight Delay Velocity yang digunakan untuk mengoptimalkan bobot masukan dan bias dari model. Extreme Learning Machine adalah salah satu model pelatihan jaringan saraf tiruan dengan arsitektur Single Layer Feedforward Network. Kinerja model akan dibandingkan dengan Particle Swarm Optimization-Extreme Learning Machine. Dataset yang digunakan berasal dari South African Coal Mining dengan dua kategori kestabilan, yaitu failed dan intact. Kategori kestabilan pilar pada penelitian ini dikembangkan menjadi lima kategori, yaitu failed upper, failed lower, intact upper, intact lower slender, intact lower not slender. Dari lima kategori tersebut, kategori failed lower adalah kategori kestabilan pilar yang paling berbahaya dan keempat kategori lainnya masuk ke dalam kategori kestabilan pilar yang tidak berbahaya. Pengembangan kategori tersebut berdasarkan Probability of Failure dari pilar dan jenis pilarnya (slender, intermediate, dan squat). Hasil penelitian menunjukkan bahwa model yang diusulkan memperoleh nilai evaluasi yang lebih tinggi paling tidak 10% pada nilai AUC 91,4%; F_1 74,3%; F_2 72,6%; dan G-mean 82,2%. Model berhasil mengklasifikasikan 91,24% pilar dengan kategori kestabilan tidak berbahaya, namun model hanya mampu mengklasifikasikan 36% pilar dengan kategori kestabilan paling berbahaya. Hasil penelitian ini diharapkan dapat membantu memberikan informasi sebagai bahan pertimbangan dalam memprediksi kestabilan pilar.

Kata kunci: *adaptive weight delay velocity, extreme learning machine, klasifikasi kestabilan pilar, particle swarm optimization, penambangan bawah tanah.*

1. PENDAHULUAN

Sampai saat ini batu bara masih menjadi salah satu sumber energi terpenting di dunia. Secara global, energi ini menjadi sumber daya strategis yang memainkan peran penting dalam perekonomian [1]. Afrika Selatan adalah salah satu produsen batu bara yang menempati peringkat keempat sebagai produsen batu bara terbesar di dunia [2]. Produksi batu bara dapat dilakukan dengan tiga cara penambangan, yaitu *surface* (penambangan terbuka), *underground* (penambangan bawah tanah), dan *in-situ* (penambangan daerah pemulihan). Kegiatan produksi penambangan batu bara dianggap sangat berbahaya karena kondisi eksternal yang tidak dapat diprediksi di mana pun wilayah produksinya. Karena tingginya resiko pekerjaan para penambang batu bara, keselamatan para penambang perlu menjadi perhatian untuk pihak terkait [3]. Hingga tahun 1993, frekuensi kecelakaan fatal dalam pertambangan terjadi sekitar 42% dari seribu pekerja per tahunnya. Kecelakaan yang berhubungan dengan pilar atau bebatuan masih menyumbang lebih dari 30% dari seluruh penyebab kematian dan menjadi penyebab terbesar kecelakaan fatal [2].

Pengamatan kestabilan pilar tambang batu bara dapat digunakan sebagai salah satu indikator untuk mencegah terjadinya kecelakaan bagi para pekerja pertambangan dan menjaga efisiensi produksi pertambangan. Pilar adalah struktur bagian penting yang digunakan sebagai penopang beban batuan permukaan untuk menjaga kestabilan permukaan [4]. Parameter yang paling umum digunakan untuk mengestimasi kestabilan pilar adalah *Safety Factor* atau faktor keamanan (FK). Secara teoritis, pilar tambang batu bara dianggap stabil saat nilai FK lebih besar dari 1 dan dianggap tidak stabil saat nilai FK kurang dari 1. Namun, batas seperti itu tidak dapat digunakan secara umum, karena pilar yang tidak stabil juga sering terjadi saat nilai FK di atas 1 [5]. Salah satu parameter lain yang dapat diandalkan untuk mengestimasi kestabilan pilar adalah *Probability of Failure* (PoF). Konsep PoF dianggap jauh lebih bermakna dalam mengestimasi kestabilan pilar. Risiko yang dapat diterima dalam desain kestabilan pilar adalah $PoF \leq 1\%$ [6].

Proses klasifikasi kestabilan pilar tambang batu bara dapat dilakukan menggunakan algoritma *machine learning*. Pada penelitian [7], analisis kestabilan permukaan mahkota pilar dilakukan menggunakan *Artificial Neural Networks* (ANN) dengan dua jenis arsitektur dan jumlah input variabel yang berbeda. Hasil akurasi model dari kedua jenis arsitektur tersebut masing-masing mencapai 93% dengan 9 input variabel dan 90% dengan 12 input variabel. Kemudian Wattimena [8] memperkenalkan

Multinomial Regression Logistic (MLR) untuk memprediksi kestabilan pilar dan memperoleh akurasi sebesar 79,21%. Metode *Stochastic Gradient Boosting* (SGB) diadopsi oleh [9] untuk memprediksi kestabilan pilar dan menemukan bahwa metode ini mencapai kinerja yang lebih baik dibandingkan dengan *Random Forest* (RF), *Support Vector Machine* (SVM), dan *Multilayer Perceptron Neural Networks* (MPNN). Prediksi kestabilan pilar batu bara oleh [10] dengan model SVM untuk kasus *multiclass* menggunakan kernel polinomial dan kernel RBF dengan optimasi parameter Bayesian masing-masing memperoleh akurasi sebesar 91% dan 92%. Ghasemi [11] melakukan klasifikasi kestabilan pilar menggunakan model *Support Vector Classification* (SVC) dan J48 diperoleh akurasi masing-masing 82,02% dan 84,83%. Pada penelitian Zhou [12] yang menggunakan model *Fisher Discriminant Analysis* (FDA) dan SVM, diperoleh nilai akurasi untuk klasifikasi kestabilan pilar masing-masing 90% dan 97,5%. Model *Random Trees* (RT) dan *C4,5 Decision Tree* (DT) digunakan oleh [13] untuk mengklasifikasikan kestabilan pilar bawah tanah dan diperoleh akurasi untuk masing-masing model 100% dan 83,33%. Model *Gradient Boosting Decision Tree* (GBDT), *Extreme Gradient Boosting* (XGBoost), dan *Light Gradient Boosting Machine* (LightGBM) digunakan oleh [4] untuk mengklasifikasikan kestabilan pilar dan diperoleh akurasi masing-masing 83,1%; 83,1%; dan 81,69%. Kestabilan pilar juga diklasifikasikan oleh [14] menggunakan model RF dengan seleksi fitur menggunakan *fuzzy* dan diperoleh akurasi 77,8% untuk dataset asli dan 83,3% untuk dataset dengan seleksi fitur. Meskipun sebagian model *machine learning* telah mampu memperoleh kinerja yang baik dalam memprediksi kestabilan pilar, masih terdapat masalah yang perlu diantisipasi saat menggunakan model *machine learning*. Salah satu permasalahan yang sering ditemui adalah *overfitting* [15].

Extreme Learning Machine (ELM) adalah salah satu model yang memiliki kelebihan dalam hal menghindari efek *overfitting* [16]. Dalam model ELM, bobot masukan dan bias diambil secara acak [17]. Untuk meningkatkan performa model, ELM dapat dikombinasikan dengan metode optimisasi parameter. Salah satu metode optimisasi yang populer digunakan adalah *Particle Swarm Optimization* (PSO) [18]. Optimisasi PSO membantu ELM mengoptimisasi bobot masukan dan bias, sehingga performa model menjadi lebih baik [19]. Optimisasi PSO atau PSO standar masih memiliki kekurangan, yaitu mudah terjebak dalam lokal optimal [20]. Untuk menangani hal tersebut, algoritma *particle swarm optimization adaptive weight delay velocity* (PSO-


AWDV) dibentuk oleh [21] sebagai upaya peningkatan kualitas algoritma PSO.

