
Analisis Time Series Untuk Deep Learning Dan Prediksi Data Spasial Seismik: Studi Literatur

Eko Nur Cahyo¹, Erma Susanti*²

^{1,2}Jurusan Informatika, Institut Sains & Teknologi AKPRIND Yogyakarta

e-mail : erma@akprind.ac.id

ABSTRACT

Time series analysis is a deep learning method to process data stored in a dense time. This method works for forecast data in particular cases, such as to analyze and provide the output of a trend from the data. Time series analysis can be used to analyze trends in natural disasters such as earthquakes in Indonesia. As technology advances today, in addition to using seismographs or tools to predict seismic phenomena on the earth's surface, time series analysis can be used to make forecasts and predictions. This paper will summarize various literature reviews about time series analysis and previous research to predict seismic spatial data over the last ten years. The goal is to afford the several approaches or algorithms to be able to forecast seismic spatial data to increase awareness. The results of this literature study were used to find trends, state of the arts, and research challenges and develop new models or methods to predict seismic spatial data. The study shows that deep learning methods can achieve better accurate performance in processing seismic spatial data and other complex data than conventional methods. The deep learning methods can use Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gate Recurrent Unit (GRU), linear regression, and Artificial Neural Network (ANN).

Keywords: *deep learning, earthquake, forecasting, spatial data seismic, time series analysis.*

INTISARI

Analisis time series adalah sebuah metode deep learning yang digunakan untuk mengolah data yang tersimpan dalam rentang waktu yang padat. Metode ini biasanya digunakan untuk melakukan peramalan data pada kasus tertentu, seperti untuk melakukan analisa dan memberikan output sebuah tren dari sebuah data. Analisis time series juga dapat digunakan untuk melakukan analisa terhadap tren kejadian bencana alam seperti gempa bumi di Indonesia. Seiring majunya teknologi di masa sekarang, selain menggunakan seismograf atau alat yang digunakan untuk memprediksi gejala seismik yang terjadi di permukaan bumi, analisis time series dapat digunakan untuk melakukan peramalan dan prediksi. Paper ini akan merangkum berbagai literatur review berkaitan dengan analisis time series dan berbagai metode yang pernah digunakan untuk prediksi data spasial seismik selama sepuluh tahun terakhir. Tujuannya untuk dapat menemukan metode ataupun algoritma yang tepat untuk dapat melakukan peramalan data spasial seismik, sehingga dapat meningkatkan kewaspadaan. Hasil studi literatur ini diarahkan untuk dapat menemukan tren, state of the art, tantangan penelitian, dan pengembangan model atau metode baru dalam prediksi data spasial seismik. Hasil studi menunjukkan bahwa metode deep learning seperti Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gate Recurrent Unit (GRU), linear regression, dan Artificial Neural Network (ANN) dapat memberikan kinerja akurasi yang baik untuk mengolah data spasial seismik dan mengolah data kompleks lainnya jika dibandingkan dengan metode konvensional.

Kata kunci: analisis time series, data spasial seismik, deep learning, gempa, peramalan

PENDAHULUAN

Indonesia adalah negara kepulauan terbesar di dunia dengan memiliki lebih dari 17.000 pulau yang dilalui oleh jalur pertemuan tiga lempeng tektonik yaitu Lempeng Eurasia, Lempeng Pasifik, dan Lempeng Indo-Australia (Brilliantina et al., 2021). Dilihat dari letak geografisnya menjadikan Indonesia rawan terhadap gempa bumi karena aktivitas vulkanik maupun aktivitas tektonik bumi. Berdasarkan catatan dari Badan Pusat Statistik (BPS), terdapat 10.519 frekuensi gempa bumi di Indonesia sepanjang tahun 2021. Jumlah tersebut naik 25,7% dibandingkan tahun sebelumnya dengan jumlah 8.368 frekuensi gempa bumi. Peningkatan gempa bumi terbanyak sepanjang 2021 terjadi di Pulau Sulawesi sebanyak 925 kali. Adapun 80,93% kejadian gempa bumi di Indonesia tergolong gempa bumi dengan kekuatan kecil, gempa tersebut kurang dari 40 SR (Rizaty, 2022). Gempa bumi yang terjadi di Indonesia misalnya adalah gempa bumi di zona Graben, Bantul, Yogyakarta pada tanggal

27 Mei 2006 yang menyebabkan kerusakan dan menelan korban jiwa sangat besar (Daryono et al., 2018). Gempa bumi yang diakibatkan oleh meletusnya gunung merapi pada tahun 2010 (Latifiana, 2019). Gempa Lombok yang terjadi pada tahun 2018 yang membawa dampak yang signifikan bagi masyarakat baik fisik, psikologis, maupun sosial (Thoyibah et al., 2020). Masih banyak lagi potensi bencana alam yang mungkin terjadi di Indonesia karena letak geografisnya misalnya letusan gunung berapi, tsunami, tanah longsor, banjir dan penurunan struktur tanah (Ito et al., 2012) (Gunawan et al., 2014) (Anugrah et al., 2015) (Ardika et al., 2015) (Alif et al., 2016) (Gunawan et al., 2017).

Banyaknya kejadian bencana alam seismik mendorong untuk melakukan pengembangan teknologi yang dapat meningkatkan kewaspadaan masyarakat. Salah satu teknologi yang dapat digunakan adalah analisis time series. Teknologi ini dapat digunakan untuk melakukan peramalan dan prediksi. Penelitian ini dilakukan untuk mengetahui berbagai metode yang pernah digunakan oleh peneliti sebelumnya seperti Support Vector Machine (SVM), K-Nearest Neighbor (K-NN), Naïve Bayes, Probabilistic Neural Network (PNN), kombinasi RNN dan LSTM Layer, dan beberapa model jaringan syaraf lainnya (Muhuri et al., 2020). Algoritma-algoritma tersebut dapat digunakan untuk analisis time series untuk peramalan data spasial seismik ataupun sebagai acuan untuk meningkatkan kewaspadaan masyarakat dalam mengantisipasi adanya bencana alam seismik. Studi literatur perlu dilakukan untuk mengetahui mana algoritma yang memiliki kinerja dengan akurasi yang lebih baik diantara metode lainnya.

Paper ini akan merangkum hasil studi literatur berkaitan dengan perkembangan penelitian analisis time series atau analisis runtun waktu dalam kurun waktu sepuluh tahun terakhir untuk mendeskripsikan tantangan pada penelitian tentang prediksi data spasial seismik. Pada bagian kedua akan dijelaskan tentang metode studi literatur yang digunakan, cakupan review dan struktur review. Bagian ketiga akan membahas tentang beberapa konsep dasar berkaitan dengan analisis time series dan hasil review berbagai pendekatan, metode, algoritma tentang penelitian analisis time series untuk deep learning dan prediksi data spasial seismik. Terakhir bagian keempat akan menjelaskan tentang kesimpulan..

