

MODEL SUPPORT VECTOR MACHINE (SVM) BERDASARKAN PARAMETER WINDOWS UNTUK PREDIKSI KEKUATAN GEMPA BUMI

Oman Somantri¹, Santi Purwaningrum², Riyanto³

^{1,2}Jurusan Teknik Informatika, Politeknik Negeri Cilacap, Indonesia

³Program Studi Manajemen Informatika, AMIK YMI Tegal, Indonesia

Email: ¹oman_mantri@yahoo.com, ²santi.purwaningrum@pnc.ac.id, ³riyan_sala3@yahoo.co.id

Abstrak

Abstrak—Gempa bumi merupakan jenis bencana alam yang saat ini tidak bisa diprediksikan kemunculannya. Memprediksikan nilai kekuatan gempa bumi bagi pihak terkait seperti pemerintah dan badan penanggulangan bencana sangatlah penting. Lebih lanjut, hasil prediksi gempa bumi oleh beberapa pihak dijadikan sebagai indikator dalam penanggulangan pasca gempa tersebut dalam meminimalisir resiko yang akan terjadi. Beberapa penelitian menerapkan metode *machine learning* untuk memprediksi gempa seperti *deep neural network* dan *parallel Support Vector Regression*. Pada artikel ini mengusulkan sebuah metode *data mining* menggunakan algoritma *Support Vector Machine* (SVM) disertai dengan optimalisasi nilai parameter *windowing* pada model yang diterapkan untuk memprediksi nilai kekuatan gempa magnitudo. Berdasarkan kelebihan model SVM dipilih karena telah mampu diterapkan dalam pengolahan data *time series*. Pada proses tahapan eksperimen dilakukan terlebih dahulu pengaturan parameter, hal ini dilakukan untuk mengoptimalkan tingkat akurasi dari model yang dihasilkan seperti pengaturan tipe *kernel*, tipe *sampling*, dan jumlah *windowing*. Hasil penelitian menunjukkan bahwa model terbaik yang memiliki nilai *Root Mean Square Error* (RMSE) terkecil adalah sebesar 0,712.

Kata Kunci: gempa bumi, magnitudo, support vector machine, windowing

Abstract

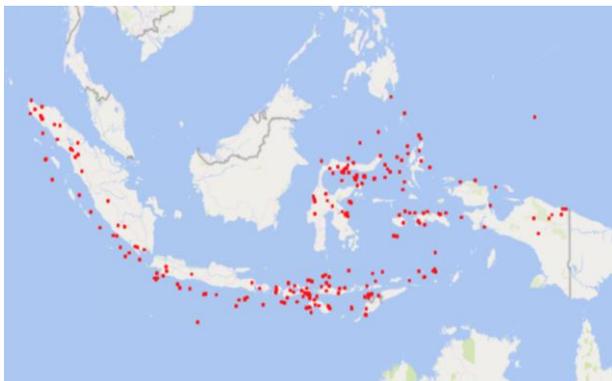
Abstrak—Earthquakes are a type of natural disaster that currently cannot be predicted. Predicting the value of earthquake magnitude for related parties such as government and National Disaster Management Authority is very important. Furthermore, the results of earthquake predictions by several parties are used as indicators in post-earthquake response in minimizing the risks that will occur. Several studies have applied machine learning methods to predict earthquakes such as deep neural networks and parallel Support Vector Regression. In this article, we propose a data mining method using the Support Vector Machine (SVM) algorithm accompanied by the optimization of the windowing parameter value in the model that is applied to predict the value of the earthquake magnitude. Based on its advantages, the SVM model was chosen because it has been applicable in time series data processing. In the experimental stage process, parameter settings are first carried out, namely setting the kernel type, sampling type, and number of windowing to optimize the level of accuracy of the resulting model. The results showed that the best model with the smallest Root Mean Square Error (RMSE) was 0.712.