Pada penelitian ini, klasifikasi kestabilan pilar tambang batu bara dilakukan menggunakan model ELM dengan optimisasi bobot masukan dan bias menggunakan PSO-AWDV yang kemudian disebut sebagai model PSO-AWDV-ELM. Penggunaan model PSO-AWDV-ELM untuk mengklasifikasikan kestabilan pilar tambang batu bara menjadi *novelty* dalam penelitian ini. Data yang digunakan adalah data kestabilan pilar tambang batu bara yang berasal dari *South African Coal Mining*. Pada penelitian ini dilakukan modifikasi penambahan kategori kestabilan, dari dua kategori (*failed* dan *intact*) menjadi lima kategori yang disesuaikan dengan PoF dan jenis pilarnya. Modifikasi kategori kestabilan pada dataset merupakan *originality* dalam penelitian ini.

Proses pelatihan serta pengujian model dilakukan dengan variasi pembagian data menggunakan stratified 5-fold cross validation dan 5 variasi *random state*. Setelah dilakukan proses pelatihan dan pengujian model, evaluasi performa model diukur menggunakan nilai AUC, F_1 , F_2 , *G-mean* dan waktu komputasi dari setiap *fold*. Selain itu, untuk melihat peran algoritma optimisasi PSO-AWDV dalam memilih bobot dan bias terbaik, model PSO-AWDV-ELM akan dibandingkan dengan model PSO-ELM menggunakan evaluasi performa model yang sama.

2. METODE PENELITIAN

Penelitian ini terdiri dari beberapa tahap yang dimulai dari studi literatur sampai analisis hasil evaluasi model seperti yang ditunjukkan oleh Gambar 1. Hasil modifikasi dataset dibagi menjadi dua bagian, yaitu set data uji dan set data latih menggunakan *stratified k-fold cross validation* dengan $k = 5$. Sebelum proses pelatihan dan pengujian model, dataset terlebih dahulu melalui proses *preprocessing* yang terdiri dari *oversampling*, normalisasi data, dan *one-hot-encoding* (OHE) yang hanya diterapkan untuk set data latih. Evaluasi performa model dilakukan menggunakan nilai *Area Under Curve* (AUC), F_1 , F_2 , *G-mean*.




Gambar 1. Alur Penelitian

Model yang dibentuk dalam penelitian ini adalah PSO-AWDV-ELM dimana PSO-AWDV digunakan untuk mengoptimalkan bobot dan bias pada ELM. Algoritma PSO-AWDV sudah dibahas pada [21] sedangkan ELM sudah dibahas pada [16]. Model ELM merupakan salah satu model yang

memiliki keunggulan dalam menghindari efek *overfitting* dan PSO-AWDV membantu meningkatkan performa ELM dalam mengklasifikasikan kestabilan pilar tambang batu bara.

2.1. Stratified k-Fold Cross Validation

K-fold Cross Validation merupakan bentuk dasar dari *Cross Validation* (CV) [22]. Teknik CV yang digunakan menggunakan metode *stratified* akan membuat set pelatihan dan pengujian memiliki proporsi fitur yang hampir sama dengan kumpulan data asli [23]. Dalam *k-fold* CV, seluruh kumpulan data dibagi menjadi k bagian dengan $k - 1$ bagian digunakan untuk melatih model prediksi dan bagian sisanya digunakan untuk pengujian. Bagian tersebut kemudian digunakan bergilir sampai semua bagian digunakan untuk pelatihan dan pengujian model. Evaluasi performa model akhir dirata-ratakan dari seluruh k [24]. Gambar 2 menunjukkan contoh *k-fold* CV dengan $k = 5$.



Gambar 2. Skema Stratified 5-Fold Cross Validation


2.2. Preprocessing

Ketidakeimbangan jumlah kelas dalam dataset (*imbalanced data*) sering kali ditemukan dalam kasus nyata. Salah satu metode yang dapat digunakan untuk menangani permasalahan tersebut adalah *oversampling* menggunakan *Synthetic Minority Over-Sampling Technique* (SMOTE) [25]. Pada beberapa dataset terdapat rentang nilai yang berbeda di masing-masing variabel. Untuk memperoleh hasil analisis model yang lebih baik diperlukan adanya normalisasi data. Salah satu normalisasi data yang dapat dilakukan adalah standarisasi menggunakan *standard scaler* [26]. Teknik OHE bekerja untuk mengubah satu fitur dari n observasi dengan d nilai yang berbeda menjadi d bernilai biner (0 dan 1). Misalkan terdapat dataset $S = \{a, b, c\}$ dengan fitur $x_1 = a, x_2 = b, \text{ dan } x_3 = c$. Teknik OHE akan mengubah fitur dataset tersebut menjadi $x_1 = (1,0,0); x_2 = (0,1,0); x_3 = (0,0,1)$ [27].

2.3. Extreme Learning Machine

Extreme Learning Machine (ELM) adalah salah satu model untuk melatih jaringan saraf tiruan yang dikemukakan oleh [28] menggunakan arsitektur *Single Layer Feedforward Network* (SLFN) seperti pada Gambar 3. Dalam model ELM, bobot masukan dan bias diperoleh secara acak. Selanjutnya, keluaran

dari matriks pada *hidden layer* digunakan untuk menghitung bobot keluaran akhir. Proses perhitungan bobot keluaran akhir diperoleh menggunakan matriks *invers* umum Moore-Penrose [29].



Gambar 3. Arsitektur ELM

Asumsikan terdapat data latih sebanyak N . Berdasarkan Gambar 3, terdapat observasi data dengan d variabel pada *input layer*, l node pada *hidden layer*, dan m target pada *output layer* [30], [31]. Setiap node pada *input layer* dihubungkan dengan node yang berada pada *hidden layer* menggunakan persamaan (1) sebagai berikut.

$$h_{in} = g(x_{ik}w_{kn} + b_n) \tag{1}$$

dengan observasi $i = 1, \dots, N$; *hidden node* $n = 1, \dots, l$; *input variabel* $k = 1, \dots, d$; dan $g(\cdot)$ adalah fungsi aktivasi yang terdapat pada *hidden layer*, yaitu fungsi sigmoid (f_1 pada Gambar 3). Sementara itu, untuk x_{ik} adalah observasi data ke- i dengan k dimensi, w_{kn} dan b_n adalah bobot masukan untuk node ke- n dengan k dimensi dan bias pada node ke- n di *hidden layer* berturut-turut yang dijabarkan melalui persamaan (2) sampai (4) sebagai berikut.

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1d} \\ x_{21} & x_{22} & \dots & x_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nd} \end{bmatrix}_{N \times d} \tag{2}$$

$$W = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1l} \\ w_{21} & w_{22} & \dots & w_{2l} \\ \vdots & \vdots & \ddots & \vdots \\ w_{d1} & w_{d2} & \dots & w_{dl} \end{bmatrix}_{d \times l} \tag{3}$$

$$b = [b_1 \quad b_2 \quad \dots \quad b_l]_{1 \times l} \tag{4}$$

Kemudian estimasi target pada *output layer* dapat diperoleh menggunakan persamaan (5) sebagai berikut.

$$y_{ij} = h_{in}\beta_{nj} \tag{5}$$

dengan $j = 1, \dots, m$ dan β_{nj} adalah bobot keluaran dari node ke- n untuk target ke- j pada *output layer* yang dijabarkan melalui persamaan (6) sebagai berikut.

$$\beta = \begin{bmatrix} \beta_{11} & \beta_{12} & \dots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \dots & \beta_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{l1} & \beta_{l2} & \dots & \beta_{lm} \end{bmatrix}_{l \times m} \tag{6}$$

Selanjutnya, persamaan (5) dapat diperluas menjadi persamaan (7).

$$Y = H\beta \tag{7}$$

dengan matriks Y dan H berturut-turut dijabarkan pada persamaan (8) dan (9).

