

## Pembelajaran Mesin SVM terhadap Sistem Pengesanan Gempa Bumi Geofon (SVM Machine Learning Implementation on Geophone Earthquake Detection System)

Long Muhammad Haziq Long Hassan<sup>a,b</sup>, Seri Mastura Mustaza<sup>a,c</sup>, Tan Ji Loun<sup>a,b</sup>, Noor Ainayasmin Abdul Ghani<sup>a,b</sup> & Norhana Arsad<sup>a,b\*</sup>

<sup>a</sup>Fakulti Kejuruteraan & Alam Bina, Universiti Kebangsaan Malaysia, 43600 Bangi, Malaysia,

<sup>b</sup>Kumpulan Teknologi Fotonik, Jabatan Kejuruteraan Elektrik, Elektronik dan Sistem, Fakulti Kejuruteraan & Alam Bina, Universiti Kebangsaan Malaysia, UKM Bangi 43600, Malaysia

<sup>c</sup>Kumpulan Teknologi Spektrum (Spectech), Jabatan Kejuruteraan Elektrik, Elektronik dan Sistem, Fakulti Kejuruteraan & Alam Bina, Universiti Kebangsaan Malaysia, UKM Bangi 43600, Malaysia

\*Corresponding author: [noa@ukm.edu.my](mailto:noa@ukm.edu.my)

Received 10 October 2025, Received in revised form 8 January 2026  
 Accepted 8 February 2026, Available online 30 July 2026

### ABSTRAK

Gempa bumi yang berpunca dari Indonesia merupakan ancaman besar kepada Malaysia, yang boleh mengakibatkan kerosakan infrastruktur dan kehilangan nyawa. Kaedah pengesanan gempa bumi tradisional seringkali tidak mempunyai ketepatan yang mencukupi untuk amaran tepat pada masanya. Kajian ini memperkenalkan sistem pengesanan gempa bumi masa nyata yang kos efektif dengan mengintegrasikan sensor geofon dengan algoritma Support Vector Machine (SVM). Pembangunan sistem melibatkan Raspberry Pi, Geofon, ADS1115 sebagai blok binaan utama, Micromix 5 Shaker sebagai sumber getaran makmal, dan data diperoleh dianalisis menggunakan Microsoft Excel bagi pembinaan graf dan MATLAB bagi kajian data getaran menggunakan algoritma SVM. Enam jenis kernel diuji dalam latihan pembelajaran mesin bagi klasifikasi jenis-jenis getaran menggunakan SVM. Ujian makmal pengesanan getaran geofon pada lima amplitud getaran yang berbeza mendedahkan kepekaan geofon yang berbeza terhadap amplitud positif dan negatif, menunjukkan potensinya untuk sistem amaran awal. Data yang diproses dengan model SVM dalam MATLAB menggunakan matriks kekeliruan sebagai alat statistik menunjukkan bahawa kernel Quadratic dan Fine Gaussian mencapai ketepatan klasifikasi tertinggi (96%), dengan berkesan membezakan kejadian seismik daripada bunyi latar belakang. Kajian lanjutan adalah dicadangkan dengan menguji keberkesanan sistem ini di lapangan, serta integrasi pelbagai sensor dalam sistem bersepadu. Kejayaan pembangunan dan pengujian sistem ini menawarkan langkah yang menjanjikan ke arah meningkatkan kesiapsiagaan Malaysia terhadap gempa bumi melalui keupayaan amaran awal yang boleh dipercayai dan dipacu oleh pembelajaran mesin.

Kata kunci: Geofon, Pengesanan Gempa Bumi, Support Vector Machine (SVM), Pemantauan Masa Nyata

### ABSTRACT

Earthquakes originating from Indonesia pose a major threat to Malaysia, which can cause infrastructure damage and loss of life. Traditional earthquake detection methods often lack sufficient accuracy for timely warning. This study introduces a cost-effective real-time earthquake detection system by integrating geophone sensors with Support Vector Machine (SVM) algorithms. The system development involves Raspberry Pi, Geophone, ADS1115 as the main building blocks, Micromix 5 Shaker as the laboratory vibration source, and the data obtained are analysed using Microsoft Excel for graph construction and MATLAB for vibration data analysis using the SVM algorithm. Six types of kernels are tested in machine learning training for classification of vibration types using SVM. Laboratory tests of geophone vibration detection at five different vibration amplitudes reveal different sensitivity of geophones to positive and negative


*amplitudes, demonstrating their potential for early warning systems. Data processed with the SVM model in MATLAB using the confusion matrix as a statistical tool shows that the Quadratic and Fine Gaussian kernels achieve the highest classification accuracy (96%), effectively distinguishing seismic events from background noise. Further studies are suggested by testing the effectiveness of this system in the field, as well as the integration of multiple sensors in an integrated system. The successful development and testing of this system offer a promising step towards improving Malaysia's earthquake preparedness through reliable, machine learning-driven early warning capabilities.*

**Keywords:** *Geophone, Earthquake Detection, Support Vector Machine (SVM), Real-time Monitoring*

## PENGENALAN

Kejadian gempa bumi di Malaysia tidak seteruk seperti di negara lain, namun Malaysia selalu terjejas dengan gempa bumi serantau. Sebanyak 50 gempa bumi dengan magnitud lebih dari 6.0 (Mw) berlaku sekitar 1000 km dari Kuala Lumpur sejak 1973 (Tongkul 2021). Kejadian seismik ini sering berlaku di Sumatra Barat, Lautan Sulu, dan Kalimantan yang memberi kesan kepada negeri-negeri di Malaysia (Tongkul 2021).

Kehadiran gempa bumi di Borneo berkait rapat dengan pergerakan plat tektonik yang aktif seperti di Zon Garis Sesar Besar Sumatra (GSF), Zon Subduksi Cekung Sunda, Zon Subduksi Cekung Sulu, dan Palu-Koro Garis Sesar (PKF) (A et al. 2018; Natawidjaja & Triyoso 2007; Rangin et al. 1990; Shabnam 2018; Tongkul 1991). Rajah 1 menunjukkan pergerakan plat tektonik di Asia Tenggara.



RAJAH 1. Sempadan plat utama (garis kuning tebal) dan pergerakan di Asia Tenggara (Tongkul 1991)

Gempa bumi memberi kesan negatif terhadap alam sekitar, infrastruktur, dan kehidupan manusia (Ahmed et al. 2023; Mavroulis et al. 2023; Tatar et al. 2024). Kesan gempa bumi terbahagi kepada kesan utama dan kesan sampingan yang dikenali sebagai Kesan Lingkungan Gempa Bumi (EEE) (Choudhury et al., n.d.; Guerrieri et al., 2007). Kesan utama merujuk kepada akibat secara langsung dari kejadian gempa bumi seperti penurunan atau penggelaman tanah dan keretakan permukaan (Al-Taie & Ahmed 2025; Choudhury, Verma & Saha 2016; Moorthy,

Benny & Gill 2018; Samad et al. 2024; Tatevossian et al. 2009). Akibat kesan utama bergantung kepada magnitud gempa bumi dan keadaan tekanan (Choudhury, Verma & Saha 2016).

