

Klasifikasi percepatan dari sinyal gempa bumi dan sinyal linier aktivitas manusia menggunakan akselerometer smartphone berbasis algoritme support vector machine

Acceleration classification of earthquake signals and linear signals of human activity using smartphone accelerometer based on support vector machine algorithm

Hapsoro Agung Nugroho^{*)}, Haryas Subyantara Wicaksana

Program Studi Instrumentasi MKG, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika
Jalan Perhubungan I No.5 Komp. BMKG, Pondok Betung, Pondok Aren, Tangerang Selatan, Indonesia 15221

Cara sitasi: H. A. Nugroho and H. S. Wicaksana, "Klasifikasi percepatan dari sinyal gempa bumi dan sinyal linier aktivitas manusia menggunakan akselerometer smartphone berbasis algoritme support vector machine," *Jurnal Teknologi dan Sistem Komputer*, vol. 7 no. 4, pp. 166-171, 2019. doi: 10.14710/jtsiskom.4.1.2019.166-171, [Online].

Abstract - *The threat of earthquake calamity spread throughout most of the Indonesian archipelago. Smartphone's accelerometer usage as a seismic parameter detector in Indonesia, of which the noise has obstacles, mainly due to human activities. This study aims to classify linear acceleration signals caused by human activity and earthquake acceleration signals as an initial effort to reduce noise caused by human activity in the smartphone's accelerometer signals. Both signals are classified by using the Support Vector Machine (SVM) algorithm of which consists of several steps, respectively, data collection, data preprocessing, data segmentation, feature extraction, and classification. These algorithms are tested to 2545 human activity signals in trouser pocket, 2430 human activity signals in shirt pocket and earthquake acceleration signals. Based on the test results by using the confusion matrix, linear acceleration signal data caused by human activity and earthquake acceleration signals can be classified properly using an SVM algorithm with Polynomial or Gaussian kernel with a small kernel scale value. The algorithms can achieve an accuracy of 87.74% to 97.94%.*

Keywords – *accelerometer; earthquake; earthquake detection; support vector machine*

Abstrak - *Ancaman bahaya gempabumi tersebar hampir di seluruh wilayah kepulauan Indonesia. Akselerometer pada smartphone, yang dapat dimanfaatkan sebagai instrumen pendeteksi parameter kegempaan di Indonesia, memiliki kendala terkait noise akibat aktivitas manusia. Penelitian ini bertujuan memilah sinyal percepatan linier manusia*

dan sinyal gempabumi sebagai upaya awal untuk mereduksi noise akibat aktivitas manusia dalam sinyal akselerometer smartphone. Sinyal percepatan linier aktivitas manusia dan sinyal percepatan gempabumi diklasifikasikan menggunakan algoritme Support Vector Machine (SVM) dengan beberapa tahapan yaitu pengumpulan data, prapengolahan data, segmentasi data, ekstraksi fitur, dan klasifikasi. Algoritme SVM diujikan terhadap 2545 sinyal aktivitas manusia pada kantong celana, 2430 sinyal aktivitas manusia pada kantong baju dan sinyal gempabumi. Berdasarkan hasil pengujian menggunakan matriks konfusi, data sinyal percepatan linier aktivitas manusia dan sinyal percepatan gempabumi dapat diklasifikasikan secara baik menggunakan algoritme SVM berkernell Polinomial atau Gaussian dengan nilai kernel skala yang kecil. Algoritme ini mampu mencapai akurasi 87,74% hingga 97,94%.

Kata kunci – *akselerometer; gempabumi; support vector machine*

I. PENDAHULUAN

Wilayah Indonesia merupakan zona aktif pertemuan tiga lempeng tektonik dunia, yaitu lempeng Eurasia, lempeng Pasifik, dan lempeng Indo-Australia serta satu lempeng mikro, yaitu lempeng Filipina. Akibat tumbukan antara lempeng tersebut terbentuk daerah penunjaman atau subduksi. Oleh sebab itu, Indonesia menjadi rawan terhadap bencana gempabumi berupa getaran bumi secara tiba-tiba. Gempabumi dapat terjadi oleh peristiwa letusan gunung api, benturan meteorit, tanah longsor, ledakan bom, dan beberapa penyebab lainnya. Namun, gempabumi umumnya disebabkan oleh gerakan mendadak kerak bumi di sepanjang bidang patahan [1].