Keywords: earthquake, magnitude, support vector machine, windowing

I. PENDAHULUAN

Peningkatan frekuensi bencana alam dalam beberapa tahun ini mengalami peningkatan jumlahnya, hal ini memberikan alasan kenapa pemerintah khususnya di Indonesia membentuk sebuah badan tertentu yang dinamakan Badan penanggulangan Bencana Alam Daerah (BPBD). Bencana alam yang saat ini mempunyai tingkat dampak yang sangat tinggi adalah gempa bumi. Beberapa pengalaman di Indonesia memperlihatkan dampak bencana alam ini sangat tinggi, karena bagaimanapun gempa bumi ini memiliki bencana turunan lain seperti tsunami dan lonsor seperti halnya terjadi di daerah Palu dan Aceh serta beberapa daerah lainnya di Indonesia (Jena dkk., 2020). Kekuatan guncangan gempa bumi memiliki pengaruh yang sangat besar dari dampak yang ditimbulkan, dimana semakin tinggi kekuatan magnitudo yang dihasilkan maka semakin tinggi juga dampak yang ada (Wyss, 2014).

Prediksi gempa bumi bagi beberapa pihak sangat diperlukan terutama dalam proses mitigasi bencana yang akan dijadikan kebijakan pihak terkait khususnya pemerintah dalam *Standard Operating Procedure* (SOP) penanggulangan bencana alam khususnya gempa bumi ini. Seiring berkembangnya teknologi informasi khususnya kecerdasan buatan, maka saat ini *data mining* menjadi solusi dalam memprediksi kejadian gempa bumi dan potensi tsunami (Utomo & Purba, 2019). Data histori yang diperoleh pada penelitian ini dijadikan sebagai data penelitian untuk mencari model untuk prediksi gempa bumi. Pada penelitian ini yang diprediksikan akan menilai kekuatan magnitudo, hal ini dilakukan karena indikator tersebut memberikan pengaruh sangat besar terhadap dampak dari bencana tersebut.



Gambar 1. Visualisasi sebaran lokasi gempa bumi berdasarkan dataset penelitian

Terdapat beberapa penelitian dengan menggunakan *data mining* dan *machine learning* dalam prediksi gempa bumi. Penelitian telah

dilakukan dengan menerapkan *Machine learning* pada tahun 2021 untuk mendeteksi kedalaman sumber gempa skala mikro (Yang dkk., 2021), pada penelitian ini menerapkan *convolutional neural network* (CNN) sebagai algoritma yang digunakan. Penelitian dilakukan untuk prediksi gempa mengusulkan metode *AdaBoost* berbasis *framework ensemble*, pada penelitian ini data yang digunakan adalah berasal dari data satelit (Xiong dkk., 2021). Selain itu, penelitian yang fokusnya kepada analisis prediksi dan anomali gempa bumi termasuk magnitudo telah dilakukan oleh para peneliti lainnya (Cecilia Charlene, 2020; Mallouhy dkk., 2019). Penelitian lain mengusulkan sebuah GIS berbasis *support vector machine* untuk memetakan kerentanan tanah longsor yang dipicu dari gempa pada wilayah daerah aliran sungai (Xu dkk., 2012). Penelitian yang dilakukan dengan metode statistik dan *transformasi wavelet* untuk analisis periodisitas gempa bumi pernah dilakukan oleh (Fatimatuzzahra dkk., 2020) Salah satu penelitian untuk estimasi magnitudo gempa dari sinyal seismik gelombang P menggunakan metode regresi polinomial telah dilakukan (Ginting dkk., 2020)

Beberapa penelitian telah dilakukan dengan menerapkan SVM sebagai model yang digunakan. Peneliti (Wei dkk., 2018) melakukan penelitian untuk mengkaji mengenai magnitudo gempa. Penelitian yang dilakukan oleh (Yousefzadeh dkk., 2021) mengusulkan model *deep neural network* dalam prediksi gempa, dalam evaluasi model yang dilakukan menggunakan SVM sebagai pembandingan dari model yang diusulkan. Sebuah model pernah diusulkan oleh (Kollam & Joshi, 2020) yang dinamakan *Paralel Support Vector Regression* menggunakan *Computing Unified Device Architecture* (CUCA) untuk memprediksi gempa bumi. Dalam sebuah penelitian dilakukan oleh (Noor, 2018) mengusulkan algoritma *Support Vektor Machine* berbasis *Particle Swarm Optimization* sebagai model untuk prediksi gempa bumi.

Berdasarkan penelitian-penelitian sebelumnya, pada penelitian dalam artikel ini diusulkan sebuah model data mining dengan menggunakan Support Vektor Machine (SVM) sebagai model yang digunakan berbasiskan nilai parameter *pre-processing* data. Pada penelitian ini berbeda dengan penelitian yang sudah dilakukan para peneliti sebelumnya, pada penelitian ini model terbaik dihasilkan berbasis dari penentuan nilai parameter *time series windowing* pada proses *pre-processing* data.