Kesan sampingan pula terjadi akibat kesan utama seperti tanah runtuh, pencairan, tsunami, dan kebakaran (Daniell, Schaefer & Wenzel 2017; Fan et al. 2019; Hill et al. 2024). Kesan sampingan memainkan peranan utama terhadap kerugian ekonomi dan kematian berbanding kesan utama (Daniell, Schaefer & Wenzel 2017; Neamah & Naser 2025).

Dalam bidang pengesanan gempa bumi, alat gempa bumi yang sedia ada, seperti akselerometer dan geofon, mempunyai kekurangan ketara dari segi liputan sensor dan sensitiviti pengesanan. Alatan pengesanan ini sering menghadapi masalah dalam membezakan antara gegaran seismik dan gangguan bunyi aktiviti harian.

Di peringkat global, sistem seperti ShakeAlert (AS) memerlukan infrastruktur mahal seperti jaringan sensor padat dan pusat data berprestasi tinggi, yang sukar dilaksanakan di Malaysia akibat kekangan bajet dan kepelbagaian geografi (Hughes et al. 2025). Sistem amaran gempa bumi sedia ada pula mungkin tidak memberikan amaran awal dengan masa pendahuluan yang mencukupi untuk membolehkan penyediaan dan tindak balas yang cekap (Allen & Melgar 2019; Cremen & Galasso 2020). Penyelesaian terbaik pada masa ini ialah membangunkan sistem pengesanan gempa bumi menggunakan pembelajaran mesin bagi mengenal pasti pola gegaran seismik secara tepat.

Perkembangan terkini dalam pembelajaran mesin (*Machine Learning*) membuka peluang untuk mereka bentuk sistem pengesanan gempa bumi yang lebih tepat, cekap, dan mudah alih. Bagi sistem amaran, dengan menggunakan pembelajaran mesin, sistem amaran dapat diperbaiki dengan meningkatkan masa memberi amaran yang efektif, dan memberi pemantauan gempa bumi secara nyata.


Selaras dengan perkembangan teknologi semasa, teknologi seperti RaspberryPi digunakan untuk meningkatkan keupayaan sistem pengesanan gempa bumi. Contohnya, projek Raspberry Shake yang berjaya mengesan frekuensi mikro (magnitud <3.0) (Hughes et al. 2025; Minson et al. 2015).

Selain itu, algoritma seperti *Support Vector Machine* (SVM) dan *Recurrent Neural Network* (RNN) menunjukkan ketepatan dalam julat 80 – 90% dalam mengklasifikasi jenis gegaran (Lee & Chan 2023; Li, Wang & Dai 2023; Muhammad & Lam 2023). Namun, integrasi kedua-dua teknologi ini dalam membangunkan sistem pengesanan dan amaran gempa bumi masih terhad.

Kajian ini bertujuan mengisi jurang sistem sedia ada dengan membangunkan sistem pengesanan gempa bumi masa nyata berasaskan pembelajaran mesin yang mengintegrasikan data Geofon dengan algoritma SVM untuk meningkatkan ketepatan dan kelajuan pengesanan gempa bumi masa nyata.


## METODOLOGI

Pembangunan sistem pengesanan gempa bumi ini melibatkan penggunaan komponen utama seperti Raspberry Pi dan geofon. Proses bermula dengan kajian literatur untuk menentukan keperluan dan spesifikasi komponen, diikuti integrasi antara Raspberry Pi dengan geofon (Rajah 2).



RAJAH 2. Blok sistem pengesanan gempa bumi menggunakan geofon

Penyusunan litar dilakukan untuk memastikan kestabilan, manakala pustaka dan pakej dipasang pada Raspberry Pi dan Arduino menggunakan Arduino IDE dan Python. Data yang dikumpul daripada penerima dipaparkan secara masa nyata atau disimpan dalam fail CSV untuk analisis (Rajah 3).




RAJAH 3. Skematik sistem pengesanan gempa bumi menggunakan geofon

Seterusnya, ujian makmal dijalankan menggunakan plat getaran ‘Micromix 5 Shaker’ untuk menilai kepekaan geofon terhadap simulasi gempa bumi dengan amplitud 0 hingga 8, seperti ditunjukkan dalam Rajah 4.



RAJAH 4. Pengujian prototaip geofon

Data seismik diproses menggunakan MATLAB dengan algoritma SVM untuk pengkelasan data, seperti ditunjukkan dalam Rajah 5. Klasifikasi data seismik dilakukan melalui beberapa peringkat bermula dengan penyediaan data daripada sumber Geofon dan simulasi makmal menggunakan plat getaran Micromix 5 Shaker. Data mentah diproses dengan penapisan jalur (0.1–20 Hz) untuk mengasingkan frekuensi seismik dan normalisasi amplitud kepada julat  $[-1, 1]$  bagi memastikan konsistensi input. Ciri-ciri penting seperti RMS, amplitud puncak, dan komponen frekuensi dominan (melalui FFT) diekstrak daripada isyarat seismik untuk dijadikan input kepada model SVM.



RAJAH 5. Carta alir klasifikasi data menggunakan MATLAB

Bagi setiap tahap amplitud getaran (0, 2, 4, 6, dan 8) sebanyak 29,097 titik data mentah direkodkan. Perincian bagi setiap kelas amplitud dan jumlah titik data mentah yang direkodkan ditunjukkan dalam Jadual 1. Untuk fasa pembelajaran mesin, data mentah ini kemudiannya dibahagikan kepada 167 sampel fitur secara keseluruhan dan dibahagikan kepada set latihan dan ujian seperti yang diringkaskan dalam Jadual 2. Kelas 1 hingga 5 masing-masing mewakili amplitud 0, 2, 4, 6, dan 8.

JADUAL 1. Perincian Bilangan Sampel Data Mengikut Kelas

| Kelas SVM | Amplitud Getaran | Titik Data Mentah |
|-----------|------------------|-------------------|
| 1         | 0                | 29,097            |
| 2         | 2                | 29,097            |
| 3         | 4                | 29,097            |
| 4         | 6                | 29,097            |
| 5         | 8                | 29,097            |
| JUMLAH    | -                | 145,485           |

JADUAL 2. Pembahagian Sampel Data Latihan dan Ujian

| Kelas SVM | Latihan (70%) | Ujian (30%) | Jumlah Sampel |
|-----------|---------------|-------------|---------------|
| 1         | 23            | 10          | 33            |
| 2         | 23            | 10          | 33            |
| 3         | 24            | 10          | 34            |
| 4         | 24            | 10          | 34            |
| 5         | 23            | 10          | 33            |
| JUMLAH    | 117           | 50          | 167           |

Seterusnya, pemprosesan dataset dibahagikan secara rawak kepada dua kumpulan utama menggunakan nisbah 70:30. Daripada keseluruhan data, sebanyak 70% digunakan sebagai data latihan supaya algoritma SVM dapat mempelajari corak isyarat dan sempadan keputusan bagi setiap kelas getaran. Manakala, data ujian pula menggunakan sebanyak 30% dari data keseluruhan untuk menilai prestasi akhir model pada data yang belum pernah dilihat sebelumnya bagi memastikan objektif klasifikasi yang tepat.