^{*)} Penulis korespondensi (Hapsoro A. Nugroho)
Email: hapsoro.agung@bmkgo.id

Salah satu parameter yang menentukan besarnya kekuatan gempabumi adalah *Peak Ground Acceleration* (PGA). PGA adalah harga percepatan tanah maksimum pada permukaan tanah yang terjadi di suatu wilayah dalam periode waktu tertentu yang ditimbulkan getaran gempabumi [2]. Penentuan harga PGA sangat berguna dalam analisis kerawanan bencana gempabumi karena bermanfaat bagi insinyur dalam rekayasa bangunan tahan gempabumi [3]. Harga PGA secara empiris berkaitan dengan intensitas gempabumi atau tingkat guncangan gempabumi. Skala intensitas gempabumi dinyatakan dengan dua belas skala *Modified Mercalli Intensity* (MMI) [4]. Saat ini skala MMI secara cepat diperoleh dari perangkat akselerometer. Akselerometer ditempatkan pada suatu lokasi yang mempunyai tingkat keaktifan gempabumi yang tinggi.

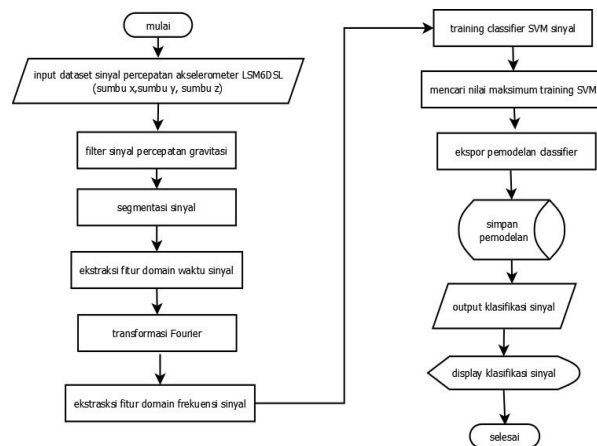
Perkembangan teknologi dan komunikasi saat ini dapat memanfaatkan akselerometer pada *smartphone* untuk mendapatkan informasi MMI secara cepat. Hanya saja pemanfaatan ini memiliki kendala terkait *noise*. Aktivitas manusia menghasilkan *noise* yang cukup signifikan terhadap rekaman di akselerometer pada *smartphone*. *Human Activity Recognizer* (HAR) sangat mungkin diimplementasikan sebagai pereduksi *noise* tersebut [5].

Penelitian terkait HAR telah banyak digunakan untuk mengidentifikasi dan menganalisis klasifikasi model komputasi. HAR mampu menginterpretasikan gerakan manusia lewat sensor dan dapat membedakan antara gerakan manusia atau aktifitas yang lainnya [6]. Penelitian HAR lainnya adalah untuk pengenalan pola aktifitas manusia, yaitu berjalan, berjalan perlahan, berlari kecil, dan naik-turun. Data menggunakan akselerometer *smartphone* ataupun perangkat yang digunakan pada manusia seperti *smart watch* dan *sport bracelet* yang mempunyai akselerometer [7]-[9].

Salah satu metode yang digunakan untuk melakukan klasifikasi pola adalah algoritme *Support Vector Machine* (SVM). SVM mempunyai kemampuan untuk mengklasifikasikan sinyal yang terekam pada akselerometer *smartphone*. Selain itu, SVM dapat membedakan sinyal *electroencephalography* (EEG) pada bidang medis [10]. SVM dapat melakukan pengenalan pola sinyal gempabumi secara otomatis dalam sebuah jaringan seismograf [11].

Selama ini, sebagian besar implementasi HAR hanya diterapkan dalam bidang kesehatan dan militer. Pengenalan aktivitas manusia digunakan untuk menghitung jumlah kalori sebagai acuan konsumsi gizi harian [10]. Namun, belum banyak kajian implementasi HAR untuk mitigasi bencana seperti gempabumi. Pemanfaatan algoritme SVM hanya berfokus pada pengenalan sinyal aktivitas manusia, tetapi belum mencakup pengenalan sinyal seismik yang mungkin terjadi terhadap *smartphone*.