METODE PENELITIAN

Metodologi Review

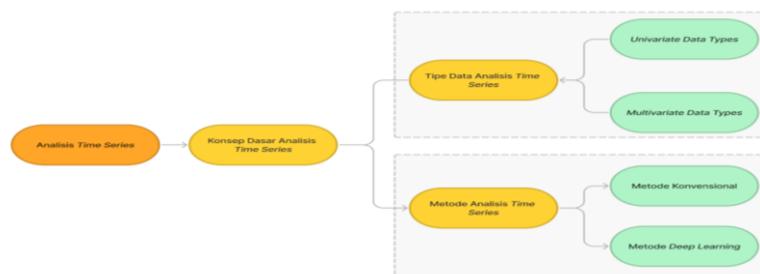
Penelitian ini menggunakan metode kajian literatur sebagai metode utama. Kajian literatur merupakan ringkasan tertulis mengenai suatu artikel dari jurnal, buku, dan dokumen lain yang digunakan untuk mendukung sebuah studi penelitian. Menghimpun data-data yang relevan dengan kebutuhan penelitian untuk mendukung sebuah penelitian, dengan tujuan analisis untuk memudahkan sebuah penelitian (Habsy, 2017). Penelitian ini mengumpulkan, mempelajari dan menganalisis beberapa literatur yang relevan dengan analisis time series, dengan menggunakan kata kunci '*time series analysis*', '*recurrent neural network*', '*long short-term memory*', '*prediction*', '*forecasting*', dan '*seismik*'.

Cakupan Review

Cakupan pada penelitian ini berfokus pada analisis time series dan penerapannya pada deep learning dan data spasial seismik. Penelitian ini memperhatikan kesamaan antara sumber literatur dengan penelitian yang dilakukan, hal yang diperhatikan adalah langkah pengambilan data time series, proses analisis time series, kesamaan data dan penggunaan algoritma penelitian, dan variasi penggunaan algoritma (Alqahtani et al., 2021).

Struktur Review

Penelitian ini merupakan sebuah studi untuk kasus analisis time series pada deep learning dan data spasial seismik, pada penelitian ini memiliki struktur atau tahapan penelitian yang ditampilkan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Tahap pertama pada penelitian ini adalah menjelaskan bagaimana analisis time series itu dilakukan yang kemudian menghasilkan sebuah data yang dapat dimengerti oleh khalayak, kemudian tahap yang kedua adalah memberikan penjelasan tentang konsep dasar dari analisis time series yang merupakan konsep dasar bagaimana time series dapat bekerja dan tahap yang terakhir adalah membagi konsep dasar tersebut menjadi tipe data dalam analisis time series yaitu terdapat dua tipe data yaitu *univariate data types* dan *multivariate data types*, kemudian metode analisis time series yang memiliki dua metode yaitu metode konvensional dan metode *deep learning*.

HASIL DAN PEMBAHASAN

1. Analisis Time Series

Analisis time series adalah proses memahami data dengan melakukan analisa terhadap sekumpulan data dari deret waktu dari sebuah pengamatan memiliki interval yang konsisten. Data dikumpulkan kemudian dilakukan analisa kemudian dapat dilihat bahwa terdapat pola yang muncul. Pola tersebut terbagi menjadi tiga jenis pola yaitu tren (*trend*), siklus (*cycle*), dan pola musiman (*seasonal*) (Al'afi et al., 2020). Pola musiman (*seasonal*) adalah pola yang berulang dari waktu ke waktu yang memiliki interval yang teratur dan konsisten. Kemudian berdasarkan pembagian wilayah data (*domain*), data time series dibagi menjadi dua wilayah utama (*domain*) yaitu wilayah waktu (*times domain*) dan wilayah frekuensi (*frequency domain*). Wilayah waktu atau *time domain* melakukan pemeriksaan pada *autocorrelation*, *stationary*, melakukan estimasi terhadap parameter model regresi pada data *time series*, *forecasting* dan *prediction*. Wilayah frekuensi atau *frequency domain* adalah sebuah interval yang ada pada sebuah data time series, yang membentuk pola perekaman pada data tertentu. Pengambilan pola frekuensi tersebut dapat menggunakan metode analisis spektral (Al'afi et al., 2020).

2. Konsep Dasar Analisis Time Series

Time series merupakan deretan atau rangkaian data yang memiliki rentang waktu tertentu yang memiliki interval yang sama. Dalam dunia industri memiliki fungsi sebagai pendukung terhadap keputusan yang akan ditentukan waktu sekarang, untuk proyeksi maupun untuk melakukan peramalan di masa depan. Data time series selalu diawali dengan tanggal mulai dan tanggal berakhir (Azis et al., 2020) dengan tambahan data pendukung lainnya misalnya *magnitude* dan *depth* pada data seismik. Data time series diolah untuk mengetahui *trends* dan *seasonal variations*. Cara kerja dari pengolahan data time series adalah dengan cara mempelajari data di masa lampau, setelah mendapat *trends* dari data model akan dapat memberikan peramalan untuk kurun waktu tertentu, karena sebuah data time series memiliki *autocorrelation* atau data di masa depan memiliki nilai yang saling ketergantungan dengan data di masa lalu. Contoh sederhananya adalah analisis *time series* yang digunakan dokter untuk menyediakan alatnya untuk mengevaluasi karakteristik pasien dan mengelola data praktiknya (Azis et al., 2020).

3. Tipe Data Analisis Time Series

Tipe data dalam time series adalah sebuah istilah umum yang dipakai semua jenis data yang memiliki komponen waktu yang bersifat sekuensial. Tipe data ini dapat diartikan sebagai deretan pengamatan atau serangkaian data yang teratur dan terurut yang dibuat dari waktu ke waktu, dan juga memiliki interval waktu yang berkesinambungan. Pemrosesan dan analisis data time series tersebut memerlukan keterampilan khusus dan metode pendukung untuk memahami kompleksitas dari deret data dan untuk menyelidiki proses yang mendasarinya. Tipe data time series dapat diklasifikasikan menjadi dua kategori yaitu, konsep tipe data *univariate* dan *multivariate* (Alqahtani et al., 2021).

a. Tipe Data *Univariate*

Tipe data *univariate* adalah sebuah deretan data yang hanya berisi satu nilai data per deret waktu yang primitif (Aigner et al., 2011) (Hotz & Peikert, 2014) (Alqahtani et al., 2018) (Zheng et al., 2014). Jenis tipe data ini hanya mempunyai variabel tunggal yang direkam atau diamati dari waktu ke waktu, sehingga tipe data ini dikatakan primitif. Penerapan tipe data ini secara nyata misalnya pada perekaman data suhu kota yang hanya memiliki satu variabel saja yaitu data suhu, penggunaan tipe data ini dimaksudkan untuk memberikan penekanan pada suatu data kasus yang dianggap variabel dependen yang bergantung pada setiap data waktu yang teratur, sehingga data suhu tersebut dapat diketahui dari waktu ke waktu dan akan

berdampak pada kebijakan yang akan diambil untuk mengurangi peningkatan suhu yang drastis.