Enam jenis fungsi kernel (Linear, Quadratic, Cubic, Fine Gaussian, Medium Gaussian, Coarse Gaussian) diuji bersama parameter regularisasi dan hiperparameter lain menggunakan MATLAB, dengan kernel Gaussian dipilih kerana keupayaannya mengklasifikasi data tidak linear. Model dilatih melalui pengesanan silang “5-fold” bagi mengelakkan terlebih muat (overfitting). Dalam proses “5-fold” ini, data latihan dibahagikan kepada lima sub-set yang sama saiz, di mana model dilatih sebanyak lima kali dengan setiap sub-set digunakan sebagai data pengesanan (validation) secara bergilir-gilir.


Kemudian, prestasi model dinilai menggunakan metrik prestasi iaitu ketepatan (accuracy), ketelitian

(precision), capaian (recall), dan skor-F1 (F1-score). Ketiga – tiga kriteria prestasi model ditetapkan berdasarkan ambang ketepatan melebihi 85%. Hanya model terlatih yang mencapai ketepatan melebihi 85% kemudiannya dieksport dalam format .mat untuk disepadukan dengan sistem Raspberry Pi, membolehkan pengesanan gempa bumi masa nyata berasaskan ciri seismik yang dipelajari.

## DAPATAN KAJIAN


### UJIAN MAKMAL BAGI PERANTI PENGESANAN GEOFON

Rajah 6 dan 7 masing-masing menunjukkan keputusan ujian yang dijalankan pada amplitud 0 yang mewakili kekuatan getaran paling minimum dan keputusan pada amplitud 8 yang mewakili getaran paling maksimum.



RAJAH 6. Data mentah yang dikumpulkan dan jadual penjelasan bagi amplitud 0


Pada amplitud 0, data mentah geofon yang dikumpulkan selama lima minit menunjukkan sejumlah 29,097 data. Dari data tersebut, histogram menunjukkan nilai min (purata) sebesar 0.1660 mV dengan varians 88.608 (mV)<sup>2</sup> dan sisihan piawai 9.413 mV. Nilai maksimum yang dicatat ialah 79 mV manakala nilai minimum ialah -74 mV, menghasilkan julat data antara maksimum dan minimum ialah 153 mV.



RAJAH 7. Data mentah yang dikumpulkan dan jadual penjelasan bagi amplitud 8

Pada amplitud 8 seperti yang ditunjukkan di Rajah 5, data mentah yang dikumpulkan juga menunjukkan sejumlah 29,097 data. Histogram menunjukkan nilai min (purata) sebesar -16.764 mV dengan varians 12,216,343.82 (mV)<sup>2</sup> dan sisihan piawai 3,495.189 mV. Nilai maksimum yang dicatat ialah 17,769 mV manakala nilai minimum ialah -27,048 mV, menghasilkan julat data antara maksimum dan minimum ialah 44,817 mV.

Rajah 8 menunjukkan plot kotak bagi setiap tahap amplitud memberikan ringkasan grafik mengenai taburan nilai geofon dari amplitud 0 hingga 8. Pada amplitud 0, nilai geofon menunjukkan nilai julat yang agak rendah dengan median yang hampir kepada sifar dan julat antara kuartil (IQR) yang kecil, menandakan kebolehubahan yang terhad dalam data. Walaupun begitu, terdapat beberapa pencilon dalam julat dari -20,000 hingga 20,000 mV.



RAJAH 8. Plot kotak bagi setiap tahap kekuatan

Apabila amplitud meningkat kepada 8, nilai median geofon juga meningkat dengan IQR yang lebih luas. Ini menunjukkan kebolehubahan yang lebih besar dalam bacaan geofon pada tahap amplitud ini. Kehadiran banyak pencilon pada tahap amplitud yang lebih tinggi menandakan bahawa nilai geofon cenderung kepada turun dan naik yang melampau, mungkin disebabkan oleh kepekaan geofon yang meningkat kepada intensiti getaran yang lebih tinggi. Secara keseluruhannya, plot kotak ini menggambarkan bahawa apabila tahap amplitud meningkat, nilai median geofon cenderung untuk meningkat, dan kebolehubahan dalam bacaan juga meningkat.

## PEMBELAJARAN MESIN BAGI KLASIFIKASI JENIS-JENIS GETARAN MENGGUNAKAN SVM

Rajah 9 menunjukkan prestasi ketepatan pengelasan untuk pelbagai jenis fitur Mesin Vektor Sokongan (SVM) yang digunakan pada set data penerima geofon untuk mengesan gempa bumi. Fitur Quadratic SVM (2.2) dan Fine Gaussian SVM (2.4) mencapai ketepatan pengelasan antara fungsi SVM yang tertinggi pada 96.0%, diikuti oleh Cubic SVM

(2.3) dengan ketepatan pengelasan antara fungsi SVM sebanyak 94.0%. SVM Linear (2.1) dan SVM Gaussian Sederhana (2.5) kedua-duanya mempunyai ketepatan pengelasan antara fungsi SVM sebanyak 90.0%, manakala SVM Gaussian Kasar (2.6) mempunyai ketepatan pengelasan antara fungsi SVM yang paling rendah iaitu sebanyak 74.0%.


|                                  |                              |
|----------------------------------|------------------------------|
| 2.1 SVM                          | Accuracy (Validation): 90.0% |
| Last change: Linear SVM          | 1/1 features                 |
| 2.2 SVM                          | Accuracy (Validation): 96.0% |
| Last change: Quadratic SVM       | 1/1 features                 |
| 2.3 SVM                          | Accuracy (Validation): 94.0% |
| Last change: Cubic SVM           | 1/1 features                 |
| 2.4 SVM                          | Accuracy (Validation): 96.0% |
| Last change: Fine Gaussian SVM   | 1/1 features                 |
| 2.5 SVM                          | Accuracy (Validation): 90.0% |
| Last change: Medium Gaussian SVM | 1/1 features                 |
| 2.6 SVM                          | Accuracy (Validation): 74.0% |
| Last change: Coarse Gaussian SVM | 1/1 features                 |

RAJAH 9. Prestasi pengelasan antara fungsi SVM

## PERBINCANGAN

### UJIAN MAKMAL BAGI PERANTI PENGESANAN GEOFON

Berikut merupakan analisis yang telah dilakukan bagi ujian makmal dengan menggunakan peranti pengesanan geofon. Data yang diperolehi dianalisis dengan menggunakan SPSS. Graf garis lurus digunakan dan diterapkan bagi mendapatkan nilai kecerunan (m).




