



METODE REGRESI LOGISTIK UNTUK MEMPREDIKSI RISIKO *ROCKBURST* JANGKA PENDEK

Logistic Regression Method for Predicting Short-term Rockburst Risk

Ridho Kresna Wattimena^{1*}

¹ Kelompok Keahlian Teknik Pertambangan, Fakultas Teknik Pertambangan dan Perminyakan, Institut Teknologi Bandung, Bandung 40132

Artikel masuk : 23-03-2021 , Artikel diterima : 24-06-2021

Kata kunci:
metode statistika, regresi logistik,
prediksi, *rockburst*

Keywords:
*statistical method, logistic
regression, prediction, rockburst*

ABSTRAK

Rockburst telah menjadi salah satu risiko mayor pada konstruksi dan tambang bawah tanah batuan keras yang dalam. Banyak pendekatan telah diusulkan untuk memprediksi risiko *rockburst*, mulai dari pengujian laboratorium sederhana sampai kepada metode *learning machine* yang canggih. Makalah ini membandingkan hasil prediksi metode *ensemble learning* dan regresi logistik dan menunjukkan bahwa metode regresi logistik yang lebih sederhana dapat memberikan hasil yang lebih akurat.

*Penulis Koresponden: rkw@mining.itb.ac.id

Doi : <https://doi.org/10.36986/impj.v3i1.32>

ABSTRACT

Rockbursts have been one of the major risks in deep underground constructions and hard rock mines. Many approaches have been proposed to predict rockburst risks, from simple laboratory tests to sophisticated learning machine methods. This paper compares the prediction results of ensemble learning methods and logistic regression. It reveals that the logistic regression method, which is simpler, can produce more accurate results.

PENDAHULUAN

Rockburst merupakan fenomena ketidakmampuan yang disertai dengan terlepasnya sebagian massa batuan (*spalling, cracking, splitting*) atau bahkan terlempar (*ejection*) akibat pembebasan energi regangan secara cepat (Gong *et al.* 2019). Pada tambang bawah tanah dan terowongan yang berada pada kedalaman yang besar, kasus *rockburst* telah meningkat dalam beberapa tahun terakhir ini. Beberapa contoh penting kasus *rockburst* termasuk akibatnya dapat telah dikumpulkan dan dapat dilihat pada publikasi Liang *et al.* (2020).

Zhou *et al.* (2012) membagi prediksi risiko *rockburst* ke dalam dua kelompok: jangka panjang dan jangka pendek. Prediksi jangka panjang didasarkan pada parameter mekanika batuan seperti kekuatan, kekakuan, kegetasan dan kapasitas penyimpanan energi serta tegangan-tegangan in situ maupun terinduksi. Contoh prediksi yang pernah dilakukan di Indonesia dapat dilihat dalam Wattimena *et al.* (2012) dan Sirait *et al.* (2013). Prediksi jangka pendek dimaksudkan untuk memprediksi risiko *rockburst* dalam jangka pendek berdasarkan hasil-hasil pengukuran, umumnya pengukuran seismik-mikro. Contoh prediksi yang pernah dilakukan di Indonesia dapat dilihat dalam P. Angin *et al.* (2019).

Pada makalah ini diberikan contoh mengenai penggunaan metode regresi logistik untuk prediksi risiko *rockburst* jangka panjang. Metode ini cukup sederhana dibandingkan dengan, misalnya, metode-metode *ensemble learning* (Liang *et al.*, 2020) tetapi hasilnya dapat lebih akurat.

METODE

Data *rockburst* yang digunakan dalam makalah ini adalah *dataset* yang disusun oleh Feng *et al.* (2013). Dalam *dataset* tersebut terdapat 93 data *rockburst*. Tingkat *rockburst* dibagi menjadi empat, yaitu:

- a. Tidak ada *rockburst*.
 - b. *Rockburst* ringan.
 - c. *Rockburst* sedang.
 - d. *Rockburst* berat.
- Indikator yang digunakan berjumlah enam, yaitu:
- a. Jumlah kumulatif kejadian C1.

- b. Logaritmik kumulatif energi yang dilepaskan C2 (J).
- c. Logaritmik kumulatif volume nyata C3 (m³).
- d. Laju kejadian C4 (jumlah per hari).
- e. Logaritmik laju energi C5 (J/hari).
- f. Logaritmik laju volume nyata C6 (m³/hari).