b. Tipe Data *Multivariate*

Tipe data multivariate merupakan suatu sekumpulan time series dengan timestamps yang sama dan dimungkinkan untuk memiliki beberapa variabel (Aigner et al., 2011) (Hotz & Peikert, 2014) (Alqahtani et al., 2018) (Zheng et al., 2014). Jenis tipe data time series ini merupakan sebuah deret variabel yang berupa angka pada setiap time series point dan tipe data ini dapat berupa sekumpulan beberapa tipe data univariate yang ditampung dari waktu ke waktu. Penggunaannya secara nyata adalah pengembangan dari tipe data univariate yaitu pembacaan suhu dan tekanan (Alqahtani et al., 2021), pada kasus tersebut dimungkinkan memiliki beberapa variabel yang dapat dikumpulkan yaitu data suhu, data tekanan dan data timestamps. Data time series adalah sekumpulan pengamatan yang teratur dan merupakan serangkaian titik data yang dibuat secara sekuensial dari waktu ke waktu, jenis tipe data deret waktu multivariate khusus ini berguna di bidang-bidang seperti biologi, kedokteran, keuangan, animasi, (Alqahtani et al., 2021) dan tidak menutup kemungkinan untuk dapat relevan di berbagai bidang lainnya. Penggunaan metode ini misalnya dalam bidang kesehatan yaitu tenaga medis menggunakan data time series untuk pengukuran tekanan darah pasien dari waktu ke waktu kemudian data tersebut digunakan untuk memahami riwayat pemeriksaan pasien dan menangani kasus dengan baik (Cho et al., 2014). Selain itu, data time series dengan tipe data multivariate ini dapat digunakan dalam bidang keuangan untuk mencatat data transaksi yang mencakup data dari waktu ke waktu, pencatatan data pada pasar saham, dan pasar keuangan internasional, kemudian data tersebut dapat digunakan untuk melakukan analisis, memahami data dan melakukan prediksi, sehingga didapatkan korelasi antara data pasar dan hipotesis uji sehingga dapat menentukan kebijakan yang tepat pada bisnis (Alqahtani et al., 2021). Tipe data ini juga dapat digunakan untuk melakukan pencatatan untuk data seismik yang dapat mencatat beberapa data univariate, pada kasus ini misalnya adalah data gempa bumi, data yang dapat dicatat adalah data magnitudo, data kedalaman gempa, dan data timestamps. Pengolahan dan pencatatan data tersebut dapat memudahkan untuk pengambilan keputusan terhadap masalah gempa bumi pada daerah tertentu yang dianggap rawan terjadi gempa bumi.

4. Metode Analisis *Time Series*

Penelitian ini menggunakan dua metode yang dari segi karakteristiknya cukup berbeda yaitu menggunakan metode konvensional pada metode ini menggunakan metode yang berdasarkan teori-teori matematika dan statistika yang cukup mendasar sedangkan metode yang kedua adalah metode deep learning yang sedang marak saat ini penggunaannya dalam analisis data time series khususnya untuk data spasial seismik.

a. Metode Konvensional

Penelitian yang dilakukan oleh Susilo (Susilo et al., 2017) menggunakan metode co-seismic deformation yang mengolah data time series dari parameter gempa bumi dan dihitung menggunakan model spherical berlapis (Pollitz, 1996). Metode penelitian yang dipakai juga adalah continuous GPS (cGPS) yang digunakan untuk melakukan perkiraan deformasi co-seismic, dan kemudian hasilnya dianalisis menggunakan root mean square error (rmse) dari residual co-seismic. Hasil persebaran data tersebut kemudian ditandai dengan heatmap dengan parameter kedalaman gempa bumi (earthquake depth) untuk tingkat kedalaman gempa bumi.

Penelitian yang dilakukan oleh Min Lin (Lin et al., 2020) menggunakan cross-correlation atau korelasi silang untuk mengetahui hubungan antara data spasial seismik temporal dengan data spasial menggunakan metode *detrended cross-correlation analysis* (DCCA) dan *temporal evolution of detrended cross-correlation analysis* (TDCCA). Data yang digunakan dalam penelitian ini adalah data inter-earthquakes times (IET) dan *inter-earthquakes distances* (IED) yang terjadi secara temporal pada wilayah California dan Sumatera dari tahun 1990 sampai dengan 2013. Kemudian dari pengolahan data tersebut diambil kesimpulan bahwa melalui metode korelasi silang ditemukan adanya hubungan korelasi silang antara IET dan IED, dan ditemukan juga koefisien korelasi silang DCCA yang menunjukkan signifikan positif yang memiliki perubahan skala, kemudian TDCCA juga menunjukkan korelasi silang pada ukuran skala ukuran jendela yang masing-masing memiliki perbedaan. Tingkat korelasi silang antara IET dan IED yang kuat ketika terjadi gempa besar, sedangkan korelasi silang lemah tidak ditemukan.

Penelitian Hiro Nimiya (Nimiya et al., 2017) melakukan penelitian pada *earthquake faults and volcanoes* yang terjadi di Jepang, menggunakan metode pemetaan data *generic mapping tools*, melakukan perhitungan terhadap data harian dengan *cross-correlations*, melakukan estimasi terhadap seismic velocity change menggunakan *stretching interpolation*, melakukan estimasi terhadap seismic velocity change menggunakan MWCS analysis. Hasil dari pemantauan patahan gempa bumi dan gunung berapi adalah adanya beberapa kontribusi variabel yang dapat digunakan memprediksi gempa bumi di masa depan. Ada sebuah variasi spasial dan temporal kecepatan seismik, seperti yang terjadi pada patahan seismogenik gempa bumi Kumamoto pada tahun 2016 (*magnitudo momen Mw 7,0*) pengukuran didasarkan pada ambient seismic noise. Kecepatan seismik di samping patahan dan gunung berapi Aso menunjukkan grafik menurun, hal ini dipengaruhi oleh faktor perubahan tegangan, kerusakan formasi tanah, dan adanya peningkatan tekanan pori tanah. Selanjutnya dilakukan pemantauan berulang untuk meninjau kecepatan seismik dan memetakan proses penyembuhan patahan pasca gempa bumi.

b. Metode Deep Learning

Penelitian yang dilakukan oleh Jingyang Wang (Wang et al., 2022) meneliti tentang analisis time series menggunakan model RNN untuk melakukan prediksi. Penelitian yang dilakukan adalah studi komparatif yang membandingkan tiga metode yaitu *Recurrent Neural Network* (RNN), *Long Short-Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU). Dikatakan bahwa metode RNN merupakan jaringan syaraf tiruan yang paling independen, namun ada sebuah masalah pada pengolahan data waktu panjang (long-term data) yang menyebabkan masalah pada training data. Metode LSTM dapat menangani masalah pada pengolahan data waktu yang panjang, dan pengelolaan data yang sudah tidak relevan, namun LSTM memiliki kelemahan dengan banyaknya parameter yang digunakan sehingga menyebabkan waktu training data yang cukup lama. Metode GRU dapat melakukan reduksi terhadap waktu training yang lama dengan melakukan reduksi terhadap parameternya (Gao et al., 2020). Hasil prediksi dievaluasi menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Explained Variance Score* (EVS), *R-Squared*, dan lama waktu pelatihan model.