Penelitian ini bertujuan mengimplementasikan HAR untuk mendapatkan sinyal percepatan gempabumi yang tercampur sinyal percepatan linier aktivitas manusia pada akselerometer *smartphone*. Algoritme yang didapatkan nantinya dapat diimplementasikan pada



Gambar 1. Diagram alir sistem

aplikasi Android di *smartphone* setiap pengguna sehingga pengguna dapat melihat informasi gempabumi yang terekam pada *smartphone* tanpa tercampur *noise* yang berasal dari aktivitas penggunanya.

II. METODE PENELITIAN

A. Penghimpunan data

Diagram alir untuk mendapatkan sinyal gempabumi dengan metode HAR ditunjukkan pada Gambar 1. Penghimpunan data dilakukan dengan merekam sinyal akselerometer *smartphone* saat subjek melakukan aktivitas. Jumlah subjek penelitian sebanyak 10 orang, dengan variasi jenis kelamin laki-laki 5 orang dan perempuan 5 orang dengan usia 12 - 53 tahun. Setiap subjek melakukan aktivitas berupa duduk, berdiri, berbaring, berjalan, berlari, dan memegang *smartphone*. Setiap aktivitas diujikan untuk meletakkan *smartphone* pada saku baju bagian dada dan saku celana bagian paha dengan orientasi peletakan vertikal. Sinyal masukan gempabumi yang dihimpun bervariasi dengan magnitudo 4,5 Mw hingga 7 Mw. Data yang digunakan sebanyak 2430 data untuk peletakan *smartphone* pada saku baju, sedangkan untuk total data di saku celana sebanyak 2545 data.

B. Data preprocessing

High pass filter dirancang untuk memisahkan sinyal percepatan linier pergerakan aktivitas subjek dari sinyal percepatan gravitasi. Filter ini merupakan *highpass filter* tipe *Butterworth* orde 3 dengan frekuensi *cut-off* 0,1 Hz. Orde 3 dianggap cukup efektif dalam mereduksi sinyal percepatan gravitasi yang memiliki frekuensi dominan berkisar 0,1 Hz - 0,5 Hz [12].

C. Segmentasi data

Segmentasi data untuk ekstraksi HAR menggunakan 100 sampel tanpa *overlapping*. Segmentasi tanpa *overlapping* memiliki akurasi yang lebih baik dibanding dengan *overlapping*. Frekuensi pencuplikan akselerometer *smartphone* sebesar 100 Hz sehingga terdapat 100 sampel per detik. Pada penelitian

ini, segmentasi data dilakukan dengan membagi sinyal akselerometer *smartphone* dengan 100 sampel atau durasi persegmen sepanjang 1 detik tanpa *overlapping*.

D. Ekstraksi fitur sinyal

Fitur setiap segmen sinyal pada ketiga sumbu akselerometer *smartphone* dilakukan ekstraksi. Fitur sinyal dalam domain waktu meliputi mean, maksimum, minimum, *skewness*, dan *kurtosis*. Fitur sinyal dalam domain frekuensi meliputi energi spektral, *spectral centroid*, entropi, dan frekuensi dominan.

E. Klasifikasi data

Klasifikasi sinyal output percepatan linier aktivitas manusia pada akselerometer triaksial *smartphone* menggunakan *classifier* berbasis SVM. Klasifikasi menggunakan SVM dibutuhkan data latih dan data uji dimana setiap data tersebut terdiri dari beberapa masukan data. Setiap masukan dalam data latih mengandung satu nilai target dan beberapa atribut. SVM menghasilkan sebuah model yang mampu memprediksi nilai target dari data pengujian dari nilai atributnya [13]. Prediktor dinotasikan sebagai x_i dan kelas dinotasikan sebagai y_i yang berisi dua kelas, diasumsikan -1 dan 1, sedangkan vektor w adalah *support vector*. Rumusan *hyperplane* untuk data linear dinyatakan dalam Persamaan 1.

$$\vec{y}_i = \vec{w} \cdot \vec{x}_i + b \quad (1)$$

Hyperplane untuk data non-linear dirancang menggunakan fungsi Kernel, yaitu mentransformasikan bidang vektor 2-D ke vektor 3-D terlebih dahulu. Dalam ruang vektor 3-D, prediktor-prediktor non-linear lebih mudah untuk dipisahkan dibanding bidang vektor 2-D. *Hyperplane* yang diterapkan pada data non-linear dengan memanfaatkan fungsi Kernel dinyatakan dalam Persamaan 2.