$$H = \begin{bmatrix} g(x_1w_1 + b_1) & g(x_1w_2 + b_2) & \dots & g(x_1w_l + b_l) \\ g(x_2w_1 + b_1) & g(x_2w_2 + b_2) & \dots & g(x_2w_l + b_l) \\ \vdots & \vdots & \ddots & \vdots \\ g(x_Nw_1 + b_1) & g(x_Nw_2 + b_2) & \dots & g(x_Nw_l + b_l) \end{bmatrix}_{N \times l} \tag{8}$$

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1m} \\ y_{21} & y_{22} & \dots & y_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ y_{N1} & y_{N2} & \dots & y_{Nm} \end{bmatrix}_{N \times m} \tag{9}$$

Sehingga, nilai bobot keluaran β dapat dihitung menggunakan persamaan (10).

$$\beta = H^\dagger Y \tag{10}$$

dengan H^\dagger merupakan matriks *invers* Moore-Penrose dari matriks *hidden layer* H . Matriks H^\dagger dapat diperoleh menggunakan persamaan (11).

$$H^\dagger = (H^T H)^{-1} H^T \tag{11}$$

Sehingga persamaan (10) dapat ditulis menjadi persamaan (12) sebagai berikut.

$$\beta = (H^T H)^{-1} H^T Y \tag{12}$$

2.4. Particle Swarm Optimization Adaptive Weight Delay Velocity

Particle swarm optimization adaptive weight delay velocity (PSO-AWDV) adalah skema baru dari algoritma optimisasi PSO dengan penundaan *velocity* (kecepatan) yang dapat memberikan ‘kekuatan’ tambahan bagi kumpulan partikel dalam populasi agar bergerak lebih baik dan dapat keluar dari perangkap lokal optimal dan mencapai global optimal [21]. Algoritma optimisasi PSO-AWDV mula-mula menginisialisasi posisi populasi partikel. Selanjutnya posisi dan kecepatan partikel berturut-turut akan diperbarui menggunakan persamaan (13) dan (14).

$$v_k(i+1) = \omega v_k(i) + (1-\omega)v_k(i-1) + c_1 r_1 (p_{best}^k(i) - x_k(i)) + c_2 r_2 (g_{best}(i) - x_k(i)) \tag{13}$$

$$x_k(i+1) = x_k(i) + v_k(i+1) \tag{14}$$

Tabel 1. Keterangan Variabel PSO-AWDV

Variabel	Keterangan
----------	------------

$v_k(i)$	Kecepatan partikel k pada iterasi ke- (i)
$v_k(i + 1)$	Kecepatan partikel k pada iterasi ke- $(i + 1)$
$x_k(i)$	Posisi partikel k pada iterasi ke- (i)
$x_k(i + 1)$	Posisi partikel k pada iterasi ke- $(i + 1)$
$p_{best}^k(i)$	Posisi terbaik individu dari partikel k pada iterasi ke- (i)
$g_{best}(i)$	Posisi terbaik global pada iterasi ke- (i)
ω	Bobot inersia yang mengatur eksplorasi global dan lokal serta kemampuan eksploitasi populasi partikel
$(1 - \omega)$	Bobot inersia dari penundaan kecepatan
c_1, c_2	Koefisien akselerasi yang mengatur seberapa besar pengaruh posisi terbaik global dan posisi terbaik individu terhadap kecepatan partikel

Pada algoritma PSO-AWDV koefisien akselerasi mengalami perubahan seiring waktu. Dengan nilai koefisien akselerasi yang besar di awal, partikel-partikel tersebut dapat menyatu ke titik optimal global pada bagian akhir optimasi. Koefisien akselerasi masing-masing dapat diperoleh menggunakan persamaan (15) dan (16) sebagai berikut.

$$c_1 = (c_{1i} - c_{1f}) \times \frac{i_{max} - i}{i_{max} + c_{1f}} \quad (15)$$

$$c_2 = (c_{2i} - c_{2f}) \times \frac{i_{max} - i}{i_{max} + c_{2f}} \quad (16)$$

dengan c_{1i} dan c_{2i} adalah koefisien akselerasi awal, sementara c_{1f} dan c_{2f} adalah koefisien akselerasi akhir. i adalah iterasi saat ini dan i_{max} adalah jumlah maksimum iterasi.

Sementara itu, bobot inersia dari kecepatan diatur sesuai dengan keadaan perubahan dalam proses optimasi yang dapat diperoleh menggunakan persamaan (17).

$$\omega = 1 - \frac{a}{1 + e^{b \cdot E(k)}} \quad (17)$$

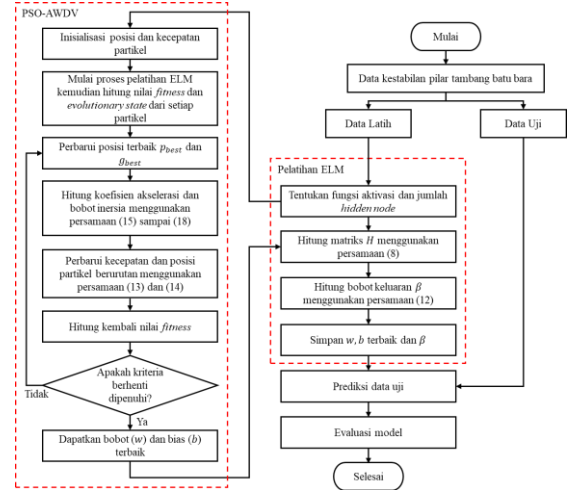
dengan a dan b adalah dua parameter yang dapat disesuaikan untuk mengatur performa dari algoritma PSO-AWDV, $E(k)$ adalah nilai estimasi dari perubahan posisi pada iterasi ke- i yang dapat diperoleh menggunakan persamaan (18).

$$E(k) = \frac{|f_{max}(i)| - |f_{min}(i)|}{|f_{max}(i)|} \quad (18)$$

dengan f_{max} dan f_{min} berturut-turut adalah nilai *fitness* maksimal dan minimal pada iterasi ke- i .

2.5. Model Klasifikasi

Model klasifikasi yang digunakan pada penelitian ini adalah PSO-AWDV-ELM. Alur pelatihan dan pengujian dataset menggunakan model PSO-AWDV-ELM dapat dilihat pada Gambar 4.



Gambar 4. Alur Pelatihan dan Pengujian Model PSO-AWDV-ELM

Proses pelatihan dan pengujian model dimulai dengan inisialisasi parameter partikel yang meliputi ukuran populasi posisi partikel, dimensi partikel, dan jumlah iterasi. Selanjutnya menentukan parameter a dan b untuk bobot inersia (ω) dan koefisien akselerasi (c_{1i} , c_{1f} , c_{2i} , dan c_{2f}). Nilai dari fungsi target (*Cross Entropy*) digunakan sebagai nilai *fitness* untuk setiap partikel. Kecepatan dan posisi partikel diperbarui hingga kriteria berhenti terpenuhi. Bobot dan bias dengan nilai *fitness* terkecil menjadi bobot dan bias terbaik untuk proses pengujian model.

2.6. Fungsi Target

Algoritma pembelajaran *machine learning* memerlukan tolok ukur seberapa baik (atau buruk) model yang dikembangkan [32]. Fungsi target umumnya juga dapat disebut sebagai fungsi *loss* [33]. Fungsi target yang digunakan dalam *machine learning* bergantung pada *output* jaringan dan *output* yang diharapkan. Dalam permasalahan klasifikasi multiclass umumnya menggunakan fungsi target *Cross Entropy* (CE). Untuk klasifikasi data *multiclass*, fungsi target dapat diperoleh menggunakan persamaan (19) sebagai berikut.

$$CE = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^m y_{ij} \log(p_{ij}) \quad (19)$$

dengan N adalah jumlah observasi data, m adalah jumlah kelas data, y_{ij} adalah estimasi nilai target observasi data ke- i pada kelas ke- j , p_{ij} adalah *output* dari observasi data ke- i pada kelas ke- j . Dalam penelitian ini, *output* dihitung menggunakan fungsi *softmax* (f_2 pada Gambar 3).

