

PEMODELAN NILAI *B-VALUE* UNTUK MITIGASI RISIKO GEMPA DI ZONA MEGATHRUST SELATAN JAWA MENGGUNAKAN LSTM, SVM, DAN RANDOM FOREST

B-VALUE MODELING FOR EARTHQUAKE RISK MITIGATION IN SOUTH JAVA MEGATHRUST ZONE USING LSTM, SVM, AND RANDOM FOREST

Ismi Amalia¹, Taswanda Taryo², Sudarno Wiharjo³

^{1,2,3}Program Studi Teknik Informatika S-2, Program Pascasarjana, Universitas Pamulang, Tangerang Selatan^{1,2,3}

irgie19nanda@gmail.com¹, taswandataryo@gmail.com², sudarnogm@gmail.com³

ABSTRACT

The South Java Megathrust Zone is an active subduction area with high seismicity prone to large earthquakes and tsunamis, where the *b-value* parameter serves as a critical indicator for mapping tectonic stress accumulation. This study aims to model the spatiotemporal dynamics of *b-value* time series using the Maximum Likelihood Estimation (MLE) method combined with moving average smoothing techniques and three artificial intelligence approaches: Long Short-Term Memory (LSTM), Support Vector Machine (SVM/SVR), and Random Forest (RF). The evaluation results show that in the standard configuration, the SVM approach delivers the best numerical accuracy due to its robustness in handling moderate-sized datasets without overfitting, followed by the efficiency of the RF model, although both exhibit limitations characterized by lazy prediction or time-lag effects. Conversely, true sequential architectural superiority is achieved by the LSTM network in a controlled experimental scenario utilizing instantaneous data inputs, where truncating the long-term historical chain effectively liberates the model from temporal inertia bias, enabling its gating mechanisms to operate in a far more responsive, adaptive, and precise manner when tracking the causality of tectonic stress changes without naive phase delays.

Keywords: *b-value*, South Java Megathrust, LSTM, SVM, Random Forest

ABSTRAK

Zona Megathrust Selatan Jawa merupakan wilayah subduksi aktif dengan tingkat kegempaan tinggi yang rawan terhadap bencana gempa bumi besar dan tsunami, di mana parameter *b-value* bertindak sebagai indikator kritis dalam memetakan akumulasi tegangan tektonik. Penelitian ini bertujuan memodelkan dinamika deret waktu *b-value* secara spasio-temporal menggunakan metode *Maximum Likelihood Estimation* (MLE) yang dikombinasikan dengan teknik pemulusan jendela bergerak serta tiga pendekatan kecerdasan buatan, yaitu *Long Short-Term Memory* (LSTM), *Support Vector Machine* (SVM/SVR), dan *Random Forest* (RF). Hasil evaluasi menunjukkan bahwa pada konfigurasi standar, pendekatan SVM memberikan akurasi numerik terbaik karena ketangguhannya mengolah dataset berukuran sedang tanpa gejala *overfitting*, disusul oleh efisiensi model RF, meskipun keduanya menunjukkan keterbatasan berupa gejala perkiraan malas (*lazy prediction*) atau penundaan fase waktu. Sebaliknya, superioritas arsitektural sekuensial yang sesungguhnya berhasil dicapai oleh jaringan LSTM pada skenario eksperimen kontrol berbasis masukan data seketika, di mana pemotongan rantai historis jangka panjang mampu membebaskan model dari bias inersia temporal sehingga mekanisme gerbang pengaturannya bekerja jauh lebih responsif, adaptif, dan presisi dalam melacak kausalitas perubahan stres tektonik tanpa penundaan fase naif.

Kata Kunci: *b-value*, Megathrust Selatan Jawa, LSTM, SVM, Random Forest

PENDAHULUAN

Indonesia terletak di pertemuan tiga lempeng tektonik utama, yaitu Lempeng Indo-Australia, Eurasia, dan Pasifik, sehingga menjadikannya salah satu negara dengan tingkat seismisitas tertinggi di dunia (Hutchings & Mooney, 2021). Zona Megathrust Selatan Jawa, sebagai zona

subduksi aktif antara Lempeng Indo-Australia yang menunjam ke bawah Lempeng Eurasia, memiliki potensi kegempaan dan tsunami yang sangat besar. Hal ini dibuktikan oleh gempa bumi 17 Juli 2006 berkekuatan M7,7 yang memicu tsunami di pesisir selatan Jawa, serta berbagai kajian terkini yang

mengidentifikasi adanya celah seismik (seismic gaps) aktif di wilayah ini (Widiyantoro et al., 2020);(Supendi et al., 2023).