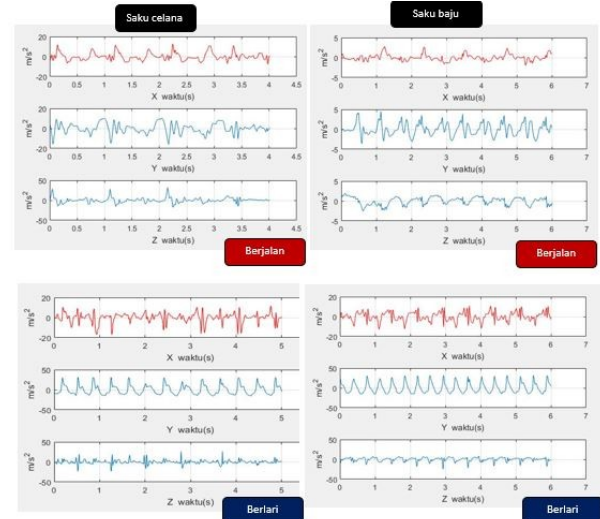
$$\vec{y}_i = \vec{w} \cdot K(\vec{x}_i, \vec{x}_j) + b \quad (2)$$

Sebanyak 70% data digunakan sebagai data model, sedangkan 30% data digunakan sebagai data validasi melalui proses pelatihan. Hasil akurasi *classifier* tertinggi dijadikan sebagai prediktor HAR untuk sinyal masukan yang baru. Akurasi model *classifier* dapat ditentukan melalui Persamaan 3 [14]. Parameter TP menyatakan *true positive*, TN *true negative*, FP *false positive*, dan FN *false negative*.

$$\text{Akurasi} = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (3)$$

III. HASIL DAN PEMBAHASAN

Sinyal akselerometer *smartphone* memiliki pola tertentu untuk setiap jenis aktivitas manusia. Pola ini bersifat identik untuk subjek dan orientasi yang berbeda, tetapi tidak identik untuk penempatan *smartphone* yang berbeda. Sinyal percepatan linear



Gambar 2. Pola sinyal aktivitas berjalan

Tabel 1. Fitur domain waktu

Fitur (m/s ²)	Aktivitas manusia		
	Saku Celana	Saku Baju	Gempabumi
meanX	1,68	0,97	0,04
meanY	2,69	2,39	0,10
meanZ	1,65	1,64	0,01
maxX	15,97	10,11	0,05
maxY	21,00	18,10	0,13
maxZ	18,97	13,32	0,02
minX	-15,83	-10,30	-0,02
minY	-20,04	-18,02	-0,08
minZ	-17,76	-13,05	-0,02
sma	946,10	777,10	18,87
skewnessX	0,01	0,00	-0,06
skewnessY	0,02	0,05	-0,11
skewnessZ	0,05	-0,01	-0,02
kurtosisX	4,04	3,44	1,19
kurtosisY	3,60	3,44	1,27
kurtosisZ	4,73	3,76	1,10

akselerometer *smartphone* pada saku celana cenderung memiliki amplitudo yang lebih besar dibandingkan dengan sinyal pada saku baju. Pergerakan kaki saat peralihan aktivitas dari berdiri ke duduk, duduk ke berbaring, serta berdiri ke berbaring lebih signifikan dibanding pergerakan dada. Demikian pula dengan pergerakan kaki pada aktivitas berjalan dan berlari yang lebih dominan dibandingkan dengan pergerakan dada. Gambar 2 menunjukkan pola sinyal akselerometer untuk aktivitas berjalan.

Tabel 1 menunjukkan perbedaan karakteristik fitur yang cukup signifikan antara sinyal aktivitas manusia dan sinyal gempabumi dalam domain waktu. Sinyal percepatan linier akibat aktivitas manusia memiliki nilai yang lebih besar untuk semua fitur dibandingkan dengan sinyal gempabumi baik di saku celana maupun di saku baju pada ketiga sumbu akselerometer. Sebagian besar sinyal aktivitas manusia memiliki amplitudo yang lebih besar dibanding sinyal gempabumi. Hal ini ditunjukkan oleh fitur nilai mean, maksimum dan signal magnitude area untuk semua sumbu akselerometer pada sinyal aktivitas manusia.