2.7. Evaluasi Performa Model

Nilai AUC dapat digunakan sebagai ukuran numerik dari kinerja model klasifikasi untuk menunjukkan seberapa sukses suatu model memisahkan kelas positif dan negatif. Matriks evaluasi AUC dapat memberikan gambaran kinerja

yang baik untuk kondisi data dengan jumlah kelas yang tidak seimbang (*imbalanced data*) [34]. Untuk menghitung evaluasi performa model pada kasus *multiclass*, proses perhitungannya harus melibatkan seluruh kelas yang ada [35]. Hasil evaluasi diperoleh dengan cara menghitung rata-rata nilai evaluasi dari masing-masing kelas. Pada kasus *multiclass* dengan kondisi *imbalanced data*, hasil evaluasi dihitung menggunakan terboboti. Hal tersebut dilakukan karena kondisi data *imbalanced class* dapat mempengaruhi evaluasi performa model [36]. Sehingga, nilai evaluasi performa model F_α dan G -mean berurut-turut dapat dihitung menggunakan persamaan (20) dan (21).

$$wF_\alpha = \frac{1}{N} \sum_{i=1}^m n_i \left(\frac{(1+\alpha)[precision_i \times recall_i]}{[\alpha \times precision_i] + recall_i} \right) \quad (20)$$

$$wG - mean = \sqrt{sensitivity_i \times specificity_i} \quad (21)$$

dengan i menunjukkan kelas ke- i , m adalah banyaknya kelas, n_i adalah jumlah observasi kelas ke- i , dan N adalah jumlah seluruh observasi. Untuk $\alpha = 1$ (F_1) menandakan bahwa *precision* dan *recall* memiliki bobot yang sama, sementara $\alpha = 2$ (F_2) menandakan bahwa bobot *recall* dua kali lipat dari *precision* [34]. Semakin tinggi nilai AUC, F_α , maupun G -mean masing-masing menandakan kinerja model semakin baik dalam mengklasifikasikan dataset [34], [37], [38].

3. MODIFIKASI DATASET

Dataset yang digunakan adalah dataset kestabilan pilar tambang batu bara di Afrika Selatan yang terdiri dari dua kategori kestabilan pilar, yaitu *failed* dan *intact*. Terdapat 79 observasi dengan kategori kestabilan *failed* dan 316 observasi dengan kategori kestabilan *intact*. Dataset memiliki 4 jenis variabel, yaitu *depth*, *mining height*, *bord with*, *pillar width* [39]. Pada penelitian ini dilakukan penambahan variable, yaitu rasio yang diperoleh dari hasil pembagian *pillar width* dengan *mining height*. Definisi variabel dapat dilihat pada Tabel 2 sebagai berikut.

Tabel 2. Definisi Variabel

Variabel	Tipe Data	Keterangan	Satuan
<i>Depth</i> (H)	Numerik	Kedalaman penambangan dari permukaan bawah tanah	Meter (m)
<i>Pillar width</i> (w)	Numerik	Lebar pilar	Meter (m)
<i>Bord width</i> (B)	Numerik	Jarak antar pilar	Meter (m)
<i>Mining height</i> (h)	Numerik	Tinggi pilar dari dasar penambangan	Meter (m)
Rasio	Numerik	Perbandingan antara lebar pilar dengan tinggi pilar	-

Pada penelitian ini dilakukan modifikasi dataset berupa penambahan label berdasarkan nilai PoF [6]

dan kategori kestabilan pilar [40]. Penambahan label dilakukan dari dua kategori (*failed* dan *intact*) menjadi lima kategori (*failed upper*, *failed lower*, *intact upper*, *intact lower slender*, dan *intact lower not slender*). Nilai PoF dapat diperoleh menggunakan persamaan (22).

$$PoF = 100e^{-2.7(FK^{1.9})}\%, \quad (22)$$

dengan FK adalah faktor keamanan yang dapat dihitung dengan persamaan (23).

$$FK = \frac{\text{Kekuatan pilar}}{\text{Beban pilar}} = \frac{S}{L} \quad (23)$$

Kekuatan pilar (S) dan beban pilar (L) berturut-turut dapat dihitung menggunakan persamaan (24) dan (25).

$$S = kw^\alpha h^\beta \text{ mPa} \quad (24)$$

$$L = \frac{0,025H(w+B)^2}{w^2} \text{ mPa} \quad (25)$$

dengan k, α, β adalah parameter optimal yang digunakan dalam perhitungan kekuatan pilar yang bergantung pada kondisi lokasi pilar tersebut. Kondisi lokasi pilar dibagi menjadi dua, yaitu *normal area* dan *weak area*. Tabel 3 menunjukkan nilai dari masing-masing parameter optimal berdasarkan kondisi lokasi pilar [41].

Tabel 3. Parameter Optimal

Lokasi	Parameter Optimal		
	k	α	β
<i>Weak</i>	2,18	0,88	-0,87
<i>Normal</i>	6,61	0,5	-0,7

Pilar dapat dibagi ke dalam tiga jenis, yaitu *slender*, *intermediate*, dan *squat* pilar. Pilar jenis *slender* adalah pilar dengan rasio $w/h \leq 4$ dan merupakan jenis pilar paling berbahaya karena dapat memancing efek rantai apabila salah satu pilar mengalami keruntuhan atau kegagalan. Pilar jenis *intermediate* adalah pilar dengan rasio $4 < w/h \leq 8$. Pilar ini tidak menciptakan efek rantai ketika gagal, namun pilar tidak dapat menerima beban tambahan. Pilar yang paling aman adalah *squat* pilar yang memiliki rasio $w/h > 10$ karena mampu menopang beban yang sangat besar [40].

4. HASIL DAN PEMBAHASAN

Aplikasi program, bahasa pemrograman, dan spesifikasi perangkat yang digunakan dalam penelitian ini adalah sebagai berikut.

Aplikasi progam : PyCharm edisi 2023.2.1.
 Bahasa pemrogaraman : Python edisi 3.10.
 Prosesor : Intel® i7-1165G7.
 RAM : 16GB.
 Sistem operasi : Windows 11.

Model dibentuk menggunakan *libraries* dari *scikitlearn*. Model klasifikasi yang digunakan

berjalan dalam proses iterasi dan akan berhenti jika kriteria berhenti telah terpenuhi. Kriteria berhenti yang diterapkan pada penelitian ini adalah saat model mencapai maksimum iterasi atau selisih nilai *fitness* dari iterasi saat ini dengan iterasi sebelumnya $< 10^{-5}$ atau $g_{best}(i) > g_{best}(i + 1)$. Pada penelitian ini, jumlah maksimum iterasi yang ditentukan adalah 100 iterasi.

Pelatihan dan pengujian model ELM-PSO-AWDV dilakukan menggunakan parameter optimisasi $a = 0,9$; $b = 0,5$; $c_{1i} = c_{2f} = 2,5$; $c_{2i} = c_{1f} = 0,5$ [21]. Jumlah partikel yang diinisialisasi sebanyak 100 partikel. Fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid (f_1 pada Gambar 3) untuk *hidden layer* dan fungsi *softmax* (f_2 pada Gambar 3) untuk *output layer*. Jumlah *node* pada *hidden layer* yang dipilih berjumlah 30 *node*. Pemilihan ini dilakukan berdasarkan hasil percobaan menggunakan beberapa variasi jumlah *hidden node* dan 30 *node* merupakan jumlah yang paling optimal untuk model dalam penelitian ini.

4.1. Hasil Modifikasi Dataset

Batas aman nilai PoF untuk desain kestabilan pilar adalah $\leq 1\%$. Modifikasi dilakukan karena adanya ketidaksesuaian nilai PoF dengan kondisi kestabilan pilar sesungguhnya. Hasil modifikasi label berdasarkan nilai PoF dan jenis pilar dapat dilihat pada Tabel 4 berikut.