Parameter *b-value* dalam persamaan Gutenberg-Richter merupakan indikator krusial kondisi tegangan batuan dan potensi terjadinya gempa besar. Secara umum, nilai *b* yang lebih rendah dari ambang normal ($< 1,0$) mengindikasikan akumulasi tegangan tektonik yang tinggi, yang berkorelasi dengan potensi pelepasan energi seismik berskala besar. Beberapa studi telah mengkonfirmasi bahwa penurunan spasiotemporal nilai *b* dapat digunakan sebagai prekursor gempa bumi (Jiang et al., 2021); (5. *Spatial–Temporal Variations of B-values Prior.Pdf*, n.d.). Pemantauan *b-value* di Megathrust Selatan Jawa oleh (Arubi et al., 2022) dan (R & Madrinovella, 2024) juga menunjukkan variasi temporal yang signifikan di wilayah tersebut.

Meskipun demikian, perhitungan dan pemantauan *b-value* secara konvensional menghadapi tantangan akibat sifatnya sebagai fenomena deret waktu yang kompleks, non-linear, dan berubah-ubah (Taroni et al., 2021). Kemajuan kecerdasan buatan dan pembelajaran mesin (ML/DL) menawarkan solusi yang signifikan. Model *Long Short-Term Memory* (LSTM) terbukti unggul dalam pemodelan deret waktu kompleks dengan dependensi jangka panjang (Barrera-Animas et al., 2022). *Support Vector Machine* (SVM) dan *Random Forest* (RF) telah banyak diterapkan dalam berbagai tugas geofisika dan klasifikasi seismik (Domel et al., 2023) (Turino et al., 2025).

Kesenjangan penelitian yang teridentifikasi adalah belum adanya studi yang secara sistematis membandingkan LSTM, SVM, dan RF khusus untuk pemodelan deret waktu *b-value* di Zona Megathrust Selatan Jawa, serta belum adanya eksplorasi pengaruh skala jendela pemulusan (*moving average*) terhadap kinerja model. Studi ini bertujuan untuk: (1) memodelkan deret waktu *b-value* bulanan di Zona Megathrust Selatan Jawa Bagian

Barat; (2) mengembangkan dan membandingkan model LSTM, SVM, dan RF; (3) menganalisis pengaruh variasi jendela *Moving Average* terhadap performa model; serta (4) merekomendasikan model terbaik untuk sistem pemantauan seismik berbasis kecerdasan buatan yang mendukung mitigasi bencana.

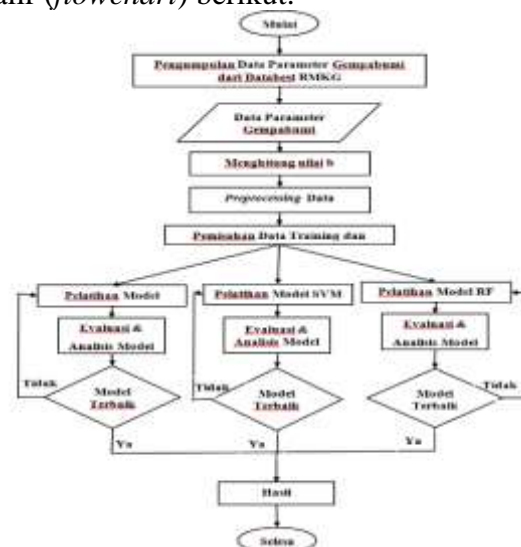
METODE

Data dan Wilayah Penelitian

Wilayah studi difokuskan pada segmen Megathrust Jawa Bagian Barat menggunakan pendekatan *bounding box* yang mengacu pada Peta Sumber dan Bahaya Gempa Indonesia tahun 2024 (BUKU_PETA_SUMBER_DAN_BAHAYA_GEMPA_2024, 2025). Data yang digunakan merupakan katalog gempabumi historis dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) periode 2008 hingga 2025. Variabel parameter yang diekstraksi meliputi waktu kejadian (*origin time*), magnitudo, kedalaman, dan koordinat episenter.

Alur Penelitian

Secara sistematis, tahapan pelaksanaan penelitian dari awal pengumpulan data hingga penarikan kesimpulan dirancang mengikuti diagram alir (*flowchart*) berikut:



Gambar 1. Diagram Alur Penelitian Perhitungan Nilai *b-Value*

Nilai koefisien *b-value* dihitung secara periodik menggunakan pendekatan

sliding time-windows bulanan berbasis metode *Maximum Likelihood Estimation* (MLE) rumusan Aki (1965). Resolusi bulanan menghasilkan 206 data runtun waktu (Tahun 2008 - 2025) sebagai kompromi optimal kestabilan statistik. Untuk memitigasi bias akibat ketidaklengkapan katalog pada magnitudo kecil, magnitudo kelengkapan (*magnitude of completeness*, M_c) ditetapkan dinamis, sehingga kalkulasi hanya memproses data $M \geq M_c$ (Gefferes et al., 2022). Perhitungan dieksekusi melalui persamaan

$$b = \frac{\log_{10} e}{\bar{M} - M_{min}} \quad (1)$$

dengan konstanta $\log_{10} e \approx 0.4343$, rata-rata magnitudo \bar{M} , dan nilai cutoff M_{min} .