Berdasarkan penelitian yang dilakukan oleh Sherstinsky (Sherstinsky, 2020) memberikan penjelasan yang sangat mendasar pada RNN dan LSTM. Penelitian tersebut menjelaskan bahwa dalam proses training data RNN memiliki masalah yang cukup rumit pada gradien yang hilang dan gradien yang meledak ketika menggunakan data dengan dependensi jauh atau panjang. Masalah ini berakibat pada training data pada RNN berstandar Windows yang mencakup data yang besar dengan menggunakan Gradient Descent terhambat oleh gradien yang hilang dan meledak. Solusi yang dapat dilakukan adalah menggunakan arsitektur LSTM. LSTM merupakan arsitektur yang kompleks dapat meredam masalah pada gradien RNN.

Penelitian yang dilakukan oleh Pramita Sree Muhuri (Muhuri et al., 2020) tentang penggunaan Long Short-Term Memory dan Recurrent Neural Network untuk mengklasifikasikan serangan jaringan. Penggunaan metode deep learning dapat dilakukan menggunakan beberapa algoritma yaitu *Deep Neural Network* (DNN), *Recurrent Neural Network* (RNN), *Convolutional Neural Network* (CNN), *Deep Belief Network* (DBN), dan *Long Short-Term Memory* (LSTM). Namun dari sekian algoritma deep learning dan algoritma machine learning yang ada kombinasi LSTM-RNN merupakan salah algoritma yang dapat memberikan performa yang sangat baik pada model bahkan lebih baik daripada SVM, K-NN, Naïve Bayes, Probabilistic Neural Network (PNN), dan beberapa model jaringan saraf lainnya. RNN bekerja dengan mengirimkan sinyal dari neuron ke neuron yang saling terhubung. RNN memiliki tiga layer yaitu input layer, hidden layer, dan output layer dimana hidden layer merupakan layer yang digunakan untuk melakukan perhitungan dan pembobotan untuk menghasilkan sebuah output. RNN menggunakan gradient-based learning untuk mempelajari runtunan waktu dengan menggunakan back-propagation through time (BPTT) dan real-time recurrent learning (RTRL). RNN dapat digunakan untuk supervised classification learning, namun RNN cukup sulit dalam proses pelatihan data karena gradien yang dipakai bisa menghilang dan meledak. Masalah pada RNN dapat diselesaikan dengan mengkombinasikan dengan LSTM, algoritma ini dapat mengganti pemrosesan data pada hidden layer dengan sebuah

memory blocks, hal ini dapat mengurangi potensi kehilangan gradien saat proses pelatihan. LSTM juga memiliki sebuah gerbang yang dapat mengatur keluar masuk proses yang bekerja dengan gerbang masuk dan gerbang keluar.

Penelitian Tolga Ergen (Ergen & Kozat, 2018) memberikan pernyataan tentang modifikasi LSTM untuk efektivitas model. RNN merupakan algoritma yang memiliki kompleksitas yang tinggi dengan menggunakan *Stochastic Gradient Descent* (SGD) adalah pilihan tepat untuk menghindari kehilangan gradien yang banyak dan juga dapat ditangani dengan menggunakan LSTM yang dapat menangani masalah long-term memory. Namun dengan menerapkan LSTM pemrosesan data akan membutuhkan waktu yang cukup lama. Penelitian ini menggunakan non linier regresi dan vektor regresi yang dapat membuat performa LSTM lebih meningkat. LSTM-based online algorithms menggunakan algoritma *Stochastic Gradient Descent* (SGD), *Extended Kalman Filter* (EKF) dan *Particle Filter* (PF) sebagai metode pelatihan (training). Algoritma pendukung EKF dengan nilai 0,03590 dan PF dengan nilai 0,03824 memiliki durasi waktu yang lebih baik daripada SGD dengan nilai 0,03708, karena bermasalah pada gradiennya.

Penelitian yang dilakukan oleh Sergiu Cosmin Nistor (Nistor et al., 2021) menerapkan RNN pada sentiment analysis. Penelitian ini menggunakan teks yang sudah dilakukan tokenization sebagai data yang sekuensial dan outputnya adalah sebuah penilaian sentimen terhadap barisan kata pada suatu kalimat. *Backpropagation* digunakan pada RNN, setiap layernya merupakan learnable parameters. RNN selalu bermasalah pada gradiennya, LSTM dan GRU bisa digunakan untuk mengatasinya. Algoritma RNN dengan menambahkan LSTM menghasilkan akurasi yang baik sebesar 80,39% sedangkan GRU menghasilkan nilai sebesar 80,74%.

Penelitian yang dikemukakan oleh Muhammad Fakhrillah Abdul Azis (Azis et al., 2020) menyatakan bahwa efektivitas penggunaan supervised learning methods Regresi linier dan RNN cukup baik untuk mengolah data time series. Regresi linier digunakan untuk menentukan nilai terbaik pada data points sedangkan RNN merupakan algoritma yang cukup baik untuk model sekuensial, dengan tambahan LSTM model. Model evaluasi menggunakan R-Square. Model LSTM bekerja lebih baik daripada regresi linier, LSTM menghasilkan nilai -0,04, -0,03, 0,15 sedangkan regresi linier menghasilkan nilai 0,08, 0,16, 0,02. Namun regresi linier bekerja lebih baik dalam pengelolaan dan penyimpanan memori, memori yang disimpan jauh lebih kecil dibandingkan dengan model LSTM.