Data tersebut telah digunakan oleh Liang *et al.* (2020) untuk prediksi *rockburst* jangka pendek dengan menggunakan beberapa metode *ensemble learning*, yaitu:

- a. *Random Forest (RF)*.
- b. *Adaptive Boosting (AdaBoost)*
- c. *Gradient Boosted Decision Tree (GBDT)*
- d. *Extreme Gradient Boosting (XGBoost)*
- e. *Light Gradient Boosting Machine (Light GBM)*

Penjelasan rinci mengenai metode-metode ini tidak diberikan dalam makalah ini tetapi dapat dilihat pada literatur mengenai *machine learning*.

Data *rockburst* tersebut selanjutnya dievaluasi dengan metode regresi logistik yang lebih sederhana dibandingkan dengan kelima metode di atas. Regresi ini telah digunakan untuk memprediksi *caveability* massa batuan (Mawdesley *et al.*, 2001) maupun kemantapan pilar pada tambang bawah tanah (Wattimena *et al.*, 2013; Wattimena, 2014). Regresi ini dipilih mengingat *variable* tak-bebas (tingkat *rockburst*) pada *dataset* hanya mempunyai empat nilai yang mungkin yaitu 0 (tidak ada *rockburst*), 1 (*rockburst* ringan), 2 (*rockburst* sedang), dan 3 (*rockburst* berat). Penjelasan rinci mengenai metode regresi logistik ini dapat ditemukan pada berbagai literatur statistika.

HASIL DAN PEMBAHASAN

Metode-Metode Ensemble Learning

Hasil dari penerapan metode-metode *ensemble learning* terhadap 30 data uji diberikan pada Tabel 1-5 yang dimodifikasi dari Liang *et al.* (2020). Angka yang dicetak tebal pada diagonal utama Hasil Prediksi menunjukkan jumlah masing-masing tingkat *rockburst* yang diprediksi tepat.

Tabel 1. Hasil prediksi risiko *rockburst* dengan Metode RF

Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
0	11	11	0	0	0	100,00
1	7	2	3	2	0	42,86
2	8	0	1	7	0	87,50
3	4	0	0	1	3	75,00
% Tepat Keseluruhan						80,00

Tabel 2. Hasil prediksi risiko *rockburst* dengan Metode AdaBoost

Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
0	11	9	0	2	0	81,82
1	7	2	2	3	0	28,57

Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
2	8	0	1	7	0	87,50
3	4	0	0	2	2	50,00
% Tepat Keseluruhan						66,67

Tabel 3. Hasil prediksi risiko *rockburst* dengan Metode *GBDT*

Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
0	11	10	0	0	1	90,91
1	7	3	2	2	0	28,57
2	8	0	1	7	0	87,50
3	4	0	0	2	2	50,00
% Tepat Keseluruhan						70,00

Tabel 4. Hasil prediksi risiko *rockburst* dengan Metode *XGBoost*

Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
0	11	9	0	2	0	81,82
1	7	2	2	3	0	28,57
2	8	0	1	7	0	87,50
3	4	0	0	2	2	50,00
% Tepat Keseluruhan						66,67

Tabel 5. Hasil prediksi risiko *rockburst* dengan Metode *Light GBM*

Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
0	11	10	1	0	0	90,91
1	7	3	2	2	0	28,57
2	8	0	2	6	0	75,00
3	4	0	0	2	2	50,00
% Tepat Keseluruhan						66,67

Terlihat bahwa metode *RF* memiliki tingkat akurasi tertinggi berdasarkan % tepat keseluruhan yang mencapai 80,00%. Kecuali metode *AdaBoost*, semua metode dapat memprediksi *rockburst* sedang dengan akurasi 87,50%. Yang perlu dicatat adalah akurasi untuk memprediksi *rockburst* ringan oleh semua metode cukup rendah, sebesar 28,57%-42,86%. Selain itu, masih terdapat hasil prediksi yang menghasilkan tingkat *rockburst* yang lebih rendah dibandingkan tingkat *rockburst* aktual, yang jika digunakan dapat menimbulkan masalah keselamatan.