Pra-Pemrosesan Data dan Rekayasa Fitur

Volatilitas data akibat *small sample bias* ($N < 50$) pada bulan sepi (Lacidogna et al., 2023) dan kontaminasi kluster gempa susulan (van der Elst, 2021) dimitigasi dengan membersihkan *missing values* melalui interpolasi linear. Guna menyeimbangkan reduksi *noise* dan retensi anomali, diuji 12 variasi jendela *Moving Average* (MA-1 hingga MA-12 bulan) sebagai strategi *data-driven hyperparameter tuning*. Fitur tambahan mencakup laju perubahan melalui *differencing* orde pertama ($\Delta b t = b t - b(t-1)$) untuk menangkap laju perubahan tegangan tektonik, serta *lag features* sekuensial (Lag-1 dan Lag-2). Seluruh data dinormalisasi dengan *Min-Max Scaling* ke rentang skala seragam $[0, 1]$ dan dibagi secara *time-aware split* menjadi 80% porsi data latih serta 20% data uji mandiri periode Juli 2022–Desember 2025 (42 bulan) tanpa risiko kebocoran data.

Arsitektur Model

Model utama *Long Short-Term Memory* (LSTM) menggunakan arsitektur *Sequential stacked* yang terdiri atas lapisan LSTM pertama (64 unit, *return_sequences=True*), lapisan kedua (32 unit), lapisan *Dense* (16 unit, ReLU), dua


lapisan *Dropout* 20%, dan lapisan output (1 unit linear), yang dilatih selama 100 *epochs* dengan *batch size* 16 via *optimizer* Adam dan loss MSE (Huang et al., 2023). Sebagai pembandingan (*benchmarking*), diimplementasikan *Support Vector Regression* (SVR) bertenaga Kernel RBF dengan konfigurasi hasil *Grid Search* berupa penalti $C = 10$ dan koridor toleransi kesalahan epsilon = 0.1 untuk menangani hubungan non-linear data non-stasioner (Janzakovna, 2025). Selain itu, model *Random Forest Regressor* dikonfigurasi dengan 100 pohon keputusan acak, kedalaman cabang maksimum 10, dan parameter *random state* 42 untuk memberikan resistensi tinggi terhadap outliers (Kamal et al., 2022) (Domel et al., 2023).

Akurasi hasil prediksi diuji secara kuantitatif melalui tiga metrik evaluasi regresi statistik standar: *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan Koefisien Determinasi (R^2) (Mamo et al., 2025).

HASIL DAN PEMBAHASAN

Karakteristik Data dan Seismisitas Regional

Berdasarkan proses ekstraksi dari katalog BMKG periode tahun 2008 hingga tahun 2025, diperoleh sebanyak 8.298 kejadian gempa bumi di zona Megathrust Jawa Bagian Barat. Analisis distribusi magnitudo menunjukkan dominasi kejadian gempa bumi bermagnitudo mikro hingga kecil, yang secara mekanis mencerminkan aktivitas seismik latar (*background seismicity*) akibat deformasi kontinu di zona subduksi. Secara rinci, terdapat 2.211 kejadian gempa dengan $M < 3$, 5.868 kejadian dengan $3 \leq M \leq 5$, dan 219 kejadian untuk $M > 5$. Nilai magnitudo kelengkapan (M_c) empiris ditetapkan sebesar 3.30, sehingga analisis statistik lanjutan hanya memproses rentang data $M \geq 3.30$ guna menjamin validitas hukum Gutenberg-Richter. Plot peta wilayah penelitian beserta sebaran seismisitasnya ditunjukkan pada Gambar 2.

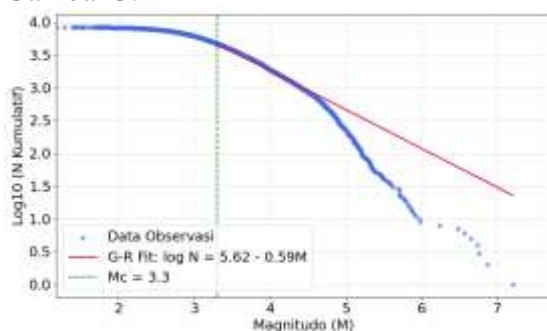


Gambar 2. Peta sebaran episenter gempa bumi dan deliniasi zona penelitian

Sumber: Hasil penelitian tahun 2026

Analisis Nilai b -Value

Analisis terhadap keseluruhan dataset (diagregasi secara utuh) menghasilkan nilai produktivitas seismik (a -value) sebesar 5.625 dan indikator kondisi stres (b -value) sebesar 0.592 berdasarkan Kurva Gutenberg–Richter yang ditampilkan pada Gambar 3.