Penelitian yang dilakukan oleh Sultan Lok (Lok & Karabatak, 2021) memberikan penjelasan tentang penggunaan *Artificial Neural Network* (ANN) yang digunakan untuk mengenali pola data dan melakukan prediksi terhadap data gempa bumi. ANN memiliki banyak neuron yang saling terhubung di dalamnya, yang terdiri dari *Input Layer*, *Hidden Layer* dan *Output Layer*. Kemudian model ANN digunakan untuk training data, validation data, dan testing data. Setelah dilakukan processing data, maka model akan dievaluasi menggunakan matriks *Mean Squared Error* dan *R Values*. Hasil evaluasi model menunjukkan angka kesalahan pada rentang -2 sampai dengan 2. Dilihat dari rentang evaluasi model maka tingkat kesalahan model sangat kecil.

Kemudian dari penelitian-penelitian sebelumnya tersebut dilakukan perbandingan terhadap penggunaan metode penelitian, objek penelitian dan jenis penelitiannya, data tersebut ditampilkan pada Tabel 1. Penelitian ini menghasilkan sebuah kajian literatur yang membandingkan beberapa sumber literatur yang relevan, analisis time series dapat dilakukan menggunakan beberapa metode penelitian, baik metode konvensional maupun menggunakan metode *deep learning*.

Tabel 1. Perbandingan Penelitian

No	Penulis Penelitian	Metode Penelitian	Objek Penelitian	Hasil Penelitian	Saran Penelitian
1	Susilo (Susilo et al., 2017)	<i>co-seismic deformation</i> dan <i>continous GPS (cGPS)</i> .	Spasial seismik di Indonesia.	Hasil dari penelitian ini adalah menghitung deformasi <i>co-seismic</i> memakai pemodelan gempa & koordinat deret ketika GPS. Hasil penelitian menampakkan bahwa daerah Indonesia sudah mengalami deformasi <i>co-seismic</i> > 1 mm, dalam	Pemodelan gempa bumi di daerah Nias tahun 2005 dan gempa bumi di Sumatera Selatan tahun 2007 perlu ditingkatkan untuk menerima keluaran yang lebih baik apabila harus dibandingkan menggunakan deformasi <i>co-seismic</i> menurut koordinat deret ketika GPS.

No	Penulis Penelitian	Metode Penelitian	Objek Penelitian	Hasil Penelitian	Saran Penelitian
2	Min Lin (Lin et al., 2020)	<i>cross-correlation analysis</i> (DCCA) dan <i>temporal evolution of detrended cross-correlation analysis</i> (TDCCA).	California dan Sumatera dari tahun 1990-2013.	gempa Sumatera Andaman 2004 & gempa pantai barat Sumatera Utara tahun 2012 mendominasi bidang deformasi. Penelitian ini menggunakan metode DCCA dan TDCCA untuk menyelidiki korelasi silang dari intrusi seri data seismik temporal dan spasial di wilayah California dan Sumatera selama 23 tahun terakhir. Dengan menggunakan metode ini, kami menemukan korelasi silang dari dua deret waktu non-stasioner pada berbagai skala dan juga mengamati tanda variasi korelasi dari waktu ke waktu. Ditemukan bahwa statistik korelasi silang (m) dari uji QCC IET dan IED lebih besar dari nilai kritis 2 (m) pada tingkat signifikansi 5%, menunjukkan korelasi silang jarak jauh antara urutan ini.	Korelasi silang yang kuat antara sekuens multi-skala dengan ukuran jendela yang berbeda diamati pada periode pasca gempa. Namun, ada korelasi silang yang lemah atau tidak ada sebelum dan sesudah periode, sehingga perlu adanya perbaikan pada sistem ini untuk memeriksa lebih lanjut untuk nilai korelasi silang yang terjadi.
3	Hiro Nimiya (Nimiya et al., 2017)	<i>generic mapping tools</i> , <i>cross-correlations</i> , <i>stretching interpolation</i> , <i>MWCS analysis</i> .	Spasial seismik di Jepang.	Penelitian ini melakukan pengamatan pada <i>earthquake faults and volcanoes</i> yang terjadi di Jepang, menggunakan sebuah pemetaan data <i>generic mapping tools</i> , melakukan perhitungan matematis terhadap data harian dengan <i>cross-correlations</i> , membuat estimasi terhadap <i>seismic velocity change</i> menggunakan metode <i>stretching interpolation</i> , membuat estimasi terhadap <i>seismic velocity change</i> menggunakan metode <i>MWCS analysis</i> . Hasil akhir dari pemantauan patahan gempa bumi dan gunung berapi adalah adanya beberapa kontribusi variabel yang dapat digunakan memprediksi gempa bumi di masa depan.	Saran pengembangan penelitian selanjutnya adalah memberikan hasil evaluasi akhir menggunakan beberapa metode evaluasi metrik untuk mengetahui tingkat <i>error</i> dari data yang diolah, kemudian menggunakan metode <i>deep learning</i> untuk mengolah data agar bisa didapatkan sebuah model yang mampu mengenali data.
4	Jingyang Wang (Wang et al., 2022)	<i>Recurrent Neural Network</i> (RNN), <i>Long Short-Term Memory</i> (LSTM), dan <i>Gate Recurrent Unit</i> (GRU).	Kualitas udara.	Melalui penelitian tentang RNN, LSTM, GRU dan prediksi deret waktu, penelitian ini lebih untuk sebuah metode yang baru yaitu mengusulkan unit kontrol gerbang baru. Proposal NGCU terutama digunakan untuk peramalan data deret waktu. Dibandingkan dengan RNN tradisional, NGCU sangat mengurangi kehilangan gradien dan masalah <i>burst</i>	Penelitian ini ditemukan di dalamnya bahwa prediksi NGCU pada nilai fitur yang relevan masih dapat mempertahankan tingkat akurasi prediksi yang tinggi untuk berbagai data deret waktu. Namun, akurasi prediksi NGCU nilai ekstrim belum ditingkatkan secara efektif. Penyempurnaan penelitian selanjutnya akan terus mencari cara untuk meningkatkan akurasi