II. METODE

Dataset

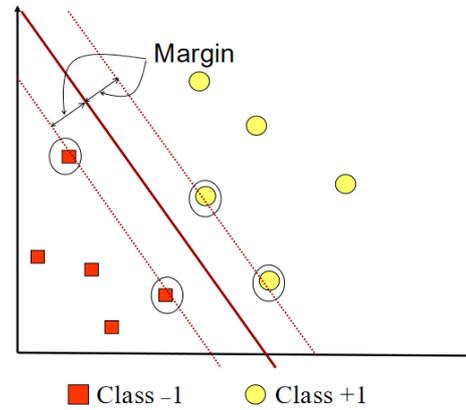
Dalam penelitian ini dilakukan dengan menggunakan metode eksperimen. Data penelitian yang digunakan adalah data laporan gempa bumi yang diambil dari BMKG dan sistem peringatan dini Tsunami Indonesia dengan rentang pengambilan data mulai 1 Januari s.d 11 Januari 2021 dengan jumlah record sebanyak 272 data (BMKG, 2021). Data yang diperoleh berbentuk multivariat, akan tetapi dalam penelitian ini yang digunakan hanya dua variabel yaitu Tanggal(GMT) dan Magnitudo(SR). Penggambaran data histori letak lokasi gempa dari *dataset* yang didapatkan yang berasal di Indonesia diperlihatkan pada Gambar 1. Eksperimen dilakukan dengan menggunakan Rapidminer studio 9.0 untuk analisis data.

Support Vector Machine (SVM)

Metode SVM merupakan salah satu algoritma *machine learning* yang digunakan dan diterapkan untuk sebuah klasifikasi data (Somantri & Apriliani, 2018) dan prediksi data. Mekanisme dan konsep dari SVM ini sebetulnya adalah mencari sebuah *hyperline* atau fungsi pemisah terbaik antar dua *class* yang berbeda. Untuk *hyperline* terbaik ini adalah posisinya berada terletak di tengah-tengah diantara dua set objek dari dua kelas tersebut (Moraes dkk., 2013).

Pada dasarnya SVM ini prinsipnya adalah mempunyai kemampuan bekerja dalam kasus *linier classifier* maupun *non-linear*. Pada kasus *non-linear*

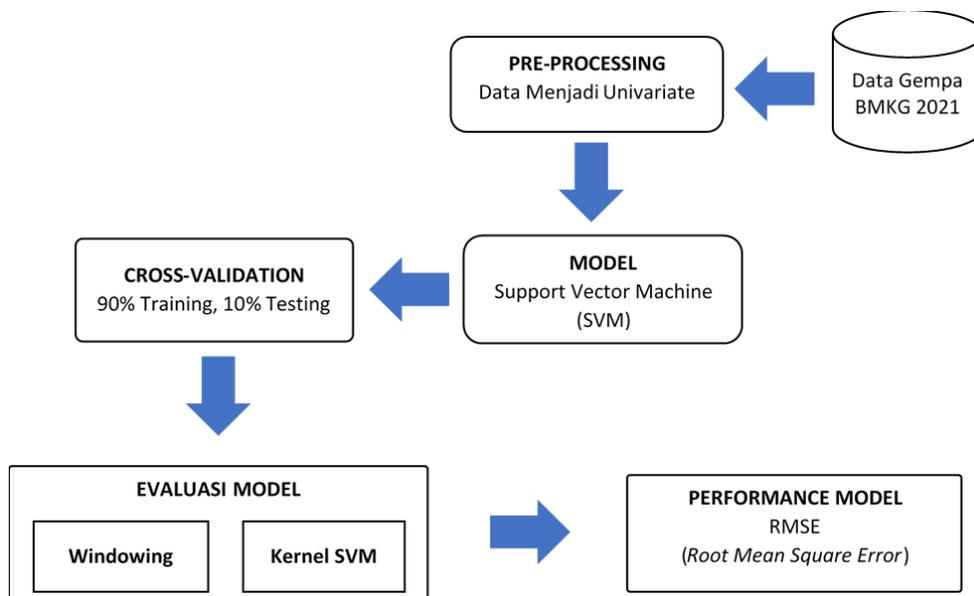
ini SVM akan menggunakan sebuah konsep *kernel* pada ruang kerja yang berdimensi tinggi yang fungsinya nanti untuk mencari *hyperlane* yang mampu memaksimalkan jarak antara kelas data (Tomar & Agarwal, 2015). Penggambaran konsep dari SVM diperlihatkan oleh Gambar 2.