Nilai minimum sinyal percepatan gempa lebih besar dibanding sinyal percepatan linier aktivitas manusia sehingga rentang osilasi percepatan gempa lebih kecil dibanding aktivitas manusia. Distribusi sinyal percepatan aktivitas manusia cenderung bersifat leptokurtik (puncak distribusi runcing), sedangkan sinyal gempabumi cenderung bersifat platykurtic (puncak distribusi tumpul). Namun demikian, perbedaan nilai fitur *skewness* sinyal percepatan linier aktivitas manusia dan gempabumi tidak terlalu signifikan.

Sinyal percepatan aktivitas manusia pada saku celana memiliki nilai fitur yang lebih besar dibanding pada saku baju. Hal ini disebabkan oleh kaki sebagai anggota gerak tubuh manusia. Gerakan kaki pada peralihan aktivitas berdiri, duduk, berbaring, berjalan dan berlari lebih dominan dibanding gerakan tubuh bagian atas seperti dada.

Tabel 2 merupakan hasil ekstraksi fitur sinyal dalam domain frekuensi. Hasil ini juga membuktikan perbedaan karakteristik yang signifikan antara sinyal percepatan linier aktivitas manusia dan sinyal percepatan gempabumi. Perbedaan karakteristik yang signifikan ditunjukkan oleh seluruh fitur frekuensi, terutama energi sinyal. Nilai frekuensi dominan dan spectral centroid sinyal aktivitas manusia lebih kecil dibanding frekuensi dominan sinyal gempabumi. Nilai entropi sinyal percepatan linier aktivitas manusia cenderung lebih besar dibanding sinyal percepatan gempabumi. Hal ini berarti sinyal percepatan linier aktivitas manusia memiliki *information gain* yang lebih spesifik dibanding sinyal percepatan gempabumi. Energi sinyal percepatan linier aktivitas manusia jauh lebih besar dibanding energi sinyal gempabumi yang terekam oleh akselerometer. Sementara itu, fitur frekuensi sinyal percepatan linier aktivitas manusia pada saku celana dan saku baju tidak lebih signifikan dibanding fitur sinyal dalam domain waktu.

Akurasi tiap algoritme SVM yang digunakan ditunjukkan dalam Tabel 3. *Linear SVM* tidak memanfaatkan kernel karena menganggap data ekstraksi fitur sebagai data yang berkorelasi secara linier. Hal ini berarti bidang hyperplane yang terbentuk masih dalam bentuk dua dimensi. Sementara itu, sebagian besar data ekstraksi fitur merupakan data non-linear, sehingga hasil klasifikasi *linear SVM* menunjukkan akurasi yang lebih rendah dibanding jenis algoritme SVM lainnya.

Quadratic SVM dan *cubic SVM* menggunakan kernel polinomial. *Quadratic SVM* menggunakan pangkat polinomial bernilai 2, sedangkan *cubic SVM* berpangkat polinomial 3. Hasil klasifikasi algoritme SVM yang menggunakan kernel polinomial memiliki akurasi yang cukup baik, yaitu di atas 80%. Kernel Polinomial menyebabkan hyperplane bersifat fleksibel dalam memisahkan antar kelas data sehingga nilai akurasi klasifikasi cukup tinggi.

Fine SVM, *medium SVM* dan *coarse SVM* menggunakan kernel Gaussian dengan nilai skala kernel berjenjang sebagai faktor pengali dalam kernel

Tabel 2. Fitur domain frekuensi

Fitur Frekuensi	Aktivitas manusia		Gempabumi
	Saku Celana	Saku Baju	
fdomX (Hz)	0,34	0,36	2,36
fdomY (Hz)	0,29	0,25	2,30
fdomZ (Hz)	0,54	0,42	2,70
energyX (kJ)	168,82	65,34	0,48
energyY (kJ)	368,45	316,26	3,86
energyZ (kJ)	157,03	119,10	0,02
centroidX (Hz)	8,32	7,82	41,69
centroidY (Hz)	6,55	6,29	39,98
centroidZ (Hz)	9,22	7,56	44,73
entropyX (bits)	1,59	2,03	1,21
entropyY (bits)	1,17	1,43	1,26
entropyZ (bits)	1,52	1,58	1,17
meanfreqX (Hz)	3,47	3,05	45,12
meanfreqY (Hz)	2,47	2,23	43,75
meanfreqZ (Hz)	4,45	3,09	47,09