RAJAH 10. Data minimum dan maksimum geofon bagi setiap frekuensi

Rajah 10 menunjukkan nilai maksimum dan minimum geofon diplotkan terhadap amplitud. Nilai maksimum ditandakan dengan petak hitam manakala nilai minimum ditandakan dengan bulatan merah. Pada amplitud 0, nilai maksimum adalah 79 mV dan nilai minimum adalah -74 mV. Apabila amplitud meningkat, nilai maksimum geofon meningkat secara konsisten, mencapai 17769 mV pada amplitud 8. Sebaliknya, nilai minimum menunjukkan penurunan drastik, jatuh ke -27048 mV pada amplitud yang sama. Penemuan ini mencerminkan keupayaan geofon untuk mengesan perubahan dalam amplitud getaran dengan jelas. Dalam kajian Caffagni dan Eaton (2014), mereka juga menunjukkan bahawa geofon berfungsi dengan baik dalam menangkap gelombang seismik, dengan 81% daripada gempa bumi yang disenaraikan dalam katalog CNSN direkodkan dengan baik oleh tatasusunan geofon yang mereka gunakan (Caffagni & Eaton 2014).



RAJAH 11. Kepekaan geofon bagi nilai positif

Rajah 11 memfokuskan kepada nilai kepekaan geofon bagi nilai positif. Data ini menunjukkan bahawa nilai maksimum bagi geofon meningkat dari 79 mV pada amplitud 0 kepada 17769 mV pada amplitud 8. Trend ini jelas dilihat melalui garis regresi ( $y = 1906.5x - 1351.6$ ), yang menunjukkan kenaikan linear yang signifikan. Peningkatan ini mencadangkan bahawa geofon semakin peka terhadap isyarat positif apabila amplitud getaran bertambah. Penemuan ini selaras dengan hasil kajian Caffagni dan Eaton (2014) yang menekankan bahawa pengukuran amplitud dan analisis gelombang memainkan peranan penting dalam menilai keberkesanan peranti ini dalam pemantauan seismik (Caffagni & Eaton 2014).



RAJAH 12. Kepekaan geofon bagi nilai negatif

Sebaliknya, Rajah 12 menunjukkan nilai kepekaan geofon bagi nilai negatif. Data ini menunjukkan penurunan dari -74 mV pada amplitud 0 kepada -27048 mV pada amplitud 8. Garis regresi ( $y = -2953.1x + 2981.6$ ) menunjukkan trend penurunan yang jelas. Penurunan ini mencadangkan bahawa geofon menjadi lebih peka terhadap isyarat negatif apabila amplitud getaran meningkat. Kajian Caffagni dan Eaton (2014) menekankan pentingnya analisis gelombang dalam memahami sensitiviti geofon terhadap pelbagai jenis isyarat. Dalam kajian mereka, geofon menunjukkan keupayaan yang baik untuk mengesan gelombang P dan S, tetapi mungkin kurang sensitif terhadap frekuensi rendah yang mempengaruhi pengesanan isyarat negatif (Caffagni & Eaton 2014).

Oleh itu, penemuan kajian ini mengenai peningkatan kepekaan terhadap isyarat negatif pada amplitud yang lebih tinggi memberikan perspektif tambahan tentang bagaimana geofon berfungsi dalam konteks seismik, selaras dengan hasil kajian mereka.

## PEMBELAJARAN MESIN BAGI KLASIFIKASI JENIS-JENIS GETARAN MENGGUNAKAN SVM

Mesin Vektor Sokongan (SVM) mencari hipersatah yang ideal dengan margin terbesar antara titik data kelas yang berbeza. Hipersatah ini berfungsi sebagai sempadan keputusan dalam konteks klasifikasi, membantu dalam perbezaan kelas. SVM ialah kaedah yang fleksibel dan cekap untuk mengendalikan data tidak boleh dipisahkan secara linear dalam ruang berdimensi tinggi. Ia menyediakan beberapa fungsi kernel, seperti "Linear", "Quadratic", "Cubic", "Fine Gaussian", "Medium Gaussian" dan "Coarse Gaussian".

Rajah 13 hingga 18 menunjukkan matriks kekeliruan bagi setiap model SVM yang diuji. Paksi Y "True Class" mewakili label kelas sebenar berdasarkan amplitud getaran yang ditetapkan pada Micromix Shaker semasa pengujian. Kelas 1 hingga 5 masing-masing mewakili Amplitud 0, 2, 4, 6, dan 8. Sel warna biru pada garisan pepenjur menunjukkan klasifikasi yang tepat berdasarkan padanan antara "True class" dan "Predicted class". Sel berwarna merah jambu di luar pepenjur menunjukkan kesilapan klasifikasi menunjukkan kegagalan model meramal kelas yang betul.

## LINEAR SVM

Matriks kekeliruan yang ditunjukkan pada Rajah 13 menunjukkan prestasi Model 2.1 iaitu model Linear SVM dalam lima kelas berbeza. Unsur pepenjur menunjukkan ramalan yang tepat, dengan kelas 1 dan 4 mempunyai kadar ketepatan tertinggi dengan 10 ramalan yang betul setiap

satu. Kelas 5 menunjukkan ketepatan yang lemah, dengan hanya 7 kes diramal tepat dan 3 kes yang dikelaskan salah dalam kelas 4. Satu kes bagi kelas 2 telah tersilap dikelaskan kepada kelas 1, dan satu kes bagi kelas 3 telah tersilap dikategorikan sebagai kelas 2.

Kesalahan klasifikasi cenderung lebih kerap berlaku merentas kelas bersebelahan. Aliran ini membayangkan bahawa walaupun model menunjukkan prestasi yang mengagumkan secara keseluruhan, ia mempunyai sedikit kesukaran untuk membezakan antara beberapa kelas berdekatan. Pemahaman ini boleh mengarahkan pengoptimuman model tambahan untuk meningkatkan ketepatan klasifikasi, terutamanya untuk kelas 5 dan kemungkinan kekeliruannya dengan kelas 4.

**Model 2.1**

|                              |    |   |   |    |   |
|------------------------------|----|---|---|----|---|
| True Class \ Predicted Class | 1  | 2 | 3 | 4  | 5 |
| 1                            | 10 |   |   |    |   |
| 2                            | 1  | 9 |   |    |   |
| 3                            |    | 1 | 9 |    |   |
| 4                            |    |   |   | 10 |   |
| 5                            |    |   |   | 3  | 7 |

RAJAH 13. Matrik kekeliruan Linear SVM

### QUADRATIC SVM

Berdasarkan Rajah 14 dengan kebanyakan ramalan jatuh pada pepenjuru menandakan pengelasan yang tepat, matriks kekeliruan untuk Model 2.2 yang menggunakan Quadratic SVM menunjukkan prestasi pengelasan yang baik merentas kesemua lima kelas. Dengan hanya beberapa kesalahan pengelasan kecil dan sepuluh ramalan yang tepat dalam kelas 1, 3, dan 4, setiap kelas menunjukkan ketepatan yang sangat baik.