No	Penulis Penelitian	Metode Penelitian	Objek Penelitian	Hasil Penelitian	Saran Penelitian
5	Shertinsky (Sherstinsky, 2020)	<i>Recurrent Neural Network (RNN), dan Long Short-Term Memory (LSTM).</i>	Teori dasar RNN dan LSTM.	yang disebabkan oleh ketergantungan data jangka panjang. Penelitian ini mempresentasikan dasar-dasar RNN dan jaringan LSTM memakai pendekatan berprinsip. Dimulai menggunakan persamaan diferensial, menerima formulasi RNN baku menggunakan menentukan parameter RNN kanonik, pembukaan RNN pada kerangka pendekatan sistem IIR menggunakan contoh FIR, mempresentasikan <i>training</i> RNN baku memakai <i>Back Propagation Through Time</i> , melihat ulang gradien meledak terkait menggunakan <i>training</i> RNN baku <i>Gradient Descent</i> , dan selanjutnya membahas kekurangan menurut RNN baku menggunakan mengganti sistem RNN kanonik sebagai LSTM yang lebih bertenaga jaringan melalui serangkaian perluasan dan hiasan.	prediksi model untuk nilai ekstrim. Rekomendasi untuk penyempurnaan penelitian di masa depan adalah menerapkan LSTM berbasis sistem di lingkungan komputasi berkinerja tinggi dan membandingkan efektivitasnya dalam beberapa skenario praktis. Menguji dan menerapkan juga RNN sebagai perbandingan untuk LSTM.
6	Pramita Sree Muhuri (Muhuri et al., 2020)	<i>Recurrent Neural Network (RNN), dan Long Short-Term Memory (LSTM).</i>	NSL-KDD (<i>Network Security Layer-Knowledge Discovery in Database</i>).	Penelitian ini membandingkan pengklasifikasi berbeda pada <i>dataset</i> NSL-KDD untuk biner dan klasifikasi multi-kelas. Membandingkan SVM, <i>random forest</i> , dan model LSTM-RNN. Hasil menunjukkan LSTM-RNN memperoleh akurasi lebih tinggi daripada SVM dalam klasifikasi biner. Jika dibandingkan dengan SVM dan <i>random forest</i> , LSTM-RNN melakukan yang terbaik dalam eksperimen klasifikasi multikelas. Akhirnya, dapat disimpulkan bahwa LSTM-RNN cocok untuk kumpulan data besar. Dengan kumpulan data kecil yang memiliki sedikit fitur, kinerjanya dari LSTM-RNN tidak terlalu terlihat. Namun, ditingkatkan dengan GA, kinerja LSTM-RNN relatif lebih baik daripada pendekatan pembelajaran mesin tradisional.	Rekomendasi untuk penelitian selanjutnya adalah menjalankan eksperimen pada sistem berbasis GPU untuk mempercepat waktu pada saat pelatihan data. Pekerjaan lebih lanjut di masa depan harus mencakup validasi efisiensi model LSTM-RNN menggunakan <i>dataset modern</i> lainnya seperti UNSW-NB15.
7	Tolga Ergen (Ergen & Kozat, 2018)	<i>Long Short-Term Memory (LSTM).</i>	Kinematik dan <i>stock price</i> .	Penelitian ini menyelidiki masalah regresi non-linier dalam lingkungan <i>online learning</i> dan menyajikan algoritma <i>online learning</i> berbasis LSTM baru untuk regresi data. Selanjutnya, disajikan metode pelatihan	Pengembangan selanjutnya adalah menggunakan algoritma <i>online learning</i> ini pada data yang lebih kompleks. Menguji penggunaan efektivitas LSTM pada <i>online learning</i> sehingga algoritma ini teruji.

No	Penulis Penelitian	Metode Penelitian	Objek Penelitian	Hasil Penelitian	Saran Penelitian
				<p><i>online learning</i> dengan kompleksitas rendah dan efektif untuk algoritme ini. Untuk mencapai ini, pertama-tama diusulkan algoritma regresi baru untuk menghitung perkiraan akhir dan memperkenalkan gerbang tambahan ke arsitektur LSTM tradisional. Kemudian menempatkan sistem LSTM dalam bentuk <i>state-space</i> dan, berdasarkan formulir ini, mendapatkan pembaruan <i>online</i> berdasarkan algoritma SGD, EKF, dan PF untuk melatih arsitektur LSTM. Penelitian ini memperkenalkan pendekatan berbasis arsitektur GRU dengan langsung mengganti persamaan LSTM dengan arsitektur GRU. Kami menemukan bahwa pendekatan berbasis LSTM mengungguli pendekatan berbasis GRU pada tugas prediksi berurutan. Selanjutnya, ditunjukkan bahwa algoritma yang diperkenalkan menghasilkan peningkatan kinerja yang signifikan dibandingkan metode konvensional.</p>	Diharapkan pada penelitian selanjutnya metode ini dapat digunakan secara meluas karena efektivitas dan efisiensinya.
8	Sergiu Cosmin Nistor (Nistor et al., 2021)	<i>Recurrent Neural Network (RNN)</i>	Sentimen <i>tweets</i> .	<p>Twitter adalah salah satu jejaring sosial paling populer dan sumber data yang bagus untuk penggalian opini. Analisis sentimen <i>tweet</i> mirip dengan analisis teks pada umumnya, tetapi keterbatasan khusus masalah memberikan peluang untuk menemukan solusi baru dan kreatif untuk bentuk penulisan khusus ini. Banyak solusi telah diusulkan karena penerapannya yang tinggi untuk mengekstraksi emosi dari <i>tweet</i>. Analisis sentimen dengan metode <i>tweet</i>. Dijelaskan komponen yang digunakan dan mempresentasikan hasil percobaan. Disimpulkan bahwa <i>preprocessing</i> yang optimal adalah menggunakan vektor <i>one-hot encoding</i>. Ditemukan bahwa hasilnya tidak berbeda secara signifikan saat menggunakan dua sel memori yang paling umum, LSTM atau GRU.</p>	Untuk studi masa depan mengurangi bias pada saat melakukan pengolahan data, pengolahan teks rentan terhadap bias. Menggunakan RNN, LSTM, dan GRU untuk meningkatkan desain sel memori yang digunakan, sehingga diharapkan mampu mengekstrak sentimen dengan lebih baik. Namun demikian, menggunakan dataset menjadi sebuah korpus untuk analisis sentimen, pekerjaan ini menghasilkan desain eksperimental yang jelas, menetapkan tolak ukur baru untuk perkembangan pengolahan teks di masa depan.