Tabel 4. Modifikasi Label Dataset

Label	Keterangan
Failed Upper (FU)	Failed dengan PoF $> 1\%$ dan termasuk pilar jenis <i>slender</i>
Failed Lower (FL)	Failed dengan PoF $\leq 1\%$ dan termasuk pilar jenis <i>slender</i>
Intact Upper (IU)	Intact dengan PoF $> 1\%$ dan termasuk pilar jenis <i>slender</i>
Intact Lower	Intact dengan PoF $\leq 1\%$ dan termasuk pilar jenis <i>slender</i>
Slender (ILS)	pilar jenis <i>slender</i>
Intact Lower not Slender (ILN)	Intact dengan PoF $\leq 1\%$ dan tidak termasuk pilar jenis <i>slender</i>

Label FL adalah label pilar paling berbahaya dibandingkan label lainnya, karena memiliki nilai PoF yang masuk ke dalam kategori aman, namun pada kenyataannya pilar tersebut gagal. Selain itu, pilar ini juga termasuk ke dalam pilar jenis *slender*, yaitu pilar yang dapat memicu efek rantai apabila pilar tersebut gagal. Berdasarkan kedua kondisi tersebut, penelitian ini berpendapat bahwa jauh lebih berbahaya apabila melewatkan prediksi kestabilan pada label FL. Oleh karena itu, pilar dengan label FL memiliki prioritas yang lebih besar dibandingkan label lainnya.

Perubahan jumlah observasi pada dataset setelah proses modifikasi dapat dilihat pada Tabel 5.

Tabel 5. Perubahan Jumlah Observasi pada Data

Data Awal		Data Setelah Modifikasi	
Label	Jumlah	Label	Jumlah
Failed	79	FU	58
		FL	21

Intact	316	IU	33
		ILS	183
		ILN	100

Jika dilihat dari jumlah observasi dataset setelah dimodifikasi pada Tabel 5, terdapat ketidakseimbangan data (*imbalanced data*).

4.2. Evaluasi Nilai AUC

Evaluasi nilai AUC pada penelitian ini digunakan untuk melihat kemampuan model memisahkan masing-masing kelas pada dataset. Nilai AUC yang ditunjukkan pada Tabel 6 merupakan nilai AUC untuk setiap *fold* dengan 5 variasi *random state*, rata-rata nilai AUC untuk setiap *fold*, dan rata-rata dari seluruh *fold*.

Tabel 6. Nilai Rata-rata AUC PSO-AWDV-ELM

Fold ke-	Random State ke-					Rata-rata Nilai AUC Fold ke-
	1	2	3	4	5	
1	92%	93%	95%	93%	91%	92,8%
2	88%	90%	90%	90%	88%	89,2%
3	89%	88%	94%	92%	96%	91,8%
4	93%	93%	91%	90%	89%	91,2%
5	89%	93%	93%	92%	92%	91,8%
Nilai Rata-rata AUC Fold ke-1 sampai ke-5						91,4%

Berdasarkan nilai AUC pada Tabel 6, *fold* ke-1 memperoleh nilai AUC terbesar pada variasi *random state* ke-3 sebesar 95%. *Fold* ke-2 berurutan-urutan memperoleh nilai AUC terbesar pada variasi *random state* ke-2, ke-3, dan ke-4 sebesar 90%. *Fold* ke-3 memperoleh nilai AUC terbesar pada variasi *random state* ke-5 sebesar 96%. *Fold* ke-4 dan ke-5 berturut-turut memperoleh nilai AUC tertinggi pada variasi *random state* ke-1, ke-2 dan ke-2, ke-3 dengan nilai AUC yang sama, yaitu 93%. Berdasarkan Tabel 5 dapat dilihat bahwa variasi *random state* mempengaruhi hasil performa model pada *fold* yang sama. Selanjutnya, berdasarkan rata-rata nilai AUC per *fold* yang ditunjukkan pada Tabel 6, *fold* ke-1 memperoleh rata-rata nilai AUC terbesar yaitu 92,80%. Performa model secara keseluruhan dapat dilihat dari jumlah rata-rata nilai AUC pada masing-masing *fold* yang dibagi dengan lima *fold* yaitu 91,4%. Artinya, model PSO-AWDV ELM memiliki performa yang sangat baik dalam membedakan antara kelas-kelas pada dataset sebesar 91,4%.

4.3. Evaluasi Nilai F_1

Selain evaluasi nilai AUC, performa model PSO-AWDV-ELM juga diukur menggunakan nilai F_1 , yaitu nilai evaluasi yang memberikan bobot seimbang untuk *precision* dan *recall*. Artinya, nilai F_1 digunakan untuk menunjukkan kemampuan model secara seimbang dalam memprediksi kelas positif dengan akurat. Kelas positif merepresentasikan kelas yang diprioritaskan dalam penelitian. Nilai F_1 untuk masing-masing label pada masing-masing *fold* dapat dilihat pada Tabel 7 berikut.

Tabel 7. Nilai F_1 masing-masing Label

Label	Fold ke-					Rata-rata Nilai F_1
	1	2	3	4	5	
FU	66%	53%	71%	50%	60%	60%
FL	32%	16%	39%	59%	22%	33%
IU	45%	37%	42%	50%	60%	47%
ILS	81%	73%	78%	80%	79%	78%
ILN	92%	97%	93%	97%	98%	96%

Berdasarkan rata-rata nilai F_1 yang diperoleh pada Tabel 7, label FL memperoleh rata-rata nilai F_1 yang paling kecil diantara label lainnya, yaitu 33%. Sementara label ILN memperoleh rata-rata nilai F_1 yang paling besar, yaitu 96%. Nilai F_1 yang kecil pada label FL diindikasikan terjadi akibat kondisi *imbalanced data* pada set data uji. Dalam satu *fold*, pada set data uji hanya terdapat sekitar 5 observasi berlabel FL, sementara kelas mayoritas berjumlah 36 observasi. Akibatnya model PSO-AWDV-ELM masih belum cukup baik dalam menyeimbangkan hasil prediksi label FL, yaitu kelas *failed* dengan $PoF \leq 1$ dan termasuk pilar jenis *slender*. Namun, model sudah sangat baik (96%) dalam menyeimbangkan hasil prediksi pada label ILN, yaitu kelas *intact* dengan $PoF \leq 1$ dan tidak termasuk pilar jenis *slender*. Selanjutnya, untuk melihat performa model secara umum, nilai rata-rata terboboti F_1 pada masing-masing *fold* dan variasi *random state* ditunjukkan pada Tabel 8.

Tabel 8. Nilai Rata-rata Terboboti F_1 PSO-AWDV-ELM

Fold ke-	Random State ke-					Rata-rata Nilai F_1 Fold ke-
	1	2	3	4	5	
1	76%	80%	79%	77%	73%	77%
2	70%	70%	67%	73%	73%	70,6%
3	74%	69%	78%	79%	80%	76%
4	73%	79%	74%	76%	74%	75,2%
5	71%	67%	74%	76%	76%	72,8%
Nilai Rata-rata F_1 Fold ke-1 sampai ke-5						74,3%

Performa model dapat dilihat dari jumlah rata-rata nilai F_1 pada masing-masing *fold* dibagi dengan lima *fold*. Berdasarkan Tabel 8, dapat dilihat bahwa secara umum model PSO-AWDV-ELM memperoleh rata-rata nilai F_1 sebesar 74,3% yang artinya model berhasil cukup baik menangkap kasus positif dari masing-masing label.

4.4. Evaluasi Nilai F_2

Evaluasi performa model selanjutnya adalah nilai F_2 . Evaluasi nilai F_2 mengasumsikan nilai *recall* dua kali lebih penting dari nilai *precision*. Pemilihan evaluasi nilai F_2 didasarkan pada kondisi *false negative* yang lebih buruk dari pada *false positive*. Seperti yang sudah dijelaskan pada Bab 3, kesalahan model dalam menganggap suatu kelas *intact* lebih berbahaya dibandingkan dengan menganggap suatu kelas *failed* terutama pada kelas dengan label FL. Oleh karena itu, *recall* menjadi lebih difokuskan dari pada *precision* untuk meminimalisir terjadinya *false negative*. Tabel 9 menunjukkan kemampuan model PSO-AWDV-ELM dalam mengutamakan *recall*

yang dapat dilihat dari perbandingan nilai F_1 dan F_2 pada label FL.