Gambar 2. Konsep dasar SVM dalam menentukan *hyperline*

Framework Penelitian

Upaya dalam mencari model terbaik dalam memprediksi kekuatan gempa bumi dilakukan beberapa tahapan dalam penelitian ini. Tahapan proses yang dilakukan diantaranya: (1) pencarian sumber data; (2) *pre-processing* data; (3) penerapan model; (4) validasi data; dan (5) evaluasi model. Setiap tahapan yang dilakukan dalam eksperimen ini adalah sebagai upaya dalam mencari model prediksi terbaik dengan tingkat *error* sekecil



Gambar 3. Framework metode yang diusulkan

mungkin, tahapan tersebut diperlihatkan pada Gambar 3.

Pada proses pengukuran *performance* model terbaik yang didapatkan diukur dengan menggunakan *Root Mean Square Error* (RMSE) (Chai & Draxler, 2014) dan *Mean Squared_error* (MSE), dengan persamaan yang ditunjukkan pada persamaan (1) dan (2), dimana y_i adalah nilai actual, \hat{y}_i adalah nilai prediksi, n adalah jumlah data, dan i adalah variabel i .

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Pada penelitian ini, nilai *mean squared_error* yang dihasilkan merupakan jumlah nilai *error* rata-rata antara nilai actual dan prediksi yang dibagi dengan jumlah record data yang diolah pada setiap prosesnya sesuai dengan jumlah nilai parameter *k-Fold* yang digunakan pada model. Nilai *mean squared_error* yang dihasilkan pada *tools rapidminer* secara otomatis pada penelitian ini memiliki hasil nilai range rata-rata *squared_error* kurang lebih (+-) 0.3 sehingga nilai *squared_error* yang dihasilkan memiliki sedikit perbedaan apabila dihitung secara manual.

Berdasarkan pada Gambar 3, pada tahapan *pre-processing* data dilakukan proses pemilihan variabel yang digunakan dan menjadikan data tersebut menjadi univariat yang artinya variabel yang dijadikan *input-an* adalah satu variabel. Tahapan berikutnya adaah proses penerapan model, dalam hal ini algoritma *Support Vektor Machine* (SVM) digunakan. SVM yang diterapkan pada tahap proses ini terlebih dahulu disesuaikan nilai parameter-parameternya agar sesuai dengan yang diharapkan hasilnya. Pada tahapan validasi data, menggunakan *cross validation*. Pada proses validasi ini data dibagi menjadi dua bagian yaitu data training sebanyak 90% dan data testing sebanyak 10%. Evaluasi model dilakukan dengan cara membandingkan nilai RMSE yang diperoleh berdasarkan parameter yang ditetapkan, yaitu *windowing* data dan tipe *kernel* model SVM.

III. HASIL DAN PEMBAHASAN

Eksperimen Windows 4

Tahap eksperimen dengan menggunakan model SVM pada tahapan ini menggunakan parameter

windows=4. Ini artinya bahwa data univariat yang digunakan pada model dijadikan terlebih dahulu menjadi multivariat dengan jumlah inputan data untuk prediksi adalah 4 data. Variabel yang digunakan adalah Magnitudo(SR), dimana variabel ini didapatkan setelah dilakukan pemilihan variabel pada saat *pre-processing* data.

Hasil eksperimen yang dilakukan pada tahapan ini terlebih dahulu dilakukan setting parameter, yaitu diantaranya untuk metode *sampling=linear*, dan kernel SVM=*dot*. Hasil yang didapatkan diperlihatkan pada Tabel 1. Perbedaan ditunjukkan ketika dilakukan eksperimen dengan menggunakan teknik setelah ditentukan *kernel* SVM dengan menggunakan *radial*. Adapun hasilnya diperlihatkan pada Tabel 2. Perubahan nilai RMSE sedikit lebih baik setelah dalam eksperimen ini dilakukan perumahan tipe *kernel* SVM yang digunakan yaitu *polynomial*. Hasil perubahan nilai yang diperoleh ditunjukkan pada Tabel 3.