Tabel 3. Akurasi algoritme SVM

Posisi	Tipe SVM	True (TP+TF)	False (FP+FN)	Akurasi (%)	
Saku	<i>Linear</i>	1887	658	74,14	
	Celana	<i>Quadratic</i>	2435	110	95,67
		<i>Cubic</i>	2233	312	87,74
		<i>Fine</i>	2367	181	92,89
		<i>Medium</i>	2084	496	80,77
	<i>Coarse</i>	1785	759	70,16	
Saku Baju	<i>Linear</i>	1727	703	71,07	
	<i>Quadratic</i>	2168	262	89,22	
	<i>Cubic</i>	2380	50	97,94	
	<i>Fine</i>	2232	198	91,85	
	<i>Medium</i>	1878	552	77,28	
	<i>Coarse</i>	1588	842	65,35	

Gaussian. Nilai skala kernel tipe *fine SVM* yaitu 2,9, tipe *medium SVM* yaitu 9,1, dan tipe *coarse SVM* yaitu 36.

Peningkatan nilai skala kernel justru menyebabkan penurunan nilai akurasi algoritme SVM tipe Gaussian (Tabel 3), baik pada posisi saku celana maupun saku baju. Kenaikan skala kernel kemungkinan menyebabkan margin hyperplane semakin kecil sehingga klasifikasi antar kelas data HAR semakin rancu. Kerancuan klasifikasi mengakibatkan akurasi yang tidak maksimal.

Berdasarkan penelaahan tersebut, data sinyal percepatan linier aktivitas manusia dan sinyal percepatan gempabumi dapat diklasifikasikan secara baik menggunakan algoritme SVM berkernel polinomial atau Gaussian dengan skala kernel yang kecil.

Nilai akurasi maksimum peletakan *smartphone* pada saku celana diperoleh menggunakan algoritme tipe *quadratic SVM* dengan nilai akurasi sebesar 95,67%. Tabel 4 menunjukkan hasil uji akurasi klasifikasi oleh algoritme *quadratic SVM* untuk gerakan/aktivitas duduk (A1), berdiri (A2), berbaring (A3), berjalan (A40), berlari (A5), aktivitas lainnya (A6), dan gempabumi (GB). Kesalahan klasifikasi terutama disebabkan oleh sebagian aktivitas manusia yang diprediksi sebagai aktivitas lainnya, yaitu *smartphone* dianggap dipegang oleh tangan secara bebas, terutama pada aktivitas berbaring, berjalan dan berlari. Selain itu, terdapat

Tabel 4. Matrik konfusi *quadratic SVM*

	Prediksi							Recall	
	A1	A2	A3	A4	A5	A6	GB		
Aktual	A1	102	1	0	0	0	6	0	0,94
	A2	1	119	0	1	0	4	0	0,95
	A3	0	2	143	0	0	22	0	0,86
	A4	0	0	0	439	0	32	0	0,93
	A5	0	0	0	4	290	25	0	0,91
	A6	0	0	0	5	4	1130	0	0,99
	GB	1	0	0	0	0	2	212	0,99
Presisi	0,98	0,98	1	0,98	0,99	0,93	1	0,96	

aktivitas berlari yang diprediksi sebagai aktivitas berjalan sebanyak 4 data. Hal ini disebabkan oleh kemiripan fitur data-data tersebut sehingga menjadi relatif sulit dibedakan.