No	Penulis Penelitian	Metode Penelitian	Objek Penelitian	Hasil Penelitian	Saran Penelitian
9	Muhammad Fakhriillah Abdul Aziz (Azis et al., 2020)	<i>Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), dan Linear Regression.</i>	<i>Significant earthquake dataset.</i>	Pendekatan analisis deret waktu untuk data seismik yang terdiri dari dua langkah: eksplorasi dan prediksi. Eksplorasi data dengan membuat visualisasi menggunakan plot peta dan grafik garis. Misalnya, memberikan pengetahuan tentang distribusi gempa bumi pada antarmuka batas lempeng dan perjalanan gempa dari waktu ke waktu. Untuk langkah prediksi, dengan membandingkan kinerja model prediksi dalam hal data normal dengan data stasioner dan teknik pemodelan menggunakan LSTM, regresi linier, dan RNN. Model prediktif menghasilkan hasil kinerja yang sangat berbeda tergantung pada struktur kualitas tanah dan waktu.	Studi masa depan didorong untuk menggunakan teknik pemodelan deret waktu lainnya, seperti ARIMA, menggunakan unit waktu yang lebih halus untuk peramalan, dan memasukkan aspek geologi tertentu ke dalam eksplorasi, prediksi dan peramalan.
10	Sultan Lok (Lok & Karabatak, 2021)	<i>Artificial Neural Network (ANN).</i>	<i>World earthquakes.</i>	Metode penambangan data telah banyak dikembangkan karena kebutuhan untuk mendapatkan menggali informasi di dalamnya. Metode tersebut meliputi metode pengelompokan, klasifikasi, asosiasi, dan deret waktu. Penelitian ini menggunakan analisis deret waktu untuk memberikan prediksi tentang waktu yang akan datang terhadap suatu kasus berdasarkan data waktu. Deret waktu dibagi menjadi dua yaitu metode linier dan non-linier. Metode deret waktu linier memperkirakan data melakukan asumsi deret tersebut stasioner. Metode deret waktu non-linier memprediksi suatu data berdasarkan data mentah dari deret waktu di dunia nyata. Penelitian ini menggunakan <i>Artificial Neural Network (ANN)</i> , salah satu metode non-linier dari analisis deret waktu. Data yang dipakai adalah data gempa, untuk melakukan estimasi data.	Rekomendasi penelitian di masa depan adalah melakukan evaluasi terhadap penggunaan <i>Artificial Neural Network (ANN)</i> agar model tersebut dapat dipakai dan dimodifikasi oleh peneliti lain, kemudian melakukan komparasi terhadap metode yang dipakai untuk melakukan prediksi terhadap data gempa bumi.

Hasil penelusuran terhadap penelitian-penelitian sebelumnya pada Tabel 1 didapatkan beberapa metode yang dapat digunakan untuk mengolah data *time series* yaitu metode konvensional dan metode *deep learning*. Untuk contoh metode konvensional adalah menggunakan metode *co-seismic deformation*, *continuous GPS (cGPS)*, *cross-correlation*, *stretching interpolation*, dan *MWCS analysis*. Sedangkan untuk contoh metode *deep learning* yaitu *Recurrent Neural Network (RNN)*, *Long Short-Term Memory (LSTM)*, dan *Gate Recurrent Unit (GRU)*, dan *Artificial Neural Network (ANN)*, masing-masing memiliki tingkat efektivitas yang relatif tergantung pada kompleksitas dari data yang digunakan dalam penelitian tersebut. Penggunaan data juga memiliki beberapa variasi dalam hal ini adalah data spasial seismik di Indonesia, data California dan Sumatera dari tahun 1990-2013, data spasial seismik di Jepang, data kualitas udara, NSL-KDD

(*Network Security Layer-Knowledge Discovery in Database*), kinematik dan *stock price*, *Significant earthquake dataset*, dan *World earthquakes*. Algoritma *deep learning* dengan RNN dengan *LSTM Layer* merupakan kombinasi yang baik untuk melakukan analisis *time series* pada data spasial seismik sehingga dapat meningkatkan performa dan akurasi model *deep learning* maupun *machine learning* dalam melakukan peramalan data spasial seismik di Indonesia, dengan data peramalan tersebut diharapkan dapat menjadi acuan untuk meningkatkan tingkat kewaspadaan masyarakat dalam mengantisipasi bencana alam seismik.

KESIMPULAN

Penelitian ini merangkum metode-metode yang sering digunakan untuk melakukan pengolahan *deep learning* maupun pengolahan data spasial seismik. Penelitian ini menggunakan metode *literature review* dengan mengumpulkan beberapa literatur yang relevan dengan rentang tahun 10 tahun terakhir. Adanya penelitian ini ditujukan untuk menangkap dan menganalisa *research gap*, *tren*, *state of the art*, tantangan penelitian, dan pengembangan model atau metode baru pada masing-masing literatur yang bertujuan untuk menemukan metode ataupun algoritma yang paling tepat untuk digunakan sebagai sumber pustaka dalam melakukan peramalan data menggunakan data *time series*. Hasil studi ditemukan beberapa kelompok metode penelitian yang dapat digunakan untuk mengolah data *time series* yaitu metode konvensional dan metode *deep learning*. Beberapa metode yang tergolong dalam metode konvensional yaitu *co-seismic deformation*, *continuous GPS (cGPS)*, *cross-correlation*, *stretching interpolation*, dan *MWCS analysis*. Sedangkan metode yang tergolong dalam metode *deep learning* yaitu *Recurrent Neural Network (RNN)*, *Long Short-Term Memory (LSTM)*, *Gate Recurrent Unit (GRU)*, *linear regression*, dan *Artificial Neural Network (ANN)*. Metode *deep learning* dari beberapa penelitian dapat memberikan kinerja akurasi yang baik untuk mengolah data spasial seismik maupun mengolah data kompleks yang lainnya. Perbedaan antara metode konvensional dengan *deep learning* adalah pada penggunaan waktu dalam melakukan proses pengolahan data. Selain itu, metode konvensional cenderung membutuhkan waktu yang lebih lama daripada metode *deep learning*, sehingga saran untuk penelitian selanjutnya dapat memanfaatkan beberapa metode *deep learning* untuk melakukan prediksi data spasial seismik.

DAFTAR PUSTAKA

- Aigner, W., Miksch, S., Schumann, H., & Tominski, C. (2011). Visualization of Time-Oriented Data. In *Human-Computer Interaction*.
- Al'afi, A. M., Widiart, W., Kurniasari, D., & Usman, M. (2020). Peramalan Data Time Series Seasonal Menggunakan Metode Analisis Spektral. *Jurnal Siger Matematika*. <https://doi.org/10.23960/jsm.v1i1.2484>
- Alif, S. M., Meilano, I., Gunawan, E., & Efendi, J. (2016). Evidence of Postseismic Deformation Signal of the 2007 M8.5 Bengkulu Earthquake and the 2012 M8.6 Indian Ocean Earthquake in Southern Sumatra, Indonesia, Based on GPS Data. *Journal of Applied Geodesy*. <https://doi.org/10.1515/jag-2015-0019>
- Alqahtani, A., Ali, M., Xie, X., & Jones, M. W. (2021). Deep time-series clustering: A review. In *Electronics (Switzerland)*. <https://doi.org/10.3390/electronics10233001>
- Alqahtani, A., Xie, X., Deng, J., & Jones, M. W. (2018). A Deep Convolutional Auto-Encoder with Embedded Clustering. *Proceedings - International Conference on Image Processing, ICIP*. <https://doi.org/10.1109/ICIP.2018.8451506>
- Anugrah, B., Meilano, I., Gunawan, E., & Efendi, J. (2015). Estimation of postseismic deformation parameters from continuous GPS data in northern Sumatra after the 2004 Sumatra-Andaman earthquake. *Earthquake Science*. <https://doi.org/10.1007/s11589-015-0136-x>
- Ardika, M., Meilano, I., & Gunawan, E. (2015). Postseismic deformation parameters of the 2010 M7.8 Mentawai, Indonesia, earthquake inferred from continuous GPS observations. *Asian Journal of Earth Sciences*. <https://doi.org/10.3923/ajes.2015.127.133>
- Azis, M. F. A., Darari, F., & Septyandy, M. R. (2020). Time series analysis on earthquakes using EDA and machine learning. 2020 *International Conference on Advanced Computer Science and Information Systems, ICACSIS 2020*. <https://doi.org/10.1109/ICACSIS51025.2020.9263188>
- Brilliantina, M. V., Pratiwi, H., & Susanti, Y. (2021). Analisis Seismisitas pada Data Gempa Bumi di Provinsi Maluku Utara Penerapan Model Epidemic Type Aftershock Sequence (ETAS). *Prosiding Pendidikan Matematika Dan Matematika*.