Tabel 1. Hasil Eksperimen SVM dengan Windows=4, dan kernel=dot

k-Fold	RMSE	Mean Squared_error
10	0.712	0.533
9	0.718	0.535
8	0.723	0.542
7	0.716	0.535
6	0.729	0.545
5	0.740	0.558
4	0.734	0.556
3	0.754	0.571
2	0.763	0.589

Tabel 2. Hasil Eksperimen SVM dengan Windows=4, dan kernel=radial

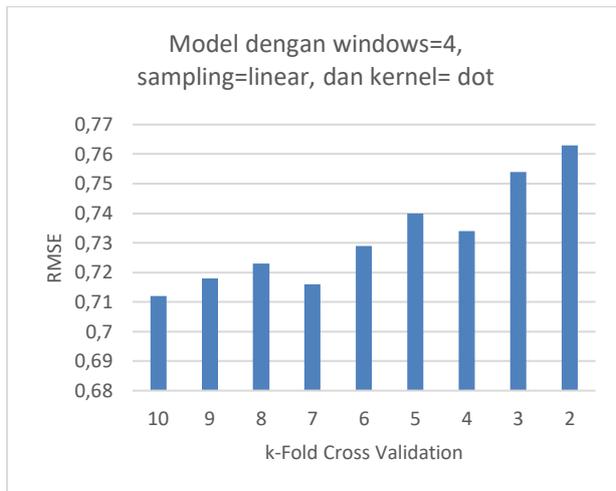
k-Fold	RMSE	Mean Squared_error
10	0.791	0.636
9	0.762	0.599
8	0.786	0.628
7	0.783	0.624
6	0.782	0.627
5	0.783	0.614
4	0.779	0.614
3	0.778	0.610
2	0.778	0.609

Hasil eksperimen menunjukkan untuk nilai RMSE terbaik dari model dengan menggunakan SVM *kernel=dot* dan *k-fold=10* adalah sebesar 0,712. Pada Model dengan *kernel=radial* memperoleh nilai RMSE sebesar 0,762 yang menggunakan *k-fold=9*.

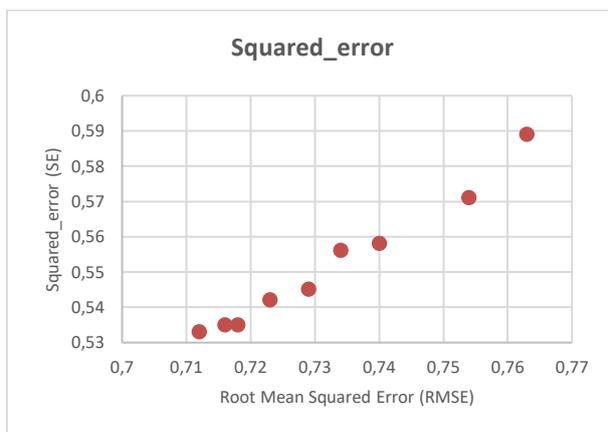
Berbeda dengan model yang menggunakan *kernel = polynomial* memperoleh nilai RMSE sebesar 0,725 yang menggunakan *k-fold=10*. Penggambaran mengenai model terbaik dengan menggunakan *windows=4* ditunjukkan pada Gambar 4 dan Gambar 5.

Tabel 3. Hasil Eksperimen SVM dengan Windows=4, dan kernel=polynomial

k-Fold	RMSE	Mean Squared_error
10	0.725	0.551
9	0.737	0.568
8	0.734	0.560
7	0.737	0.568
6	0.733	0.551
5	0.737	0.552
4	0.738	0.560
3	0.755	0.576
2	0.775	0.613



Gambar 4. Model terbaik dengan windows=4, sampling= linear, dan tipe kernel=dot



Gambar 5. Grafik *sequared_error* model terbaik dengan windows=4 dan sampling= linear

Eksperimen selanjutnya adalah metode pengambilan sampling dalam pencarian model ditentukan dengan menggunakan metode *shuffled*. Penentuan nilai validasi *k-fold* juga ditentukan dengan kombinasi, artinya ketika eksperimen dilakukan nilai *k-fold* berbeda diterapkan dan diujikan untuk mencari model terbaik. Hasil pencarian model menghasilkan nilai RMSE yang berbeda-beda, dan ini memberikan gambaran bahwa nilai parameter tersebut sangat berpengaruh. Hasil yang didapatkan dengan menggunakan metode *sampling shuffled* diperlihatkan pada Tabel 4, Tabel 5, dan Tabel 6.