Sementara itu, nilai akurasi maksimum peletakan *smartphone* pada saku baju diperoleh menggunakan algoritme tipe *cubic SVM* dengan nilai akurasi sebesar 97,94%. Tabel 5 merupakan matriks konfusi hasil klasifikasi oleh algoritme *cubic SVM* untuk gerakan/aktivitas duduk (A1), berdiri (A2), berbaring (A3), berjalan (A4), berlari (A5), aktivitas lainnya (A6), dan gempa bumi (GB). Penyebab kesalahan klasifikasi hampir sama dengan peletakan *smartphone* pada saku celana. Namun demikian, secara umum algoritme SVM mampu mengklasifikasikan sinyal percepatan linier aktivitas manusia dan sinyal percepatan gempa bumi dengan baik. Hampir seluruh data sinyal percepatan akibat gempa bumi dapat dipilah secara tepat, yaitu 212 dari 214 data sinyal gempa bumi.

Fitur nilai percepatan linear aktivitas cenderung meningkat saat subjek mencapai usia remaja dan menurun saat subjek mencapai usia dewasa atau lansia. Fitur aktivitas pria cenderung lebih besar dibanding nilai fitur aktivitas perempuan. Korelasi ini bersesuaian dengan teori bahwa jenis kelamin, tinggi dan massa badan seseorang berpengaruh terhadap tingkat kelincahannya dalam beraktivitas. Pergerakan kaki lebih dominan dibanding pergerakan badan saat manusia beraktivitas. Pengumpulan data aktivitas juga mempertimbangkan kemungkinan posisi *smartphone* dalam saku. Posisi *smartphone* cenderung tidak berpengaruh signifikan terhadap proses ekstraksi fitur data karena posisi hanya mempengaruhi nilai percepatan gravitasi *smartphone* yang sudah diredam oleh *highpass* filter gravitasi tipe Butterworth orde 3 dengan frekuensi *cut-off* 0,1 Hz.

Penelitian ini bersesuaian dengan penelitian sebelumnya bahwa implementasi HAR menggunakan algoritme SVM memiliki akurasi lebih dari 85%. Tipe algoritme SVM yang digunakan sebagaimana dalam Anguita dkk. [12], mencapai akurasi lebih optimal jika menggunakan *hyperplane* algoritme SVM yang bersifat nonlinear. Namun, akurasi SVM tidak lebih tinggi apabila dibandingkan terhadap algoritme *Deep Learning Neural Network* yang dimanfaatkan oleh Ronao dan Cho [7] karena penelitian ini tidak terbatas pada pengenalan aktivitas manusia saja, melainkan juga

Tabel 5. Matrik konfusi *cubic SVM*

	Prediksi							Recall	
	A1	A2	A3	A4	A5	A6	GB		
Aktual	A1	101	0	0	1	0	3	0	0,96
	A2	1	108	0	0	0	4	0	0,96
	A3	0	1	164	0	0	5	0	0,96
	A4	0	0	0	438	0	11	0	0,98
	A5	0	0	0	4	231	7	0	0,95
	A6	0	0	0	5	6	1126	0	0,99
	GB	0	0	0	0	0	2	212	0,99
Presisi	0,99	0,99	1	0,98	0,97	0,97	1	0,98	

mencakup pengenalan sinyal gempa bumi sehingga proses klasifikasi cenderung lebih kompleks.

Secara keseluruhan tingkat akurasi SVM lebih tinggi tetapi membutuhkan kapasitas memori besar dan waktu pemrosesan yang lebih lama. *Hyperplane SVM* yang dibangun memuat variabel yang lebih banyak dibanding algoritme lainnya. Data sinyal percepatan linier aktivitas manusia dan sinyal percepatan gempa bumi dapat diklasifikasikan secara baik menggunakan algoritme SVM berkernel polinomial atau Gaussian dengan nilai skala kernel yang kecil.

IV. KESIMPULAN

Algoritme tipe *quadratic SVM* dalam *Human Activity Recognizer* memiliki akurasi tertinggi, yaitu 95,67% untuk peletakan *smartphone* dalam saku celana. Algoritme tipe *cubic SVM* memiliki akurasi tertinggi, yaitu 97,94% untuk peletakan *smartphone* dalam saku baju. Penambahan jumlah subyek dan jenis aktivitas manusia dalam proses pengumpulan data dapat dilakukan untuk meningkatkan tingkat akurasi algoritme *classifier* karena masih terdapat banyak kemungkinan pergerakan *smartphone* akibat aktivitas manusia selain kegiatan duduk, berdiri, berbaring, berjalan dan berlari.