Satu kes dalam kelas 2 dan kelas 5 tersilap diberikan kepada kelas 3 dan kelas 4, masing-masing. Model 2.2 menunjukkan bilangan salah klasifikasi yang lebih rendah berbanding Model 2.1, terutamanya untuk kelas 5, yang meningkatkan kuasa ramalannya. Ini menunjukkan bahawa Quadratic SVM adalah pilihan yang boleh dipercayai untuk tugas pengelasan ini kerana ia dapat membezakan dengan berkesan antara pelbagai kelas.

**Model 2.2**

|                              |    |   |    |    |   |
|------------------------------|----|---|----|----|---|
| True Class \ Predicted Class | 1  | 2 | 3  | 4  | 5 |
| 1                            | 10 |   |    |    |   |
| 2                            |    | 9 | 1  |    |   |
| 3                            |    |   | 10 |    |   |
| 4                            |    |   |    | 10 |   |
| 5                            |    |   |    | 1  | 9 |

RAJAH 14. Matrik kekeliruan Quadratic SVM

### CUBIC SVM

Berdasarkan Rajah 15, Cubic SVM digunakan untuk mencipta matriks kekeliruan untuk Model 2.3, yang menunjukkan prestasi ketepatan pengelasannya yang hebat dalam lima kelas. Unsur pepenjuru, yang bermaksud ramalan yang tepat, menunjukkan bahawa kelas 1 dan 5 mempunyai ramalan ketepatan yang sempurna, dengan 10 ramalan tepat setiap satu. Namun, terdapat beberapa kesalahan klasifikasi kecil bagi kelas lain. Satu kes dalam kelas 2 telah salah dikategorikan sebagai kelas 3, satu kes dalam kelas 3 salah dikategorikan sebagai kelas 2, dan satu kes kelas 5 telah salah dikategorikan sebagai kelas 4.

**Model 2.3**

|                              |    |   |   |    |   |
|------------------------------|----|---|---|----|---|
| True Class \ Predicted Class | 1  | 2 | 3 | 4  | 5 |
| 1                            | 10 |   |   |    |   |
| 2                            |    | 9 | 1 |    |   |
| 3                            |    | 1 | 9 |    |   |
| 4                            |    |   |   | 10 |   |
| 5                            |    |   |   | 1  | 9 |

RAJAH 15. Matrik kekeliruan Cubic SVM

Model Cubic SVM mengekalkan tahap prestasi yang setanding dengan Model Quadratic SVM (Model 2.2), menunjukkan bahawa ia berkesan dalam membezakan antara kelas, dengan hanya sedikit kesalahan pengelasan bagi kelas yang bersebelahan. Ini menunjukkan bahawa kedua-dua teknik SVM boleh dipercayai, dengan Cubic SVM menawarkan hasil pengelasan yang serupa.

### FINE GAUSSIAN SVM

Berdasarkan Rajah 16, prestasi pengelas Fine Gaussian SVM (Model 2.4) ke atas lima kelas dilihat dalam matriks kekeliruan. Seperti yang dapat dilihat daripada matriks, pengelas berfungsi dengan baik untuk kebanyakan kelas, mempamerkan ketepatan tinggi pada pepenjuru di mana kelas yang benar dan yang diramalkan bertepatan.

Dengan sepuluh ramalan tepat setiap satu, kelas 1, 4, dan 5 secara khusus dilabel sebagai sempurna. Kelas 2 dan kelas 3 kadangkala tersalah klasifikasi, dengan satu kes kelas 2 dikelaskan secara salah sebagai kelas 3 dan satu kes kelas 3 dikelaskan secara salah sebagai kelas 2. Secara keseluruhannya, pengelas berprestasi baik dengan beberapa kesalahan klasifikasi, menunjukkan bahawa ia boleh dengan tepat dan berjaya mendiskriminasi data antara kelas.

**Model 2.4**

|   |    |   |   |    |    |
|---|----|---|---|----|----|
| 1 | 10 |   |   |    |    |
| 2 |    | 9 | 1 |    |    |
| 3 |    | 1 | 9 |    |    |
| 4 |    |   |   | 10 |    |
| 5 |    |   |   |    | 10 |
|   | 1  | 2 | 3 | 4  | 5  |

Predicted Class

RAJAH 16. Matrik kekeliruan Fine Gaussian SVM

### MEDIUM GAUSSIAN SVM

Prestasi pengelas merentas lima kelas dipaparkan dalam matriks kekeliruan untuk Medium Gaussian SVM (Model 2.5) dapat dilihat dalam Rajah 17. Bagi kelas 1 dan 4, model mencapai pengelasan sempurna dengan mengklasifikasikan

setiap kes untuk setiap kelas dengan betul. Bagi kelas yang lain, terdapat beberapa salah klasifikasi; misalnya 1 kes kelas 3 dikelaskan sebagai kelas 2, satu kes kelas 5 dikategorikan sebagai kelas 4, dan tiga kes kelas 2 dikelaskan sebagai kelas 1 dan kelas 3.

Sebahagian besar ramalan terletak di sepanjang pepenjuru, mencadangkan pengelasan yang betul, dan model biasanya berprestasi baik walaupun terdapat salah klasifikasi ini. Pengelas menunjukkan prestasi yang mengagumkan secara keseluruhan, bagaimanapun masih terdapat potensi untuk penambahbaikan dari segi membezakan antara kelas tertentu.

**Model 2.5**


|   |    |   |   |    |   |
|---|----|---|---|----|---|
| 1 | 10 |   |   |    |   |
| 2 | 2  | 7 | 1 |    |   |
| 3 |    | 1 | 9 |    |   |
| 4 |    |   |   | 10 |   |
| 5 |    |   |   | 1  | 9 |
|   | 1  | 2 | 3 | 4  | 5 |

Predicted Class

RAJAH 14. Matrik kekeliruan Medium Gaussian SVM

### COARSE GAUSSIAN SVM

Berdasarkan Rajah 18, matriks kekeliruan Coarse Gaussian SVM (Model 2.6) menunjukkan prestasi yang berbeza-beza dalam setiap lima kelas. Semua kes kelas 1 diklasifikasikan dengan tepat mengikut model, namun terdapat salah klasifikasi yang ketara dalam kelas yang lain. Misalnya, tiga kes kelas 2 tersilap diberikan kepada kelas 1, satu kes kelas 3 diberikan kepada kelas 2, dan tiga kes kelas 4 dikategorikan secara salah kepada kelas 3. Kelas 5 menunjukkan banyak salah faham, dengan enam kes salah dikelaskan ke kelas 4. Model ini menghadapi masalah membezakan antara beberapa kelas, terutamanya kelas 2, 4 dan 5, walaupun ia membuat beberapa ramalan yang tepat di sepanjang pepenjuru. Ini menunjukkan bahawa Coarse Gaussian SVM mungkin bukan model terbaik untuk masalah pengelasan ini.