Tabel 9. Perbandingan Nilai F_1 dan F_2 Label FL

Fold ke-	Nilai F_1	Nilai F_2
1	32%	36%
2	16%	19%
3	39%	42%
4	59%	57%
5	22%	26%
Rata-rata		36%

Berdasarkan Tabel 9, dapat dilihat bahwa rata-rata nilai F_2 lebih besar dari pada rata-rata nilai F_1 untuk label FL. Artinya, meskipun nilai rata-rata F_2 yang diperoleh cukup kecil, model PSO-AWDV-ELM mampu mengutamakan nilai *recall* untuk label FL. Sehingga, model PSO-AWDV-ELM dapat meminimalisir terjadinya *false negatif* sebesar 36% pada hasil prediksi model. Selanjutnya, nilai rata-rata F_2 terboboti dari seluruh label yang diperoleh model PSO-AWDV-ELM dalam mengklasifikasikan kestabilan pilar tambang batu bara dapat dilihat pada Tabel 10.

Tabel 10. Nilai Rata-rata Terboboti F_2 PSO-AWDV-ELM

Fold ke-	Random State ke-					Rata-rata Nilai F_2 Fold ke-
	1	2	3	4	5	
1	74%	79%	78%	75%	71%	75,4%
2	67%	66%	64%	70%	72%	67,8%
3	73%	67%	76%	78%	78%	74,4%
4	72%	78%	73%	76%	73%	74,4%
5	69%	65%	73%	75%	74%	71,2%
Nilai Rata-rata F_2 Fold ke-1 sampai ke-5						72,6%

Berdasarkan Tabel 10, dapat dilihat bahwa secara umum model PSO-AWDV-ELM memperoleh rata-rata nilai F_2 terboboti sebesar 72,6% yang artinya model berhasil cukup baik meminimalisir terjadinya *false negatif* dari seluruh label.

4.5. Evaluasi Nilai G -mean

Evaluasi nilai G -mean dihitung sebagai rata-rata geometri dari *sensitivity* (*true positive rate*) dan *specificity* (*true negative rate*). Nilai *sensitivity* dan *specificity* berturut-turut digunakan untuk melihat kemampuan model dalam memprediksi kelas positif dan negatif yang berhasil diidentifikasi dengan benar oleh model. Apabila perusahaan pertambangan ingin mendeteksi dan memastikan prediksi pada pilar dengan kategori yang tidak membahayakan dengan tujuan untuk memaksimalkan proses produksi, maka nilai *specificity* dari label FL dapat menunjukkan kemampuan model dalam memastikan bahwa kelas kestabilan selain FL diprediksi dengan tepat oleh model. Nilai *specificity* untuk label FL ditunjukkan pada Tabel 11 berikut.

Tabel 11. Nilai *Specificity* Label FL

Fold ke-	Nilai <i>Specificity</i>
1	91,2%
2	84,6%
3	94,2%
4	97,6%

5	88,6%
Rata-rata	91,24%

Nilai rata-rata *specificity* yang diperoleh mencapai 91,24%, artinya model PSO-AWDV-ELM mampu memprediksi dengan tepat pilar dengan kelas negatif (pilar yang tidak membahayakan pekerja tambang) dengan baik. Selanjutnya, nilai *G-mean* dihitung memastikan bahwa model pengklasifikasi tidak hanya memiliki performa yang baik di kelas negatif, tetapi mempertahankan kinerja yang baik juga pada semua kelas. Nilai rata-rata terboboti *G-mean* PSO-AWDV-ELM ditunjukkan pada Tabel 12.

Tabel 12. Nilai Rata-rata Terboboti *G-mean* PSO-AWDV-ELM

Fold ke-	Random State ke-					Rata-rata Nilai <i>G-mean</i> Fold ke-
	1	2	3	4	5	
1	83%	87%	86%	84%	82%	84,4%
2	79%	80%	77%	81%	81%	79,6%
3	81%	79%	86%	86%	86%	83,6%
4	81%	85%	82%	83%	82%	82,6%
5	80%	76%	82%	84%	83%	81%
Nilai Rata-rata <i>G-mean</i> Fold ke-1 sampai ke-5						82,2%

Berdasarkan rata-rata nilai *G-mean* pada Tabel 12, model PSO-AWDV-ELM memiliki sensitivitas yang baik dalam mengidentifikasi kelas positif dan kelas negatif dengan rata-rata nilai sebesar 82,2%.

5. DISKUSI

Untuk melihat lebih jauh kinerja algoritma PSO-AWDV-ELM, performa model PSO-AWDV-ELM dibandingkan dengan model PSO-ELM. Hasil evaluasi performa dari kedua model tersebut dan evaluasi performa dari dua penelitian lain ditunjukkan pada Tabel 13 berikut ini.

Tabel 13. Perbandingan Hasil Evaluasi Performa Model

Rata-rata Nilai Evaluasi Performa Model	Naïve Bayes [14]	PSO-ELM [42]	PSO-ELM	PSO-AWDV-ELM
AUC	91,2%	-	80,5%	91,4%
F_1	-	96,30%	56,1%	74,3%
F_2	-	-	54,1%	72,6%
<i>G-mean</i>	-	96,36%	68,6%	82,2%
Waktu Komputasi	-	107,19 detik	73,8 detik	43,2 detik

Pada penelitian [14] klasifikasi kestabilan pilar pertambangan Canada dilakukan menggunakan model Naïve Bayes dan memperoleh nilai AUC 91,2%. Model PSO-ELM sebelumnya telah digunakan pada penelitian [42] untuk mendeteksi COVID-19. Seluruh nilai evaluasi model PSO-AWDV-ELM pada penelitian ini lebih unggul daripada model PSO-ELM. Namun, nilai evaluasi F_1 dan *G-mean* PSO-ELM pada penelitian [42] lebih unggul dibanding model yang diusulkan pada penelitian ini. Klasifikasi yang dilakukan pada penelitian [42] merupakan klasifikasi biner,

sementara pada penelitian ini klasifikasi yang dilakukan merupakan klasifikasi *multiclass*. Meskipun demikian, waktu komputasi pada penelitian ini lebih unggul dibandingkan penelitian lainnya. Berdasarkan rata-rata nilai AUC yang diperoleh, model PSO-AWDV-ELM terbukti berturut-turut mampu memperoleh performa model 10,9% dan 0,2% lebih besar daripada model PSO-ELM dan penelitian [14]. Untuk nilai rata-rata F_1 dan F_2 , model PSO-AWDV-ELM berturut-turut mampu memperoleh nilai 18,2% dan 18,5% lebih besar daripada model PSO-ELM. Begitu pula dengan nilai rata-rata *G-mean* model PSO-AWDV-ELM yang 13,6% lebih besar dari pada model PSO-ELM. Peningkatan hasil performa tersebut sejalan dengan algoritma PSO-AWDV yang mencegah PSO terjebak pada *local optima*. Dengan kata lain, dapat ditunjukkan bahwa pada penelitian ini algoritma PSO-AWDV mampu meningkatkan kemampuan eksplorasi dan eksploitasi partikel untuk mendapatkan bobot dan bias terbaik. Model PSO-AWDV juga unggul dalam waktu komputasi.