Metode Regresi Logistik

Berbeda dengan metode-metode *ensemble learning*, metode regresi logistik menggunakan semua data dalam *dataset*. Berdasarkan variable tak-bebas *Y* (tingkat *rockburst*), matriks variable bebas *x* (C1-C6), dan vektor koefisien regresi β , persamaan-persamaan probabilitas dalam regresi logistik yang harus diselesaikan berbentuk ($Y=0$ sebagai acuan):

$$P(Y = 0|\mathbf{x}) = \frac{1}{1+e^{g_1(\mathbf{x})}+e^{g_2(\mathbf{x})}+e^{g_3(\mathbf{x})}} \dots\dots\dots(1)$$

$$P(Y = 1|\mathbf{x}) = \frac{e^{g_1(\mathbf{x})}}{1+e^{g_1(\mathbf{x})}+e^{g_2(\mathbf{x})}+e^{g_3(\mathbf{x})}} \dots\dots\dots(2)$$

$$P(Y = 2|\mathbf{x}) = \frac{e^{g_2(\mathbf{x})}}{1+e^{g_1(\mathbf{x})}+e^{g_2(\mathbf{x})}+e^{g_3(\mathbf{x})}} \dots\dots\dots(3)$$

$$P(Y = 3|\mathbf{x}) = \frac{e^{g_3(\mathbf{x})}}{1+e^{g_1(\mathbf{x})}+e^{g_2(\mathbf{x})}+e^{g_3(\mathbf{x})}} \dots\dots\dots(4)$$

$$g_1(\mathbf{x}) = \beta_{10} + \beta_{11}x_1 + \beta_{12}x_2 + \dots + \beta_{16}x_6 \dots\dots\dots(5)$$

$$g_2(\mathbf{x}) = \beta_{20} + \beta_{21}x_1 + \beta_{22}x_2 + \dots + \beta_{26}x_6 \dots\dots\dots(6)$$

$$g_3(\mathbf{x}) = \beta_{30} + \beta_{31}x_1 + \beta_{32}x_2 + \dots + \beta_{36}x_6 \dots\dots\dots(7)$$

Semua koefisien β dapat dicari dengan menggunakan berbagai perangkat lunak statistika, termasuk yang dapat diunduh secara gratis dari internet. Hasil prediksi dengan metode regresi logistik dapat dilihat pada Tabel 6.

Tabel 6. Hasil prediksi risiko *rockburst* dengan Metode Regresi Logistik

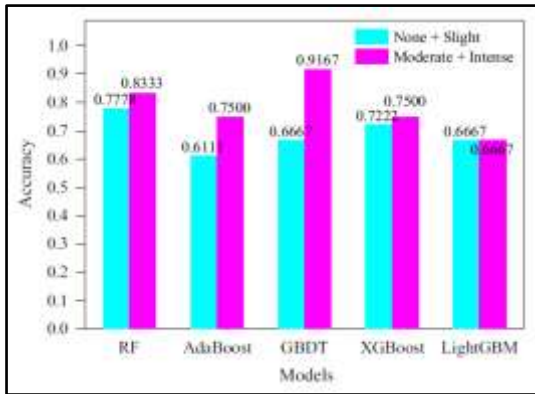
Tingkat Rockburst	Aktual	Hasil Prediksi				% Tepat
		0	1	2	3	
0	34	30	2	2	0	88,24
1	21	5	12	4	0	57,14
2	25	0	4	21	0	84,00
3	13	0	1	2	10	76,92
% Tepat Keseluruhan						78,49

Terlihat bahwa metode regresi logistik dapat memberikan hasil prediksi dengan % tepat keseluruhan mendekati metode *RF* (78,49% dibandingkan 80,00%). Akurasi untuk prediksi *rockburst* sedang mencapai 84,00% (metode *ensemble learning* 87,50%). Bahkan akurasi untuk prediksi *rockburst* ringan dan berat berada di atas semua metode *ensemble learning*. Meskipun demikian, masih terdapat juga hasil prediksi yang menghasilkan tingkat *rockburst* yang lebih rendah dibandingkan tingkat *rockburst* aktual.

Pengelompokan Ulang Tingkat *Rockburst*

Liang *et al.* (2020) menyatakan bahwa *rockburst* sedang dan berat harus mendapatkan perhatian lebih dalam rekayasa mengingat konsekuensi serius yang disebabkan. Oleh karena itu mereka selanjutnya menggabungkan kasus-kasus tidak ada *rockburst* dan *rockburst* ringan menjadi risiko *rockburst* rendah serta kasus-kasus *rockburst* sedang dan berat digabungkan menjadi risiko *rockburst* tinggi. Para peneliti terdahulu melakukan prediksi kembali dengan metode-metode *ensemble learning* yang hasilnya dapat dilihat pada Gambar 1.