RAJAH 14. Matrik kekeliruan Quadratic SVM

Analisis terperinci terhadap matriks kekeliruan bagi kesemua enam model kernel mendapati bahawa wujud corak pengelasan yang konsisten. Secara khususnya, kelas 1 (Amplitud 0) menunjukkan ketepatan hampir 100%

JADUAL 3. Prestasi ketepatan pengelasan antara fungsi SVM

| Model | Bilangan Fitur | Tetapan         | Ketepatan (%) |
|-------|----------------|-----------------|---------------|
| SVM   | 1              | Linear          | 90            |
| SVM   | 2              | Quadratic       | 96            |
| SVM   | 3              | Cubic           | 94            |
| SVM   | 4              | Fine Gaussian   | 96            |
| SVM   | 5              | Medium Gaussian | 90            |
| SVM   | 6              | Coarse Gaussian | 74            |

Kajian dilakukan oleh Muttaqin et al. (2025) menunjukkan keupayaan SVM yang luar biasa untuk mengklasifikasikan jenis getaran, termasuk getaran seismik dan bunyi bising lain. Prestasi SVM dalam klasifikasi ini hampir mencapai ketepatan sempurna, yang sepadan dengan prestasi Jaringan Neural Tiruan (ANN) yang melebihi 95%. Ini menunjukkan bahawa SVM mampu membezakan antara getaran yang berkaitan dengan gempa bumi dan getaran lain dengan sangat berkesan, mengesahkan keupayaan model ini dalam mengesan gempa bumi (Muttaqin et al., 2025).

Namun demikian, kajian oleh Muttaqin et al. (2025) menggunakan data sekunder iaitu sejarah gempa bumi yang tertumpu kepada analisis algoritma, manakala kajian ini berfokus kepada mengintegrasikan algoritma SVM ke dalam sistem perkakasan geofon untuk mengesan data primer secara masa nyata. Sistem yang dicadangkan oleh kajian ini adalah berbeza dengan model ramalan berasaskan pangkalan data kerana ia menggunakan sensor fizikal yang

merangkumi semua model, membuktikan keberkesanan algoritma SVM dalam membezakan bunyi bising latar belakang daripada getaran seismik sebenar, yang merupakan satu ciri kritikal untuk mengelakkan amaran palsu.

Walau bagaimanapun, kesilapan klasifikasi didapati kerap berlaku antara kelas yang berjiran seperti pertindihan antara kelas 2 dengan kelas 3, seta kelas 4 dengan kelas 5. Corak ini menunjukkan persamaan ciri isyarat yang ketara seperti nilai RMS dan amplitud puncak, pada tahap getaran yang berturutan. Kes seperti ini menjelaskan mengapa model yang kurang kompleks seperti "Course Gaussian" gagal memisahkan sempadan keputusan yang tepat. Manakala, model yang lebih kompleks seperti "Fine Gaussian" dan "Quadratic" berjaya menangani variasi antara data ini dan mencapai ketepatan keseluruhan yang lebih tinggi (96%).

Jadual 2 menunjukkan keputusan yang diperolehi melalui prestasi ketepatan antara fungsi SVM. Jadual ini menunjukkan bahawa data mempunyai corak bukan linear yang lebih baik ditangkap oleh model SVM yang lebih kompleks seperti Quadratic dan Fine Gaussian, manakala model Linear dan Coarse Gaussian kurang berkesan.

menangkap isyarat voltan dan amplitud getaran secara langsung. Hal ini menjadikan sistem yang dicadangkan sebagai sebuah penyelesaian amaran awal yang lebih praktikal dan kos efektif untuk kegunaan di lapangan.

Prestasi model SVM berbeza dengan ketara berdasarkan kernel dan parameter yang digunakan, menunjukkan bahawa pilihan kernel dan parameter adalah penting untuk prestasi optimum dalam mengesan gempa bumi menggunakan data sensor geofon. Ketepatan tinggi Quadratic SVM dan Fine Gaussian SVM menyerlahkan keupayaan mereka untuk memodelkan hubungan rumit dalam data, manakala prestasi Coarse Gaussian SVM yang lebih rendah menunjukkan ia mungkin terlalu mudah atau umum untuk menangkap butiran yang diperlukan dalam pengesanan gempa bumi yang tepat. Analisis ini menekankan kepentingan pemilihan model dan penalaan halus dalam aplikasi pembelajaran mesin untuk analisis data geofizik.

## ANALISIS SISTEM KOS EFEKTIF

Salah satu objektif kajian ini adalah membangunkan sistem yang kos efektif tanpa mengurangkan keupayaan pengesanan asas. Jadual 3 menunjukkan perbandingan anggarann kos antara prototaip yang dibangunkan menggunakan Raspberry Pi dan Geofon SM-24 dengan sistem seismometer gred industri tradisional

JADUAL 4. Perbandingan Anggaran Kos Sistem

| Sistem             | Komponen Utama                              | Anggaran Kos (RM) |
|--------------------|---------------------------------------------|-------------------|
| Sistem Cadangan    | Sensor: Geofon SM-24                        | 115.47            |
|                    | Pemprosesan: Raspberry Pi 3 Model B+        | 182.80            |
|                    | Penukar Analog ke Digital: ADS1115          | 75.88             |
|                    | Lain – lain (Kad SD, Kabel, Bekalan Kuasa)  | 100.00            |
|                    | JUMLAH KOS                                  | RM 473.85         |
| Sistem Tradisional | Sensor: Seismometer Jalur Lebar (Broadband) | >20,000.00        |
|                    | Pemprosesan: Datalogger Seismik             | >8,000.00n        |
|                    | Infrastruktur: Pelayan Pusat & Rangkaian    | >10,000.00        |
| JUMLAH             |                                             | >RM 38,000.00     |

Berdasarkan analisis pasaran semasa, kos keseluruhan bagi satu unit sistem yang dicadangkan dianggarkan sekitar RM 473.85. Namun, bagi sistem berskala nasional seperti ShakeAlert, kos sebenar adalah jauh lebih tinggi. Berdasarkan pelan pelaksanaan teknikal USGS, kos modal bagi penambahbaikan telemetri sahaja dianggarkan mencecah USD 20.5 juta (RM 96 juta). Manakala, kos operasi dan penyelenggaraan tahunan sekitar USD 9.7 juta (RM45 Juta). Ini menunjukkan bahawa kos infrastruktur rangkaian adalah halangan kewangan utama yang cuba diatasi oleh sistem yang dicadangkan di dalam kajian ini.