Hasil eksperimen pada model yang menggunakan windows 4 dan tipe sampling *shuffled* menunjukkan nilai RMSE terbaik sebesar 0, 728 dengan menggunakan parameter *kernel=dot* dan *k-fold=8*. Untuk yang menggunakan kernel=*radial* menghasilkan RMSE terbaik sebesar 0,740, sedangkan untuk model menggunakan *kernel=polynomial* nilai RMSE terbaik diperoleh sebesar 0,729.

Tabel 4. Hasil Eksperimen SVM *shuffled* dengan Windows=4, dan kernel=dot

k-Fold	RMSE	Mean Squared_error
10	0.730	0.540
9	0.730	0.543
8	0.728	0.536
7	0.734	0.547
6	0.733	0.545
5	0.743	0.556
4	0.739	0.548
3	0.738	0.544
2	0.797	0.635

Tabel 5. Hasil Eksperimen SVM *shuffled* dengan Windows=4, dan kernel=radial

k-Fold	RMSE	Mean Squared_error
10	0.743	0.570
9	0.745	0.572
8	0.749	0.574
7	0.740	0.562
6	0.749	0.578
5	0.748	0.569
4	0.774	0.606
3	0.767	0.590
2	0.783	0.613

Tabel 6. Hasil Eksperimen SVM dengan Windows=4, dan kernel=polynomial

k-Fold	RMSE	Mean Squared_error
10	0.736	0.559
9	0.729	0.548
8	0.733	0.547
7	0.744	0.570
6	0.743	0.565
5	0.756	0.578
4	0.751	0.568
3	0.775	0.606
2	0.741	0.549

Eksperimen Menggunakan Windows 3

Eksperimen berikutnya adalah melakukan penelitian dengan menetapkan jumlah *windows* yang digunakan berjumlah 3. Selain itu pada eksperimen ini ditetapkan beberapa parameter yang memberikan pengaruh terhadap nilai RMSE yang dihasilkan. Percobaan dilakukan dengan menggunakan teknik *sampling=linear* dan teknik *sampling shuffled* pada model SVM, untuk hasil eksperimen ditunjukkan pada Tabel 6 dan Tabel 7.

Berdasarkan hasil yang didapatkan terlihat bahwa model terbaik yang memiliki RMSE terkecil untuk yang menggunakan metode *sampling linear* adalah sebesar 0.721 yang menggunakan SVM *kernel=polynomial* dan *k-Fold validation=9*. Sedikit berbeda dengan hasil yang diperoleh dengan menggunakan metode *sampling shuffled*, dimana untuk RMSE terbaik adalah sebesar 0,713 yang menggunakan SVM dengan *type kernel=dot* dan menggunakan *k-Fold validation=10*.

Tabel 7. Hasil Eksperimen SVM dengan Windows=3, Sampling= Linear

Fold	kernel= dot		kernel= radial		kernel= polynomial	
	RMSE	Mean Squared_error	RMSE	Mean Squared_error	RMSE	Mean Squared_error
10	0.726	0.536	0.752	0.571	0.728	0.536
9	0.722	0.538	0.741	0.562	0.721	0.535
8	0.727	0.539	0.748	0.562	0.729	0.541
7	0.725	0.537	0.754	0.577	0.730	0.542
6	0.728	0.541	0.752	0.572	0.724	0.532
5	0.733	0.543	0.755	0.572	0.735	0.545
4	0.732	0.545	0.735	0.544	0.748	0.566
3	0.742	0.552	0.756	0.574	0.734	0.541
2	0.721	0.526	0.778	0.609	0.818	0.669