Performa model PSO-AWDV-ELM masih memiliki kekurangan dalam hal mengutamakan nilai *recall*. Hal tersebut dapat dilihat pada perbedaan hasil antara nilai F_1 dan F_2 untuk model PSO-AWDV-ELM yang ditunjukkan pada Tabel 13. Nilai F_1 1,7% lebih besar dibanding F_2 . Artinya, rata-rata performa model dalam mengutamakan *recall* untuk meminimalisir terjadinya *false negative* masih perlu ditingkatkan. Model PSO-AWDV-ELM masih memiliki kekurangan dalam mengutamakan label FL (label paling berbahaya yang mengancam keselamatan pekerja tambang) berdasarkan rata-rata nilai F_2 pada Tabel 9 untuk label FL yang masih cukup kecil. Namun apabila dilihat dari segi efisiensi produktifitas penambangan, model PSO-AWDV-ELM sudah sangat baik dalam memprediksi label kestabilan pilar yang tidak mengancam keselamatan pekerja tambang berdasarkan nilai *specificity* pada Tabel 11. Sehingga, hasil prediksi model PSO-AWDV-ELM dapat membantu memaksimalkan proses produksi pertambangan.

6. KESIMPULAN

Penelitian ini mengklasifikasikan lima kategori kestabilan pilar yang baru menggunakan model PSO-AWDV-ELM. Model mampu mengklasifikasikan 91,24% pilar dengan kategori kestabilan yang tidak berbahaya berdasarkan nilai *specificity* dari label *failed lower*. Namun, model ini masih memiliki kekurangan dalam mengklasifikasikan kategori pilar paling berbahaya, yaitu hanya 36% berdasarkan nilai F_2 pada label *failed lower*. Performa model PSO-AWDV-ELM dibandingkan dengan performa model PSO-ELM menggunakan evaluasi performa yang sama, di mana model PSO-AWDV-ELM menunjukkan performa yang paling baik dalam lima kategori kestabilan pilar tambang batu bara dibandingkan performa model PSO-ELM. Hal

tersebut ditunjukkan berdasarkan rata-rata nilai evaluasi yang diperoleh, yaitu nilai $AUC = 91,4\%$; $F_1 = 74,3\%$; $F_2 = 72,6\%$; dan $G\text{-mean} = 82,2\%$. Sehingga, pada penelitian ini model PSO-AWDV-ELM memberikan performa yang lebih baik dalam mengklasifikasikan kestabilan pilar tambang batu bara dibandingkan model PSO-ELM.

Data yang digunakan pada penelitian ini masih terbatas dari segi kuantitas (395 observasi). Peneliti disarankan menggunakan data yang lebih banyak dari daerah pertambangan yang lain. Selain itu, peneliti dapat mempertimbangkan parameter lain yang dapat digunakan sebagai variabel baru dari dataset (misalnya *Rock Mass Rating (RMR)* atau *Geological Strength Index (GSI)*). Dari sisi model, dapat digunakan algoritma optimisasi lainnya, misal dengan menggabungkan algoritma PSO-AWDV dengan algoritma *swarm intelligence* lainnya.

UCAPAN TERIMA KASIH

Penelitian ini didukung oleh Hibah Riset FMIPA UI Nomor: NKB-018/UN2.F3.D/PPM.00.02/2023 Tahun anggaran 2023-2024.

DAFTAR PUSTAKA

- [1] J. Brodny dan M. Tutak, "Applying computational fluid dynamics in research on ventilation safety during underground hard coal mining: A systematic literature review," *Process Saf. Environ. Prot.*, vol. 151, hal. 373–400, 2021, doi: 10.1016/j.psep.2021.05.029.
- [2] J. N. Van Der Merwe, "Beyond Coalbrook: Critical Review of Coal Strata Control Developments in South Africa," in *25th International Conference on Ground Control in Mining*, 1998, no. 1957. [Daring]. Tersedia pada: <http://www.mineaccidents.com.au/uploads/coalbrook-mine-disaster-1960-van-der-merwe-2006.pdf>
- [3] A. P. Schissler, "Coal Mining, Design and Methods of," *Encycl. Energy*, vol. 1, hal. 485–494, 2004, doi: 10.1016/b0-12-176480-x/00284-9.
- [4] W. Liang, S. Luo, G. Zhao, dan H. Wu, "Predicting hard rock pillar stability using GBDT, XGBoost, and LightGBM algorithms," *Mathematics*, vol. 8, no. 5, hal. 1–17, 2020, doi: 10.3390/MATH8050765.
- [5] N. Li, M. Zare, C. Yi, dan R. Jimenez, "Stability Risk Assessment of Underground Rock Pillars Using Logistic Model Trees," *Int. J. Environ. Res. Public Health*, vol. 19, no. 4, 2022, doi: 10.3390/ijerph19042136.
- [6] J. N. Van Der Merwe dan M. Mathey, "Probability of failure of South African coal pillars," *J. South. African Inst. Min. Metall.*, vol. 113, no. 11, hal. 849–857, 2013, [Daring]. Tersedia pada: <https://www.saimm.co.za/Journal/v113n11p849.pdf>
- [7] A. S. Tawadrous dan P. D. Katsabanis, "Prediction of surface crown pillar stability using artificial neural networks," *Int. J. Numer. Anal. Methods Geomech.*, vol. 31, no. 7, hal. 917–931, 2007, doi: 10.1002/nag.566.
- [8] R. K. Wattimena, "Predicting the stability of hard rock pillars using multinomial logistic regression," *Int. J. Rock Mech. Min. Sci.*, vol. 71, hal. 33–40, 2014, doi: 10.1016/j.ijrmmms.2014.03.015.
- [9] H. Ding, G. Li, X. Dong, dan Y. Lin, "Prediction of Pillar Stability for Underground Mines Using the Stochastic Gradient Boosting Technique," *IEEE Access*, vol. 6, no. October, hal. 69253–69264, 2018, doi: 10.1109/ACCESS.2018.2880466.
- [10] G. F. Hertono, R. K. Wattimena, G. A. Mendrofa, dan B. D. Handari, "Classifying Coal Mine Pillar Stability Areas with Multiclass SVM on Ensemble Learning Models," *J. Eng. Technol. Sci.*, vol. 56, no. 1, hal. 95–109, 2024, doi: 10.5614/j.eng.technol.sci.2024.56.1.8.
- [11] E. Ghasemi, H. Kalhori, dan R. Bagherpour, "Stability assessment of hard rock pillars using two intelligent classification techniques: A comparative study," *Tunn. Undergr. Sp. Technol.*, vol. 68, no. August 2016, hal. 32–37, 2017, doi: 10.1016/j.tust.2017.05.012.
- [12] J. Zhou, X. B. Li, X. Z. Shi, W. Wei, dan B. B. Wu, "Predicting pillar stability for underground mine using Fisher discriminant analysis and SVM methods," *Trans. Nonferrous Met. Soc. China (English Ed.)*, vol. 21, no. 12, hal. 2734–2743, 2011, doi: 10.1016/S1003-6326(11)61117-5.
- [13] M. Ahmad, N. A. Al-Shayea, X. W. Tang, A. Jamal, H. M. Al-Ahmadi, dan F. Ahmad, "Predicting the pillar stability of underground mines with random trees and C4.5 decision trees," *Appl. Sci.*, vol. 10, no. 18, 2020, doi: 10.3390/AP10186486.
- [14] B. Kumar, S. K. Sharma, dan G. S. P. Singh, "Enhanced prediction of hard rock pillars stability using fuzzy rough feature selection followed by random forest," *J. Mines, Met. Fuels*, vol. 67, no. 11, hal. 509–514, 2019, [Daring]. Tersedia pada: <https://openurl.ebsco.com/EPDB%3Aagcd%3A6%3A25882662/detailv2?sid=ebsco%3Aplink%3Ascholar&id=ebsco%3Aagcd%3A139929533&crl=f>