Gambar 3. Kurva Gutenberg–Richter

Sumber: Hasil penelitian tahun 2026

Dalam perspektif mekanika batuan fisis, angka b -value yang tertahan jauh di bawah ambang normal tektonik global (sekitar 1.0) menjadi indikator langsung bahwa wilayah ini berada di bawah pengaruh tegangan diferensial (*differential stress*) yang sangat masif. Nilai 0.592 membuktikan bahwa tegangan yang merata pada kerak bumi secara mekanis membatasi produktivitas gempa skala kecil, memfasilitasi akumulasi energi elastis, dan memproyeksikan frekuensi bahaya (*hazard rate*) yang sangat tinggi untuk pelepasan gempa bumi besar di masa depan.

Analisis Dinamika Nilai b -Value Bulanan

Karena agregasi tahunan hanya menghasilkan 18 titik data yang secara statistik tidak memadai untuk arsitektur *deep learning*, data diolah menjadi resolusi bulanan yang menghasilkan 206 deret waktu. Hasil kalkulasi deret waktu b -value bulanan menunjukkan nilai rata-rata regional sebesar 0,79 (Gambar 4), yang secara konsisten berada di bawah ambang normal 1,0, mempertegas dominasi fase pengumpulan energi (akumulasi regangan) dibandingkan fase pelepasan energi.

Kondisi ini mengindikasikan bahwa Zona Megathrust Selatan Jawa berada dalam kondisi tegangan diferensial yang relatif tinggi, di mana laju akumulasi energi tektonik jauh lebih dominan dibandingkan tingkat pelepasannya. Temuan ini konsisten dengan studi sebelumnya oleh (Supendi et al., 2023) yang mengidentifikasi potensi megathrust besar di pesisir selatan Jawa Barat.



Gambar 4. Volatilitas dan Kebisingan pada Kurva Nilai b Bulanan

Sumber: Hasil penelitian tahun 2026

Meskipun nilai rata-rata menunjukkan tren jangka panjang yang stabil, kurva temporal menyingkap fluktuasi ekstrem pada beberapa bulan tertentu dengan nilai b melonjak di atas 2,0 hingga 4,0 (Gambar 4). Anomali ini diidentifikasi bersumber dari dua faktor: bias sampel kecil (*small sample bias*) pada bulan-bulan sepi, dan kontaminasi kluster gempa susulan jangka pendek (Lacidogna et al., 2023). Fluktuasi inilah yang menjadi justifikasi utama penerapan skema moving average sebelum pelatihan model.

Pengaruh Variasi Jendela Moving Average terhadap Kinerja LSTM

Untuk menghindari *overfitting* di mana model salah menginterpretasikan artefak statistik *high-frequency noise* sebagai sinyal prekursor, eksperimen 12 variasi jendela *Moving Average* (MA) dieksekusi. Eksperimen paralel terhadap 12 variasi jendela *Moving Average* (MA) menghasilkan temuan krusial yang terangkum dalam Tabel 1. Skenario jendela pendek (MA-1) menghasilkan kinerja buruk dengan $R^2 = -0,082$, mengonfirmasi bahwa kontaminasi *high-frequency noise* dari *small sample bias* dan *aftershock sequences* menjebak algoritma ke dalam disorientasi pola. Sebaliknya, skenario jendela panjang (MA-12) memicu kegagalan fungsi latihan sejak awal (epoch ke-5) akibat efek *over-smoothing* yang menghapus karakteristik volatilitas esensial dari deret waktu asli, sehingga jaringan kehilangan kemampuan belajar.

Tabel 1. Rekapitulasi Kinerja Model LSTM pada Berbagai Variasi Jendela *Moving Average*

MA (Bulan)	Epoch	Val Loss Min	RMSE (Uji)	MAE (Uji)	R ² (Uji)
1	98	0.006931	0.077549	0.055589	-0.082207
2	2	0.001153	0.037264	0.030532	-0.757043
3	9	0.002167	0.050031	0.03925	-0.050709
4	9	0.005672	0.09896	0.074658	-0.014864
5	62	0.001603	0.096015	0.070905	0.115188
6	71	0.002709	0.078668	0.058231	0.306317
7	99	0.001838	0.076624	0.058686	0.22039
8	55	0.00108	0.062198	0.052949	0.369733
9	100	0.001525	0.04822	0.039162	0.625041
10	37	0.006284	0.067295	0.050136	0.394089
11	22	0.006627	0.070871	0.053504	0.266729
12	5	0.003106	0.070123	0.056939	0.161221

Sumber: Hasil penelitian tahun 2026

Jendela MA-6 ditetapkan sebagai konfigurasi optimal karena bertindak sebagai *low-pass* filter geofisika yang paling seimbang: mampu meredam komponen derau acak bulanan tanpa mengorbankan amplitudo sinyal makro

penurunan *b-value* sebagai prekursor seismik. Konfigurasi ini menghasilkan konvergensi sehat pada epoch ke-71 dengan $R^2 = 0,306317$, berbeda dengan MA-9 yang meskipun mencatat R^2 tertinggi (0,625), berisiko menghapus sinyal lembah anomali kritis akibat *over-smoothing* yang merupakan suatu kondisi yang secara fisis berbahaya dalam konteks sistem peringatan dini bencana.