Pemilihan seismometer jalur lebar sebagai perbandingan dibuat kerana ia merupakan peralatan standard yang digunakan dalam rangkaian pemantauan seismik dan sistem amaran awal global seperti ShakeAlert. Walaupun, seismometer jalur lebar ini mempunyai kepekaan yang lebih tinggi, tetapi kos infrastruktur yang mahal mengehendkan jumlah pemasangan sistem. Hal ini menyebabkan pemasangan rangkaian jarang (Sparse Network) yang mengurangkan ketepatan amaran gempa bumi.

Perbezaan kos yang ketara ini membuktikan bahawa sistem yang ddicadangkan sangat kos efektif. Ini membolehkan pemasangan rangkaian sensor yang lebih padat (dense network) di kawasan berisiko tinggi dengan peruntukan yang jauh lebih rendah berbanding infrastruktur yang sedia ada seperti ShakeAlert atau MET Malaysia.

## ANALISIS MASA RESPONS SISTEM

Kepantasan pengesanan sistem amaran awal gempa bumi juga merupakan satu parameter kritikal selain daripada kecekapan kos. Kebiasaanya, sistem tradisional menggunakan rangkaian berpusat (centralized network) yang akan memproses semua data mentah dari seismometer. Ini akan menyebabkan berlakunya kelewatan dalam mengesan gempa bumi kerana masa yang terbuang semasa data dihantar dari seismometer di lapangan ke komputer pusat untuk diproses. Hal ini dikenali sebagai latensi telemetri (Telemetry Latency). Berdasarkan kajian yang dilakukan oleh Allen dan Melgar (2019), latensi telemetri ini boleh melambatkan amaran antara beberapa saat hingga minit bergantung kepada kesesakan rangkaian dan jarak penghantaran.

Sebaliknya, sistem yang dicadangkan oleh kajian ini menggunakan pendekatan Pengkomputeran Pinggir (Edge Computing). Semua proses merangkumi pra-pemprosesan isyarat, pengekstrakan ciri, dan klasifikasi SVM dilakukan secara setempat pada unit Raspberry Pi. Berdasarkan kerangka ini, masa respons sistem bergantung kepada tempoh tetingkap data (windowing) dan masa pengiraan (Computational time) algoritma SVM. Berdasarkan analisis prestasi prototaip, keputusan klasifikasi dapat dijana secepat selepas satu saat data dikumpul kerana sistem ini menggunakan tetingkap data selama 1 saat dengan kadar pensampelan 100 Hz. Pemproses Raspberry Pi 3 model B+ mempunyai spesifikasi yang beroperasi pada frekuensi 1.2 GHz, jadi anggaran masa yang diambil untuk model SVM melakukan klasifikasi adalah dalam julat milisaat.

Walaupun tiada perbandingan makmal secara langsung, hasil analisis masa respons ini menunjukkan sistem yang dicadangkan mampu memberikan amaran dalam anggaran tempoh 1.5 saat termasuk pengumpulan data dan pra-pemprosesan. Sistem tradisional pula memerlukan anggaran 1 hingga 5 saat hanya untuk proses telemetri sebelum pemprosesan bermula (Allen & Melgar, 2019). Untuk aplikasi amaran awal gempa bumi masa nyata, pendekatan pengkomputeran pinggir adalah lebih pantas dan efisien tanpa komponen latensi telemetri. Sistem yang dicadangkan mempunyai kebolehpercayaan (reliability) yang lebih tinggi terutama di kawasan yang mempunyai kekurangan infrastruktur rangkaian internet yang pantas.

## KESIMPULAN

Kesimpulannya, kajian ini berjaya membangunkan dan menguji sistem pengesanan gempa bumi masa nyata yang menggabungkan data daripada geofon dengan algoritma Support Vector Machine (SVM). Hasil ujian makmal menunjukkan bahawa peranti pengesanan geofon berupaya mengesan variasi amplitud dengan kepekaan yang berbeza bagi nilai positif dan negatif, menunjukkan potensi penggunaannya dalam sistem amaran awal gempa bumi. Analisis pembelajaran mesin menggunakan SVM mendedahkan bahawa kernel Quadratic SVM dan Fine Gaussian SVM mencapai ketepatan klasifikasi yang tertinggi, mengatasi kernel-kernel lain. Ini mengesahkan bahawa model SVM mampu mengenal pasti dan mengklasifikasikan corak gegaran seismik dengan berkesan, membezakannya daripada gangguan bunyi aktiviti harian.

Walaupun kajian ini menunjukkan hasil yang menjanjikan, terdapat beberapa cadangan untuk penambahbaikan dan kajian lanjutan. Pertama, adalah penting untuk menjalankan ujian lapangan di kawasan yang terdedah kepada gempa bumi untuk mengesahkan prestasi sistem dalam keadaan dunia sebenar. Data dari ujian lapangan ini akan membantu dalam penalaan model SVM untuk meningkatkan ketepatan dan kebolehpercayaan pengesanan. Kedua, kajian lanjutan boleh meneliti integrasi algoritma pembelajaran mesin lain seperti rangkaian neural (*neural networks*) atau kaedah pembelajaran mendalam (*deep learning*) untuk melihat sama ada ia boleh memberikan prestasi yang lebih baik berbanding SVM. Ketiga, sistem ini boleh dipertingkatkan lagi dengan menggabungkan data daripada berbilang sensor, termasuk akselerometer dan stesen seismik yang sedia ada, untuk memberikan liputan yang lebih komprehensif dan tepat.

Selain itu, kajian di masa hadapan perlu menumpukan pada pengurangan kos sistem supaya ia lebih mudah diakses dan digunakan secara meluas. Ini boleh dicapai dengan mengoptimalkan pemilihan komponen dan memperkemas proses pemasangan. Akhir sekali, adalah penting untuk membangunkan antara muka mesra pengguna yang membolehkan orang awam, terutama di kawasan berisiko, untuk memahami dan bertindak balas dengan berkesan kepada amaran gempa bumi yang diberikan oleh sistem ini. Dengan mengambil kira cadangan-cadangan ini, sistem pengesanan gempa bumi berasaskan pembelajaran mesin berpotensi untuk memainkan peranan yang ketara dalam mengurangkan kesan buruk gempa bumi di Malaysia dan rantau sekitarnya.

## PENGHARGAAN

Penyelidikan ini dibiayai oleh Kementerian Pengajian Tinggi Malaysia (KPT), Malaysia, melalui Skim Geran Penyelidikan Fundamental (FRGS) di bawah geran FRGS/1/2023/TK07/UKM/01/2.

## PENGISYTIHARAN KEPENTINGAN BERSAING

Tiada.