- [15] X. Ying, "An Overview of Overfitting and its Solutions," *J. Phys. Conf. Ser.*, vol. 1168, no. 2, 2019, doi: 10.1088/1742-6596/1168/2/022022.
- [16] A. Akusok, K. M. Bjork, Y. Miche, dan A. Lendasse, "High-Performance Extreme Learning Machines: A Complete Toolbox for Big Data Applications," *IEEE Access*, vol. 3, hal. 1011–1025, 2015, doi: 10.1109/ACCESS.2015.2450498.
- [17] R. Manjuparkavi, M. Shanthi, dan M. C. Bhuvaneshwari, "Extreme learning machine algorithm and its application," *2nd Int. Conf. Latest Trends Eng. Sci. Humanit. Manag.*, hal. 50–58, 2017, [Daring]. Tersedia pada: http://www.arresearchpublication.com/images/shortpdf/1488120670_IF2014ijeee.pdf
- [18] C. Blum dan X. Li, "Swarm Intelligence in Optimization," *Swarm Intell.*, hal. 43–85, 2008, doi: 10.1007/978-3-540-74089-6_2.
- [19] M. R. Kaloop *dkk.*, "Particle Swarm Optimization algorithm-Extreme Learning Machine (PSO-ELM) model for predicting resilient modulus of stabilized aggregate bases," *Appl. Sci.*, vol. 9, no. 16, 2019, doi: 10.3390/app9163221.
- [20] Z. Liu dan T. Nishi, "Adaptive heterogeneous particle swarm optimization with comprehensive learning strategy," *J. Adv. Mech. Des. Syst. Manuf.*, vol. 16, no. 4, hal. 1–15, 2022, doi: 10.1299/jamdsm.2022jamdsm0035.
- [21] M. Li, H. Chen, X. Wang, N. Zhong, dan S. Lu, *An Improved Particle Swarm Optimization Algorithm with Adaptive Inertia Weights*, vol. 18, no. 3. 2019. doi: 10.1142/S0219622019500147.
- [22] P. Refaeilzadeh, L. Tang, dan H. Liu, "Cross-Validation," in *Contemporary Interventional Ultrasonography in Urology*, 2009, hal. 1–6. doi: 10.1007/978-1-84800-217-3_1.
- [23] S. Prusty, S. Patnaik, dan S. K. Dash, "SKCV: Stratified K-fold cross-validation on ML classifiers for predicting cervical cancer," *Front. Nanotechnol.*, vol. 4, no. August, hal. 1–12, 2022, doi: 10.3389/fnano.2022.972421.
- [24] M. S. Santos, J. P. Soares, P. H. Abreu, H. Araujo, dan J. Santos, "Cross-validation for imbalanced datasets: Avoiding overoptimistic and overfitting approaches [Research Frontier]," *IEEE Comput. Intell. Mag.*, vol. 13, no. 4, hal. 59–76, 2018, doi: 10.1109/MCI.2018.2866730.
- [25] E. Sutoyo, M. Asri Fadlurrahman, J. Telekomunikasi Ji Terusan Buah Batu, K. Dayeuhkolot, K. Bandung, dan J. Barat, "JEPIN (Jurnal Edukasi dan Penelitian Informatika) Penerapan SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Television Advertisement Performance Rating Menggunakan Artificial Neural Network," *JEPIN*, vol. 6, no. 3, hal. 379–385, 2020, [Daring]. Tersedia pada: <https://jurnal.untan.ac.id/index.php/jepin/article/view/42896/75676587815>
- [26] D. A. Nasution, H. H. Khotimah, dan N. Chamidah, "Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN," *Comput. Eng. Sci. Syst. J.*, vol. 4, no. 1, hal. 78, 2019, doi: 10.24114/cess.v4i1.11458.
- [27] A. S. Almajid, "Multilayer Perceptron Optimization on Imbalanced Data Using SVM-SMOTE and One-Hot Encoding for Credit Card Default Prediction," *J. Adv. Inf. Syst. Technol.*, vol. 3, no. 2, hal. 67–74, 2022, doi: 10.15294/jaist.v3i2.57061.
- [28] G. Bin Huang, Q. Y. Zhu, dan C. K. Siew, "Extreme learning machine: A new learning scheme of feedforward neural networks," *IEEE Int. Conf. Neural Networks - Conf. Proc.*, vol. 2, hal. 985–990, 2004, doi: 10.1109/IJCNN.2004.1380068.
- [29] Q. Fan dan T. Fan, "A Hybrid Model of Extreme Learning Machine Based on Bat and Cuckoo Search Algorithm for Regression and Multiclass Classification," *J. Math.*, vol. 2021, 2021, doi: 10.1155/2021/4404088.
- [30] D. Wu, X. Wang, dan S. Wu, "A hybrid method based on extreme learning machine and wavelet transform denoising for stock prediction," *Entropy*, vol. 23, no. 4, 2021, doi: 10.3390/e23040440.
- [31] X. Zhang, Z. Yang, F. Cao, J. Cao, M. Wang, dan N. Cai, "Conditioning optimization of extreme learning machine by multitask beetle antennae swarm algorithm," *Memetic Comput.*, vol. 12, no. 2, hal. 151–164, 2020, doi: 10.1007/s12293-020-00301-w.
- [32] I. Goodfellow, Y. Bengio, dan A. Courville, "Deep Learning," *MIT Press*, vol. 521, no. 7553, hal. 785, 2017, doi: 10.1016/B978-0-12-391420-0.09987-X.
- [33] U. S. Shanthamallu dan A. Spanias, *Neural Networks and Deep Learning*. 2022. doi: 10.1007/978-3-031-03758-0_5.
- [34] H. He dan M. Yunqian, *Imbalanced Learning*. New Jersey: He, H., & Yunqian, M. (2013). Imbalanced Learning. In IEEE Press. <https://doi.org/doi:https://doi.org/10.1002/9781118646106.fmatter>, 2013. doi: <https://doi.org/10.1002/9781118646106.fmatter>.
- [35] M. Grandini, E. Bagli, dan G. Visani,

- “Metrics for Multi-Class Classification: an Overview,” *A White Pap.*, hal. 1–17, 2020, [Daring]. Tersedia pada: <http://arxiv.org/abs/2008.05756>
- [36] C. O. Truica dan C. A. Leordeanu, “Classification of an Imbalanced Data Set Using,” *U.P.B. Sci. Bull., Ser. C*, vol. 79, no. 4, 2017, [Daring]. Tersedia pada: https://www.researchgate.net/publication/322103560_Classification_of_an_Imbalanced_Data_Set_using_Decision_Tree_Algorithms
- [37] A. Tharwat, “Classification assessment methods,” *Appl. Comput. Informatics*, vol. 17, no. 1, hal. 168–192, 2018, doi: 10.1016/j.aci.2018.08.003.
- [38] J. S. Akosa, “Predictive Accuracy: A Misleading Performance Measure for Highly Imbalanced Data,” *SAS Glob. Forum*, vol. 942, hal. 1–12, 2017, [Daring]. Tersedia pada: <https://support.sas.com/resources/papers/proceedings17/0942-2017.pdf>
- [39] J. N. Van Der Merwe dan M. Mathey, “Update of coal pillar database for South African coal mining,” *J. South. African Inst. Min. Metall.*, vol. 113, no. 11, hal. 825–840, 2013, [Daring]. Tersedia pada: <https://www.saimm.co.za/Journal/v113n11p825.pdf>
- [40] A. K. Verma, “A Comparative Study of Various Empirical Methods to Estimate the Factor of Safety of Coal Pillars,” *Am. J. Min. Metall.*, vol. 2, no. 1, hal. 17–22, 2014, doi: 10.12691/ajmm-2-1-3.
- [41] J. N. Van Der Merwe dan M. Mathey, “Update of coal pillar strength formulae for South African coal using two methods of analysis,” *J. South. African Inst. Min. Metall.*, vol. 113, no. 11, hal. 825–840, 2013, [Daring]. Tersedia pada: <https://www.saimm.co.za/Journal/v113n11p841.pdf>
- [42] M. A. A. Albadr, S. Tiun, M. Ayob, dan F. T. AL-Dhief, “Particle Swarm Optimization-Based Extreme Learning Machine for COVID-19 Detection,” *Cognit. Comput.*, hal. 1858–1873, 2022, doi: 10.1007/s12559-022-10063-x.