Tabel 8. Hasil Eksperimen SVM dengan Windows=3, Sampling= Shuffled

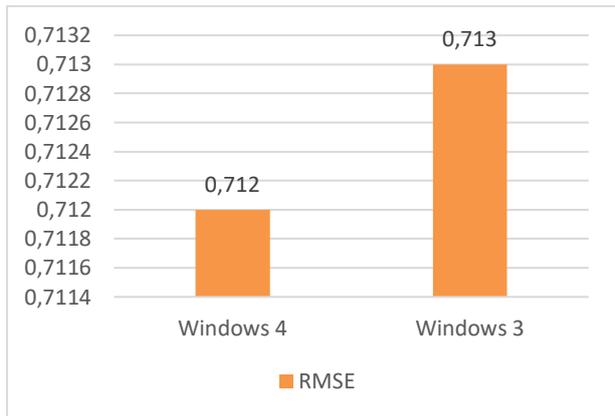
Fold	kernel= dot		kernel= radial		kernel= polynomial	
	RMSE	Mean Squared_error	RMSE	Mean Squared_error	RMSE	Mean Squared_error
10	0.713	0.533	0.755	0.582	0.718	0.539
9	0.715	0.534	0.766	0.599	0.723	0.550
8	0.725	0.540	0.769	0.604	0.723	0.541
7	0.716	0.535	0.768	0.600	0.718	0.538
6	0.728	0.544	0.774	0.612	0.725	0.540
5	0.733	0.546	0.749	0.568	0.725	0.534
4	0.730	0.546	0.773	0.610	0.726	0.541
3	0.737	0.546	0.778	0.608	0.737	0.548
2	0.753	0.574	0.774	0.605	0.765	0.600

Evaluasi Model

Pencarian model terbaik dengan menerapkan SVM sebagai model yang diusulkan menghasilkan nilai RMSE yang berbeda-beda. Untuk melihat perbedaan hasil dari metode yang diusulkan khususnya dengan menggunakan parameter *windows=3* dan *windows=4* dapat dilihat pada Tabel 9.

Tabel 9. Evaluasi Model SVM

Sampling	Windows	k-Fold	Kernel	RMSE
linear	4	10	dot	0,712
shuffled	4	8	dot	0,728
linear	3	10	dot	0,713
shuffled	3	9	polynomial	0,721



Gambar 6. Evaluasi Model Berdasarkan RMSE terbaik

Pada Tabel IX terlihat bahwa untuk RMSE terbaik adalah sebesar 0,712 dengan menggunakan *windows=4* dengan parameter metode *sampling linear*, *k-Fold=10*, serta *type kernel=dot*. Secara Grafik perbedaan nilai RMSE dari kedua model *windows* tersebut seperti diperlihatkan pada Gambar 6.

IV. PENUTUP

Kesimpulan

Metode *support vector machine* yang diusulkan pada penelitian ini telah berhasil diterapkan pada model yang diusulkan untuk memprediksi kekuatan magnitudo gempa bumi. Pada metode yang diusulkan menghasilkan nilai RMSE terbaik sebesar 0,712. Optimasi pada parameter dengan menggunakan *windowing* telah berhasil dilakukan, Nilai parameter terbaik yang dihasilkan adalah dengan menggunakan *windowing=4* dan menggunakan *k-fold=10* dengan *kernel SVM* yang diterapkan adalah tipe *dot*. Pada model yang telah dihasilkan terlihat bahwa nilai RMSE terbaik yang

dapat dihasilkan adalah tergantung dari parameter yang ditentukan dan salah satunya pada saat *pre-processing* data.

Saran

Pada penelitian selanjutnya yang akan dilakukan adalah perlu adanya optimasi model sehingga nilai RMSE menjadi lebih baik lagi, artinya bisa lebih kecil dengan menggunakan berbagai macam algoritma optimasi.

V. DAFTAR PUSTAKA

BMKG. (2021). *Data Online - Pusata Database - BMKG*. <https://dataonline.bmkg.go.id/home>

Cecilia Charlene, S. S. H. (2020). *Analisis Prediksi Dan Anomali Gempabumi Menggunakan Machine Learning* [Institut Teknologi Telkom Purwokerto]. <http://repository.itelkom-pwt.ac.id/id/eprint/6289>

Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>

Fatimatuzzahra, F., Didik, L. A., & Bahtiar, B. (2020). Analisis Periodisitas Gempa Bumi Diwilayah Kabupaten Lombok Barat Dengan Menggunakan Metode Statistik Dan Transformasi Wavelet. *Jurnal Fisika dan Aplikasinya*, 16(1), 33. <https://doi.org/10.12962/j24604682.v16i1.5717>

Ginting, N. Y. I., Novianty, A., & Prasasti, M. T. A. L. (2020). Estimasi Magnitudo Gempa Bumi Dari Sinyal Seismik Gelombang P Menggunakan Metode Regresi Polinomial. *eProceedings of Engineering*, 7(2).