Sebagai pembandingan, metode regresi logistik diterapkan juga untuk menganalisis data hasil pengelompokan ulang yang telah dilakukan dan hasilnya diberikan pada Tabel 7.



Gambar 2. Hasil Prediksi Risiko Rockburst Rendah dan Tinggi dengan Metode Ensemble Learning (Liang et al., 2020)

Tabel 7. Hasil prediksi risiko rockburst rendah dan tinggi dengan Metode Regresi Logistik

Tingkat Rockburst	Aktual	Hasil Prediksi		% Tepat
		Rendah	Tinggi	
Rendah	55	50	5	90,91
Tinggi	38	6	32	84,21
% Tepat Keseluruhan				88,17

Terlihat bahwa metode regresi logistik mempunyai akurasi yang lebih baik (90,91%) dalam prediksi risiko rockburst rendah dibandingkan dengan metode-metode ensemble learning (61,11%-77,78%). Untuk prediksi risiko rockburst tinggi, metode regresi logistik mempunyai akurasi 84,21%, yang lebih tinggi daripada metode-metode ensemble learning (66,67%-83,33%) kecuali metode metode GBDT (91,67%). Meskipun demikian masih perlu dicatat bahwa metode regresi logistik masih memprediksi sekitar 16% risiko rockburst tinggi sebagai risiko rockburst rendah.

KESIMPULAN DAN SARAN

Metode regresi logistik terbukti dapat digunakan untuk prediksi risiko rockburst dengan akurasi yang baik. Metode ini lebih sederhana dan murah dibandingkan dengan metode-metode ensemble learning yang saat ini banyak digunakan dan membutuhkan pengetahuan matematika dan statistika yang lebih kompleks serta kemungkinan perangkat lunak komputer yang cukup mahal. Oleh karena itu, metode regresi logistik ini

dapat dijadikan metode alternatif dalam melakukan prediksi risiko rockburst.

DAFTAR PUSTAKA

Feng, X.T., Chen, B.R., Zhang, C.Q., Li, S.J., Wu, S.Y., 2013; Mechanism, warning and dynamic control of rockburst development processes. Science Press, Beijing (in Chinese).

Gong, F.Q, Yan J.Y, Li X.B and Luo, S., 2019; A peak-strength strain energy storage index for bursting proneness of rock materials. *International Journal of Rock Mechanics and Mining Sciences*, 117:76-89.

Liang, W., Sari, A., Zhao, G., McKinnon, S.D. and Wu, H., 2020; Short-term rockburst risk prediction using ensemble learning methods. *Natural Hazards*, 104:1923-1946.

Mawdesley, C., Trueman, R., Whiten, W., 2001; Extending the Mathews stability graph for open-stop design. *Transactions of the Institution of Mining and Metallurgy*, 110: A27-39.

P. Angin, P., Wattimena, R.K., Sahara, D.P., Purba, A.M., 2019; Microseismic analysis to identify stress redistribution and minimize rockburst in DMLZ cave abutment, PT Freeport Indonesia. *Proceedings of the 5th ISRM Young Scholars' Symposium on Rock Mechanics and International Symposium on Rock Engineering for Innovative Future*, 851-856.

Sirait, B., Wattimena, R.K. and Widodo, N.P., 2013; Rockburst prediction of a cut and fill mine by using energy balance and induced stress. *Procedia Earth and Planetary Science*, 6: 426-434.

Wattimena, R.K., Sirait, B., Widodo, N.P. and Matsui, K., 2012; Evaluation of rockburst potential in a cut-and-fill mine using energy balance. *International Journal of the Japanese Committee for Rock Mechanics*, 8(1): 19-23.

Wattimena, R.K., Kramadibrata, S., Sidi, I.D., Azizi, M.A., 2013; Developing coal pillar stability chart using logistic regression. *International Journal of Rock Mechanics and Mining Sciences*, 58: 55-60.

Wattimena, R.K., 2014; Predicting the stability of hard rock pillars using multinomial logistic regression *International Journal of Rock Mechanics and Mining Sciences*, 71: 33-40.

Zhou, J., Li, X.B. and Shi, X.Z., (2012) Long-term prediction model of rockburst in underground openings using heuristic algorithms and support vector machines. *Safety Science*, 50(4):629-644.