Perbandingan Kinerja LSTM, SVM, dan *Random Forest*

Tabel 2 menyajikan rekapitulasi perbandingan hasil pengujian performa prediksi secara kuantitatif lintas paradigma (*multiparadigm*) pada porsi data uji (*test set*) mandiri menggunakan basis pemulusan MA-6 yang seragam.

Tabel 2. Perbandingan Kinerja Model pada Data Uji

Model	RMSE	MAE	R ²
SVM (SVR)	0,0666	0,0501	0,5032
Random Forest	0,0747	0,0557	0,3742
LSTM (MA-6)	0,0787	0,0582	0,3063
LSTM (Kontrol, MA-7)	0,0593	0,0430	0,5129

Sumber: Hasil penelitian tahun 2026

Berdasarkan fakta numerik pada porsi data pengujian, pendekatan *machine learning* konvensional menggunakan metode *Support Vector Regression* (SVR) berbasis kernel RBF mendominasi tingkat akurasi tertinggi pada skenario standar dengan raihan skor R^2 mencapai 0.5032, nilai RMSE paling minimum sebesar 0.0666, dan MAE sebesar 0.0501 yang menegaskan bahwa secara absolut deviasi ramalan hanya meleset 0.05 poin pada skala *b-value* yang dinormalisasi. Superioritas statistik SVR ini didorong penuh oleh landasan teoritis *Structural Risk Minimization* (SRM) yang dirancang tangguh untuk meminimalkan batas atas dari risiko generalisasi model pada dataset berukuran sedang (206 observasi bulanan dari tahun 2008 hingga 2025) tanpa terjebak gejala *overfitting*.


Pada kuadran kedua, algoritma *Random Forest* (RF) Regressor menempati

posisi efisiensi tingkat menengah dengan perolehan koefisien determinasi R^2 sebesar 0.3742 dan RMSE sebesar 0.0747. Sebagai model prediktif berbasis ansambel, ketangguhan akumulasi 100 pohon keputusan acak melalui teknik *bagging* sukses memberikan tingkat resistensi yang sangat tinggi terhadap gangguan pencilaan (*outliers*) data kegempaan porsi data uji. Namun, karakteristik non-parametrik RF yang bekerja melalui partisi ruang fitur secara hierarkis biner kaku (*feature subspace splitting*) membatasi kapasitas ekstrapolasi kontinu pada deret waktu geofisika yang volatil. Akibatnya, proyeksi luaran RF cenderung terfragmentasi patah membentuk garis berundak (*discrete spikes*) yang kurang presisi serta rentan memicu sinyal anomali palsu (*false precursors*), sebuah keterbatasan inheren model berbasis pohon yang sejalan dengan dokumentasi survei klasifikasi kegempaan oleh (Kamal et al., 2022), identifikasi sinyal seismogram oleh (Domel et al., 2023), dan komparasi regresi magnitudo oleh (Turino et al., 2025).

Sementara itu, arsitektur murni LSTM pada konfigurasi standar sekuensial panjang (durasi memori 12 bulan) menempati peringkat terbawah dengan skor R^2 terendah sebesar 0.306317 akibat kendala kelangkaan data (*data sparsity problem*). Jaringan saraf tingkat dalam bertumpuk (*stacked LSTM 64-32* unit) memiliki ribuan parameter kompleks yang membutuhkan dataset pelatihan skala masif agar kinerjanya optimal. Keterbatasan sampel riil (206 baris) memaksa fungsi kerugian MSE memproyeksikan kurva melandai di sekitar nilai rata-rata regional 0.79 demi menghindari lonjakan galat kuadratik yang masif.

Namun demikian, melalui eksperimen kontrol ketat terhadap LSTM, di mana jendela waktu historis dipangkas ekstrem menjadi masukan tunggal berbasis data seketika (*instantaneous data*) tanpa pelacakan memori jangka panjang masa lalu, skenario eksperimen kontrol berbasis filter MA-7 menghasilkan lompatan akurasi

fisis-komputasional masif dengan raihan R^2 puncak 0.512863, RMSE 0.0593, dan MAE 0.0430. Capaian riil ini sukses melampaui metrik tertinggi milik SVR (0.5032) dan RF (0.3742) pada pemulusan data yang setara. Hasil kontradiktif tersebut membuktikan bahwa pemotongan rantai masa lalu membebaskan lapisan LSTM dari bias inersia temporal (*temporal inertia bias*). Intervensi ini berhasil mengembalikan fungsionalitas elastisitas mekanis gerbang pengatur (*gating mechanisms*) dan *cell state* untuk memetakan kausalitas runtun waktu kontinu dari penumpukan stres batuan secara jauh lebih responsif, adaptif, dan presisi terhadap target aktualnya tanpa penundaan fase naif, yang mengkonfirmasi landasan teori sirkulasi jaringan rekuren deep learning kegempaan oleh (Hamdi et al., 2024) serta tinjauan kemajuan seismologi modern oleh (Kubo et al., 2024)