Jena, R., Pradhan, B., Beydoun, G., Alamri, A. M., Ardiansyah, Nizamuddin, & Sofyan, H. (2020). Earthquake hazard and risk assessment using machine learning approaches at Palu, Indonesia. *Science of the Total Environment*, 749, 141582. <https://doi.org/10.1016/j.scitotenv.2020.141582>

Kollam, M., & Joshi, A. (2020). Earthquake Forecasting by Parallel Support Vector Regression Using CUDA. *Proceedings - 2020 International Conference on Computing, Electronics and Communications Engineering, iCCECE 2020*, 150–155. <https://doi.org/10.1109/iCCECE49321.2020.9231137>

- Mallouhy, R., Jaoude, C. A., Guyeux, C., & Makhoul, A. (2019, Desember 1). Major earthquake event prediction using various machine learning algorithms. *6th International Conference on Information and Communication Technologies for Disaster Management, ICT-DM 2019*. <https://doi.org/10.1109/ICT-DM47966.2019.9032983>
- Moraes, R., Valiati, J. F., & Gavião Neto, W. P. (2013). Document-level sentiment classification: An empirical comparison between SVM and ANN. *Expert Systems with Applications*, *40*(2), 621–633. <https://doi.org/10.1016/j.eswa.2012.07.059>
- Noor, A. (2018). Perbandingan Algoritma Support Vector Machine Biasa dan Support Vector Machine berbasis Particle Swarm Optimization untuk Prediksi Gempa Bumi. *Jurnal Humaniora Teknologi*, *4*(1). <https://doi.org/10.34128/jht.v4i1.37>
- Somantri, O., & Apriliani, D. (2018). Support Vector Machine Berbasis Feature Selection Untuk Sentiment Analysis Kepuasan Pelanggan Terhadap Pelayanan Warung dan Restoran Kuliner Kota Tegal. *Jurnal Teknologi Informasi dan Ilmu Komputer*, *5*(5), 537. <https://doi.org/10.25126/jtiik.201855867>
- Tomar, D., & Agarwal, S. (2015). Twin Support Vector Machine: A review from 2007 to 2014. In *Egyptian Informatics Journal* (Vol. 16, Nomor 1, hal. 55–69). Elsevier B.V. <https://doi.org/10.1016/j.eij.2014.12.003>
- Utomo, D. P., & Purba, B. (2019). Penerapan Datamining pada Data Gempa Bumi Terhadap Potensi Tsunami di Indonesia. *Prosiding Seminar Nasional Riset Information Science (SENARIS)*, *1*, 846. <https://doi.org/10.30645/senaris.v1i0.91>
- Wei, H., Wang, M., Song, B., Wang, X., & Chen, D. (2018). Study on the magnitude of reservoir-triggered earthquake based on support vector machines. *Complexity*, *2018*. <https://doi.org/10.1155/2018/2830690>
- Wyss, M. (2014). Earthquake Hazard, Risk and Disasters. In *Earthquake Hazard, Risk and Disasters*. Elsevier Inc. <https://doi.org/10.1016/c2011-0-07007-2>
- Xiong, P., Tong, L., Zhang, K., Shen, X., Battiston, R., Ouzounov, D., Iuppa, R., Crookes, D., Long, C., & Zhou, H. (2021). Towards advancing the earthquake forecasting by machine learning of satellite data. *Science of the Total Environment*, *771*, 145256. <https://doi.org/10.1016/j.scitotenv.2021.145256>
- Xu, C., Dai, F., Xu, X., & Lee, Y. H. (2012). GIS-based support vector machine modeling of earthquake-triggered landslide susceptibility in the Jianjiang River watershed, China. *Geomorphology*, *145–146*, 70–80. <https://doi.org/10.1016/j.geomorph.2011.12.040>
- Yang, D. H., Zhou, X., Wang, X. Y., & Huang, J. P. (2021). Mirco-earthquake source depth detection using machine learning techniques. *Information Sciences*, *544*, 325–342. <https://doi.org/10.1016/j.ins.2020.07.045>
- Yousefzadeh, M., Hosseini, S. A., & Farnaghi, M. (2021). Spatiotemporally explicit earthquake prediction using deep neural network. *Soil Dynamics and Earthquake Engineering*, *144*, 106663. <https://doi.org/10.1016/j.soildyn.2021.106663>