## RUJUKAN

- A, S. S., Singh, L. B., Rathakrishnan, B., Kiflee, Dg. N. A., Talip, R., Zulfikar, Z. & Lan, A. S. S. 2018. Penilaian pengetahuan dan kesiapan menghadapi bencana gempa bumi dalam kalangan guru sekolah di Ranau, Sabah (Assessment of readiness and earthquake disaster prevention knowledge of school teachers in Ranau, Sabah). *e-Bangi* 15(2).
- Ahmed, S. K., Chandran, D., Hussein, S., Sv, P., Chakraborty, S., Islam, Md. R. & Dhama, K. 2023. Environmental health risks after the 2023 Turkey-Syria earthquake and salient mitigating strategies: A critical appraisal. *Environmental Health Insights* 17: 11786302231200865.
- Allen, R. M. & Melgar, D. 2019. Earthquake early warning: Advances, scientific challenges, and societal needs. *Annual Review of Earth and Planetary Sciences* 47(1): 361-388.
- Al-Taie, A. J. & Ahmed, M. D. 2025. Selection considerations and classification bases of earth retaining systems. *Jurnal Kejuruteraan* 37(2): 679-694.
- Caffagni, E. & Eaton, D. W. 2014. Detection sensitivity of local tectonic earthquakes by borehole geophone arrays: A case study from central Alberta. *GeoConvention 2014: FOCUS*.
- Choudhury, M., Verma, S. & Saha, P. 2016. Effects of earthquake on the surrounding environment: An overview. Dlm. *Proceedings of International Conference on Recent Advances in Mechanics and Materials (ICRAMM-2016)*.
- Cremen, G. & Galasso, C. 2020. Earthquake early warning: Recent advances and perspectives. *Earth-Science Reviews* 205: 103184.
- Daniell, J. E., Schaefer, A. M. & Wenzel, F. 2017. Losses associated with secondary effects in earthquakes. *Frontiers in Built Environment* 3.
- Fan, X., Scaringi, G., Korup, O., West, A. J., Van Westen, C. J., Tanyas, H., Hovius, N., Hales, T. C., Jibson, R. W., Allstadt, K. E., Zhang, L., Evans, S. G.,

- Xu, C., Li, G., Pei, X., Xu, Q. & Huang, R. 2019. Earthquake-induced chains of geologic hazards: Patterns, mechanisms, and impacts. *Reviews of Geophysics* 57(2): 421-503.
- Guerrieri, L., Tatevossian, R., Vittori, E., Commerci, V., Esposito, E., Michetti, A. M., Porfido, S. & Serva, L. 2007. Earthquake environmental effects (EEE) and intensity assessment: The INQUA scale project. *Bollettino della Societa Geologica Italiana* 126(2): 375-386.
- Hill, E. M., McCaughey, J. W., Switzer, A. D., Lallemand, D., Wang, Y. & Sathiakumar, S. 2024. Human amplification of secondary earthquake hazards through environmental modifications. *Nature Reviews Earth & Environment* 5(6): 463-476.
- Hughes, B., Illsley-Kemp, F., Mestel, E., Townend, J., Chandrakumar, C. & Prasanna, R. 2025. Using citizen science Raspberry Shake seismometers to enhance earthquake location and characterization: A case study from Wellington, New Zealand. *Seismica* 4(1).
- Lee, R. E. & Chan, P. Y. 2023. Explainable artificial intelligence for searching frequency characteristics in Parkinson's disease tremor. *Scientific Reports* 13(1): 18622.
- Li, Y., Wang, Z. & Dai, H. 2023. Improved Parkinsonian tremor quantification based on automatic label modification and SVM with RBF kernel. *Physiological Measurement* 44(2): 025003.
- Mavroulis, S., Mavrouli, M., Lekkas, E. & Tsakris, A. 2023. Managing earthquake debris: Environmental issues, health impacts, and risk reduction measures. *Environments* 10(11): 192.
- Minson, S. E., Brooks, B. A., Glennie, C. L., Murray, J. R., Langbein, J. O., Owen, S. E., Heaton, T. H., Iannucci, R. A. & Hauser, D. L. 2015. Crowdsourced earthquake early warning. *Science Advances* 1(3): e1500036.
- Moorthy, R., Benny, G. & Gill, S. S. 2018. Disaster communication in managing vulnerabilities. *Jurnal Komunikasi: Malaysian Journal of Communication* 34(2): 51-66.
- Muhammad, F. N. & Lam, K. C. 2023. Forest mapping in Peninsular Malaysia using Random Forest and Support Vector Machine Classifiers on Google Earth Engine. *Malaysian Journal of Society and Space* 19(3).
- Muttaqin, A. F., Sunge, A. S. & Zy, A. T. 2025. Comparative analysis of earthquake prediction with SVM, Naïve Bayes, and K-Means models. *Journal of Computer Networks Architecture and High Performance Computing* 7(1): 104-119.
- Natawidjaja, D. H. & Triyoso, W. 2007. The Sumatran fault zone: From source to hazard. *Journal of Earthquake and Tsunami* 1(1): 21-47.
- Neamah, A. S. & Naser, A. F. 2025. Seismic resistance evaluation of highway bridges under lateral load of earthquake: A review study. *Jurnal Kejuruteraan* 37(7): 3337-3362.
- Rangin, C., Bellon, H., Benard, F., Letouzey, J., Muller, C. & Sanudin, T. 1990. Neogene arc-continent collision in Sabah, Northern Borneo (Malaysia). *Tectonophysics* 183(1-4): 305-319.
- Samad, M. A., Arifin, K., Abas, A. & Sari, T. E. 2024. Knowledge mapping and trend analysis of disaster mitigation research in the Sulawesi Islands of Indonesia: A bibliometric study using VOSViewer. *e-Bangi* 20(4).
- Shabnam, H. 2018. *The Mulu and Niah Caves of Sarawak as the Heartland of Eco-Tourism in Sarawak*. Universiti Kebangsaan Malaysia.
- Tatar, C. O., Cabuk, S. N., Ozturk, Y., Kurkcuglu, M. A. S., Ozenen-Kavlak, M., Ozturk, G. B., Dabanli, A., Kucukpehlivan, T. & Cabuk, A. 2024. Impacts of earthquake damage on commercial life: A RS and GIS based case study of Kahramanmaraş earthquakes. *International Journal of Disaster Risk Reduction* 107: 104464.
- Tatevossian, R. E., Rogozhin, E. A., Arefiev, S. S. & Ovsyuchenko, A. N. 2009. Earthquake intensity assessment based on environmental effects: Principles and case studies. *Geological Society, London, Special Publications* 316(1): 73-91.
- Tongkul, F. 1991. Tectonic evolution of Sabah, Malaysia. *Journal of Asian Earth Sciences* 6(3-4): 395-405.
- Tongkul, F. 2021. An overview of earthquake science in Malaysia. *ASM Science Journal* 14: 12.