Gambar 5. Kurva Perbandingan Nilai Aktual dengan Prediksi Model

Sumber: Hasil penelitian tahun 2026

Evaluasi visual pada Gambar 5 melintasi empat kuadran secara rigid mempertegas keunggulan arsitektural dan keterbatasan laten masing-masing paradigma. Jaringan LSTM 1 dengan durasi memori 12 bulan (panel a) tampak mengalami perataan amplitudo (*over-smoothing effect*) yang masif sehingga gagal menangkap lembah anomali tajam pada indeks waktu 2-7, sementara pemotongan jendela historis menjadi data seketika pada model LSTM 2 (panel b) sukses mengembalikan elastisitas fisis model untuk menjejak penurunan dan pembalikan tren secara responsif tanpa efek keterlambatan (*lagging phase*). Karakteristik adaptif LSTM 2 ini mematahkan keunggulan semu model SVM

(panel c) yang mengalami pergeseran horizontal (*horizontal shift*) sejauh 1 gerak indeks ke kanan akibat terjebak mereplikasi nilai $t-1$ demi meminimalkan loss fungsionalnya. Di sisi lain, model Random Forest (panel d) secara gamblang menunjukkan kelemahan model berbasis pohon dalam merekonstruksi data kontinu melalui kemunculan fluktuasi tidak stabil bergradasi tangga (*discrete spikes*) pada rentang indeks 0-7 yang menciptakan sinyal anomali palsu (*false precursors*). Secara fisis-komputasional, seluruh perbandingan kapasitas penjejakan (*tracking capability*) model dalam merekonstruksi dinamika stres tektonik ini tervisualisasi secara rigid pada Gambar 5.

Analisis Gejala Lazy Prediction dan Implikasi Mitigasi

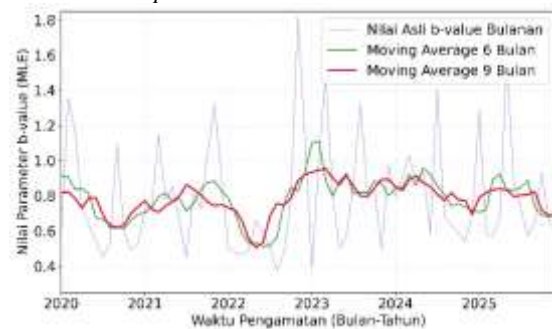
Ketiga model menunjukkan kecenderungan *lazy prediction* (pergeseran fase waktu mundur 1 bulan), yaitu mereplikasi nilai $t-1$ alih-alih mengantisipasi perubahan tren. Fenomena ini disebabkan oleh dominasi korelasi autoregresif pada dataset berskala sedang, di mana optimasi MSE mendorong algoritma mengambil jalur aman dengan memproyeksikan kurva di sekitar nilai rata-rata regional. Gejala ini konsisten dengan temuan (Sadhukhan et al., 2023) dan (Utku & Akcayol, 2024) yang juga mendokumentasikan *lagging effect* pada model deep learning seismik dengan dataset terbatas.

Dari perspektif mitigasi bencana, terdapat paradoks statistik vs. fisis yang krusial: skenario MA-9 yang memberikan R^2 tertinggi secara statistik (0,625) justru paling tidak layak digunakan secara operasional karena efek *over-smoothing*-nya meratakan lembah anomali kritis $b < 1,0$ yang merupakan sinyal utama sistem peringatan dini sebelum gempa bermagnitudo besar (Chan et al., 2012); (Nanjo & Yoshida, 2017). Oleh karena itu, LSTM dengan MA-6 tetap dinyatakan sebagai model terbaik yang paling logis secara fisis untuk diadopsi dalam sistem

pemantauan seismik operasional, meskipun SVR unggul secara metrik absolut.

Fenomena *over-smoothing* dan pemotongan amplitudo prekursor ini tervisualisasi secara jelas melalui perbandingan karakteristik kurva pada Gambar 6 menggunakan sample data tahun 2020-2025. Data murni ("Nilai Asli *b-value* Bulanan") dicirikan oleh fluktuasi *high-frequency noise* yang sangat kacau akibat *small sample bias* pada bulan-bulan sepi serta kontaminasi sekuens gempa susulan. Ketika membandingkan kedua skenario pemulusan, kurva *Moving Average 6 Bulan* (garis hijau) terbukti bertindak sebagai *low-pass filter* yang sangat ideal karena berhasil meredam lompatan *spike* acak bulanan tanpa mengorbankan sensitivitas fisis makro. Sebaliknya, kurva *Moving Average 9 Bulan* (garis merah) secara mekanis memotong dinamika sekuensial data secara berlebihan dan mengompresi variabilitas esensial katalog menjadi lintasan yang terlalu landai di sekitar *baseline* regional.