- Cho, M., Kim, B., Bae, H. J., & Seo, J. (2014). *Stroscope: Multi-scale visualization of irregularly measured time-series data*. *IEEE Transactions on Visualization and Computer Graphics*. <https://doi.org/10.1109/TVCG.2013.2297933>
- Daryono, Brotopuspito, K. S., & Sutikno. (2018). Hubungan antara Indeks Kerentanan Seismik dan Rasio Kerusakan pada Satuan Bentuklahan di Zona Graben Bantul Yogyakarta. *Proceeding Seminar Nasional Kebumihan Ke-11: Perspektif Ilmu Kebumihan Dalam Kajian Bencana Geologi Di Indonesia*.
- Ergen, T., & Kozat, S. S. (2018). Efficient online learning algorithms based on LSTM neural networks. *IEEE Transactions on Neural Networks and Learning Systems*. <https://doi.org/10.1109/TNNLS.2017.2741598>
- Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., & Lin, Q. (2020). Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2020.125188>
- Gunawan, E., Ghosalba, F., Syaqui, Widiastomo, Y., Meilano, I., Hanifa, N. R., Daryono, & Hidayati, S. (2017). Field Investigation of the November to December 2015 Earthquake Swarm in West Halmahera, Indonesia. *Geotechnical and Geological Engineering*. <https://doi.org/10.1007/s10706-016-0117-4>
- Gunawan, E., Sagiya, T., Ito, T., Kimata, F., Tabei, T., Ohta, Y., Meilano, I., Abidin, H. Z., Agustan, Nurdin, I., & Sugiyanto, D. (2014). A comprehensive model of postseismic deformation of the 2004 Sumatra-Andaman earthquake deduced from GPS observations in northern Sumatra. *Journal of Asian Earth Sciences*. <https://doi.org/10.1016/j.jseaes.2014.03.016>
- Habsy, B. A. (2017). Seni Memahami Penelitian Kuliitatif Dalam Bimbingan Dan Konseling : Studi Literatur. *JURKAM: Jurnal Konseling Andi Matappa*. <https://doi.org/10.31100/jurkam.v1i2.56>
- Hotz, I., & Peikert, R. (2014). Definition of a multifield. *Mathematics and Visualization*. https://doi.org/10.1007/978-1-4471-6497-5_10
- Ito, T., Gunawan, E., Kimata, F., Tabei, T., Simons, M., Meilano, I., Agustan, N., Ohta, Y., Nurdin, I., & Sugiyanto, D. (2012). Isolating along-strike variations in the depth extent of shallow creep and fault locking on the northern Great Sumatran Fault. *Journal of Geophysical Research: Solid Earth*. <https://doi.org/10.1029/2011JB008940>
- Latifiana, K. (2019). Pemetaan Habitat Potensial Herpetofauna Pada Daerah Terdampak Erupsi Gunung Merapi 2010. *Seminar Nasional Geomatika*. <https://doi.org/10.24895/sng.2018.3-0.1002>
- Lin, M., Qin, J., & Wang, G. (2020). Multi-scale cross-correlation analysis of temporal and spatial seismic data. *European Physical Journal B*. <https://doi.org/10.1140/epjb/e2020-100536-5>
- Lok, S., & Karabatak, M. (2021). Earthquake Prediction by Using Time Series Analysis. 9th *International Symposium on Digital Forensics and Security*, ISDFS 2021. <https://doi.org/10.1109/ISDFS52919.2021.9486358>
- Muhuri, P. S., Chatterjee, P., Yuan, X., Roy, K., & Esterline, A. (2020). Using a long short-term memory recurrent neural network (LSTM-RNN) to classify network attacks. *Information (Switzerland)*. <https://doi.org/10.3390/INFO11050243>
- Nimiya, H., Ikeda, T., & Tsuji, T. (2017). Spatial and temporal seismic velocity changes on Kyushu Island during the 2016 Kumamoto earthquake. *Science Advances*. <https://doi.org/10.1126/sciadv.1700813>
- Nistor, S. C., Moca, M., Moldovan, D., Oprean, D. B., & Nistor, R. L. (2021). Building a Twitter sentiment analysis system with recurrent neural networks. *Sensors*. <https://doi.org/10.3390/s21072266>
- Pollitz, F. F. (1996). Coseismic deformation from earthquake faulting on a layered spherical earth. *Geophysical Journal International*. <https://doi.org/10.1111/j.1365-246X.1996.tb06530.x>
- Rizaty, M. A. (2022). 10.519 Gempa Bumi Guncang Indonesia Sepanjang 2021. *Databoks*. <https://databoks.katadata.co.id/datapublish/2022/06/20/10519-gempa-bumi-guncang-indonesia-sepanjang-2021#:~:text=Berdasarkan catatan Badan Pusat Statistik,Pulau Sulawesi%2C yaitu 925 kali.>
- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*. <https://doi.org/10.1016/j.physd.2019.132306>
- Susilo, Abidin, H. Z., Meilano, I., Sapiie, B., Gunawan, E., Wijarnto, A. B., & Efendi, J. (2017). Preliminary co-sesimic deformation model for Indonesia geospatial reference system 2013. *AIP Conference Proceedings*. <https://doi.org/10.1063/1.4987073>

- Thoyibah, Z., Sukma Purqoti, D. N., & Oktaviana, E. (2020). Gambaran Tingkat Kecemasan Korban Gempa Lombok. *Jurnal Persatuan Perawat Nasional Indonesia (JPPNI)*. <https://doi.org/10.32419/jppni.v4i3.190>
- Wang, J., Li, X., Li, J., Sun, Q., & Wang, H. (2022). NGCU: A New RNN Model for Time-Series Data Prediction. *Big Data Research*. <https://doi.org/10.1016/j.bdr.2021.100296>
- Zheng, Y., Liu, Q., Chen, E., Ge, Y., & Zhao, J. L. (2014). Time series classification using multi-channels deep convolutional neural networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/978-3-319-08010-9_33