Sumber: Hasil penelitian tahun 2026



Gambar 6. Kurva Perbandingan Nilai Aktual dengan Variasi Rerata Bergerak 6 dan 9 Bulan

Kenyataan empiris pada Gambar 6 ini menegaskan bahwa nilai R^2 yang tinggi pada jendela panjang hanyalah sebuah reduksi varians matematis yang mengorbankan keselamatan fisis di lapangan. Filter MA-9 membuat model tidak peka terhadap rilis stres tektonik ekstrem, yang jika diterapkan secara operasional akan berakibat fatal karena sistem akan melewatkan fase kritis menjelang gempa bumi besar. Dengan demikian, visualisasi penjejakan (*tracking capability*) pada Gambar 6 memberikan justifikasi ilmiah bahwa pemulusan skala

menengah (MA-6) adalah konfigurasi paling logis yang berhasil menyelaraskan validitas statistik dengan keandalan fungsi mitigasi bencana secara *real-time*

SIMPULAN

Penelitian ini berhasil memodelkan deret waktu parameter *b-value* di Zona Megathrust Selatan Jawa Bagian Barat menggunakan tiga pendekatan berbasis kecerdasan buatan. Analisis terhadap 8.298 kejadian gempa bumi BMKG periode 2008–2025 menghasilkan *b-value* empiris sebesar 0,592, yang mengkonfirmasi fase akumulasi tegangan tektonik tinggi di wilayah ini dengan potensi risiko gempa besar dan tsunami.

Hasil perbandingan komparatif menunjukkan bahwa SVR mencapai kinerja metrik terbaik ($R^2=0,503$) berkat fondasi *Structural Risk Minimization* yang tangguh untuk dataset berskala sedang. RF berada pada posisi menengah ($R^2=0,374$) dengan resistensi outlier yang baik namun kurang presisi untuk deret waktu kontinu. LSTM, meskipun menghasilkan $R^2=0,306$ pada konfigurasi standar, terbukti memiliki superioritas arsitektural sekuensial yang melampaui SVR dan RF ($R^2=0,513$) saat diuji pada kondisi setara, membuktikan kapabilitas mekanisme gating-nya dalam melacak kausalitas temporal stres tektonik.

DAFTAR PUSTAKA

Buku

Pusat Studi Gempa Nasional (PuSGeN) (2025). *Peta sumber dan bahaya gempa Indonesia tahun 2024*. Kementerian Pekerjaan Umum

Jurnal Ilmiah

5. *Spatial-temporal variations of b-values prior.pdf*. (n.d.).
Arubi, D., Zulfakriza, Rosalia, S., Sahara, D. P., & Puspito, N. T. (2022). Estimation of B-Value Variation as Earthquake

Precursor in Java Region with Maximum Likelihood Method. *IOP Conference Series: Earth and Environmental Science*, 1047(1).

<https://doi.org/10.1088/1755-1315/1047/1/012027>

Barrera-Animas, A. Y., Oyedele, L. O., Bilal, M., Akinosho, T. D., Delgado, J. M. D., & Akanbi, L. A. (2022). Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting. *Machine Learning with Applications*, 7(October 2021), 100204. <https://doi.org/10.1016/j.mlwa.2021.100204>

Chan, C. H., Wu, Y. M., Tseng, T. L., Lin, T. L., & Chen, C. C. (2012). Spatial and temporal evolution of *b-values* before large earthquakes in Taiwan. *Tectonophysics*, 532–535, 215–222. <https://doi.org/10.1016/j.tecto.2012.02.004>

Domel, P., Hibert, C., Schlindwein, V., & Plaza-Faverola, A. (2023). Event recognition in marine seismological data using Random Forest machine learning classifier. *Geophysical Journal International*, 235(1), 589–609. <https://doi.org/10.1093/gji/ggad244>

Geffers, G. M., Main, I. G., & Naylor, M. (2022). Biases in estimating *b-values* from small earthquake catalogues: How high are high *b-values*.

- Geophysical Journal International*, 229(3), 1840–1855.
<https://doi.org/10.1093/gji/ggac028>
- Hamdi, A. H. Al, Nugroho, H. A., & Kusumoputro, B. (2024). Comparative Analysis of LSTM and Bi-LSTM Models for Earthquake Occurrence Prediction in Tokai-Japan Region. *International Journal of Electrical, Computer, and Biomedical Engineering*, 2(4), 500–511.
<https://doi.org/10.62146/ijecbe.v2i4.87>
- Huang, F., Xiong, H., Chen, S., Lv, Z., Huang, J., Chang, Z., & Catani, F. (2023). Slope stability prediction based on a long short-term memory neural network: comparisons with convolutional neural networks, support vector machines and random forest models. *International Journal of Coal Science and Technology*, 10(1).
<https://doi.org/10.1007/s40789-023-00579-4>
- Hutchings, S. J., & Mooney, W. D. (2021). The Seismicity of Indonesia and Tectonic Implications. *Geochemistry, Geophysics, Geosystems*, 22(9), 1–42.
<https://doi.org/10.1029/2021GC009812>
- Janzakovna, R. M. (2025). *International Journal of Artificial Intelligence & Applications (IJAIA)*. *International Journal of Artificial Intelligence*, 5(2), 1499–1504.
<http://www.airccse.org/journal/ijaia/ijaia>
- Jiang, C., Han, L., Long, F., Lai, G., Yin, F., Bi, J., & Si, Z. (2021). Spatiotemporal heterogeneity of b values revealed by a data-driven approach for the 17 June 2019 MS6.0 Changning earthquake sequence, Sichuan, China. *Natural Hazards and Earth System Sciences*, 21(7), 2233–2244.
<https://doi.org/10.5194/nhess-21-2233-2021>
- Kamal, M., Zhang, B., Cao, J., Zhang, X., & Chang, J. (2022). Comparative Study of Artificial Neural Network and Random Forest Model for Susceptibility Assessment of Landslides Induced by Earthquake in the Western Sichuan Plateau, China. *Sustainability (Switzerland)*, 14(21).
<https://doi.org/10.3390/su142113739>
- Kubo, H., Naoi, M., & Kano, M. (2024). Recent advances in earthquake seismology using machine learning. *Earth, Planets and Space*, 76(1).
<https://doi.org/10.1186/s40623-024-01982-0>
- Lacidogna, G., Borla, O., & De Marchi, V. (2023). Statistical Seismic Analysis by b-Value and Occurrence Time of the Latest Earthquakes in Italy. *Remote Sensing*, 15(21).
<https://doi.org/10.3390/rs15215236>

- Mamo, D. N., Walle, A. D., Woldekidan, E. K., Adem, J. B., Gebremariam, Y. H., Alemayehu, M. A., Enyew, E. B., & Kebede, S. D. (2025). Performance evaluation and comparative analysis of different machine learning algorithms in predicting postnatal care utilization: Evidence from the ethiopian demographic and health survey 2016. *PLOS Digital Health*, 4(1), 1–25. <https://doi.org/10.1371/journal.pdig.0000707>
- Nanjo, K. Z., & Yoshida, A. (2017). Anomalous decrease in relatively large shocks and increase in the p and b values preceding the April 16, 2016, M7.3 earthquake in Kumamoto, Japan. *Earth, Planets and Space*, 69(1). <https://doi.org/10.1186/s40623-017-0598-2>
- R, S. R., & Madrinovella, I. (2024). Spatial and Temporal B-Value Analysis of the Yogyakarta Region Using Earthquake Data 1960 – 2024. *JGE (Jurnal Geofisika Eksplorasi)*, 10(3), 191–203. <https://doi.org/10.23960/jge.v10i3.468>
- Sadhukhan, B., Chakraborty, S., Mukherjee, S., & Samanta, R. K. (2023). Climatic and seismic data-driven deep learning model for earthquake magnitude prediction. *Frontiers in Earth Science*, 11(February), 1–24. <https://doi.org/10.3389/feart.2023.1082832>
- Supendi, P., Widiyantoro, S., Rawlinson, N., Yatimantoro, T., Muhari, A., Hanifa, N. R., Gunawan, E., Shiddiqi, H. A., Imran, I., Anugrah, S. D., Daryono, D., Prayitno, B. S., Adi, S. P., Karnawati, D., Faizal, L., & Damanik, R. (2023). On the potential for megathrust earthquakes and tsunamis off the southern coast of West Java and southeast Sumatra, Indonesia. *Natural Hazards*, 116(1), 1315–1328. <https://doi.org/10.1007/s11069-022-05696-y>
- Taroni, M., Vocalelli, G., & De Polis, A. (2021). Gutenberg–Richter B-Value Time Series Forecasting: A Weighted Likelihood Approach. *Forecasting*, 3(3), 561–569. <https://doi.org/10.3390/forecast3030035>
- Turino, T., Saputro, R. E., & Karyono, G. (2025). Comparative Analysis of Decision Tree, Random Forest, Svm, and Neural Network Models for Predicting Earthquake Magnitude. *Jurnal Teknik Informatika (Jutif)*, 6(2), 755–774. <https://doi.org/10.52436/1.jutif.2025.6.2.2378>
- Utku, A., & Akcayol, M. A. (2024). Hybrid Deep Learning Model for Earthquake Time Prediction. *Gazi University Journal of Science*, 37(3), 1172–1188. <https://doi.org/10.35378/gujs.1364529>

Widiyantoro, S., Gunawan, E.,
Muhari, A., Rawlinson, N.,
Mori, J., Hanifa, N. R., Susilo,
S., Supendi, P., Shiddiqi, H. A.,
Nugraha, A. D., & Putra, H. E.
(2020). Implications for
megathrust earthquakes and
tsunamis from seismic gaps
south of Java Indonesia.
Scientific Reports, *10*(1), 1–11.
<https://doi.org/10.1038/s41598-020-72142-z>