DAFTAR PUSTAKA

- [1] H. Salahuddin, "Bencana gempa bumi," in *DRR Action Plan Workshop: Strengthened Indonesian Resilience: Reducing Risk from Disasters*, Yogyakarta, Indonesia, Jan. 2016. doi: [10.13140/RG.2.1.1112.6808](https://doi.org/10.13140/RG.2.1.1112.6808)
- [2] M. A. Massinai, K. R. Amaliah, L. Lantu, Virman, and M. F. Ismullah, "Analisis percepatan tanah maksimum, kecepatan tanah maksimum dan mmi di wilayah Sulawesi Utara," in *Seminar Nasional Fisika SNF-UNJ*, Jakarta, Indonesia, Oct. 2016, pp. 33-36. doi: [10.21009/0305020407](https://doi.org/10.21009/0305020407)
- [3] R. M. Taruna, S. Rohadi, A. Rudyanto, and D. T. Heryanto, "Penentuan ground motion prediction equations (GMPEs) dengan metode euclidean dan likelihood untuk wilayah Jawa Timur," *Jurnal Meteorologi dan Geofisika*, vol. 17, no. 3, pp. 177-189, 2016.
- [4] C. Sulaeman and A. Cipta, "Model intensitas gempa bumi di Maluku Utara," *Jurnal*

- Lingkungan dan Bencana Geologi*, vol. 3 no. 2, pp. 79-88, 2012.
- [5] W. Wang, A. X. Liu, M. Shahzad, K. Ling, and S. Lu, "Device-free human activity recognition using commercial wifi devices," *IEEE Journal on Selected Areas in Communications*, vol. 35 no. 5, pp. 1118-1131, 2017. doi: [10.1109/JSAC.2017.2679658](https://doi.org/10.1109/JSAC.2017.2679658)
- [6] O. C. Ann and L. B. Theng, "Human activity recognition: a review," in *IEEE International Conference on Control System, Computing and Engineering*, Penang, Malaysia, Nov. 2014, pp. 389-393. doi: [10.1109/ICCSCE.2014.7072750](https://doi.org/10.1109/ICCSCE.2014.7072750)
- [7] S. A. Ronao and S. B. Cho, "Human activity recognition with smartphone sensors using deep learning neural networks," *Expert System With Application*, vol. 59, pp. 235-244, 2016. doi: [10.1016/j.eswa.2016.04.032](https://doi.org/10.1016/j.eswa.2016.04.032)
- [8] F. Attal, S. Mohammed, M. Dedabrishvili, F. Chamroukhi, L. Oukhellou, and Y. Amirat, "Physical human activity recognition using wearable sensors," *Sensors*, vol. 15, no. 12, pp. 31314-31338, 2015. doi: [10.3390/s151229858](https://doi.org/10.3390/s151229858)
- [9] F. J. Ordonez, and D. Roggen, "Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition," *Sensors*, vol. 16, no. 1, pp. 1-25, 2016. doi: [10.3390/s16010115](https://doi.org/10.3390/s16010115)
- [10] A. R. Musthafa and H. Tjandrasa, "Kombinasi sinyal EEG dan giroskop untuk kendali mobil virtual dengan menggunakan modifikasi ICA dan SVM," *Jurnal Buana Informatika*, vol. 7, no. 3, pp. 169-178, 2016. doi: [10.24002/jbi.v7i3.655](https://doi.org/10.24002/jbi.v7i3.655)
- [11] L. H. Ochoa, L. F. Nino, and C. A. Vargas, "Fast determination of earthquake depth using seismic records of a single station, implementing machine learning techniques," *Ingeniería e Investigación*, vol. 38, no. 2, pp. 91-103, 2018. doi: [10.15446/ing.investig.v38n2.68407](https://doi.org/10.15446/ing.investig.v38n2.68407)
- [12] D. Anguita, A. Ghio, and L. Oneto, "A public domain dataset for human activity recognition using smartphones," in *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, Bruges, Belgium, Apr. 2013, pp. 437-442.
- [13] A. Perdana, M. T. Furqon, and Indriati, "Penerapan algoritma support vector machine (SVM) pada pengklasifikasian penyakit kejiwaan skizofreni," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 9, pp. 3162-3167, 2018.
- [14] M. Hassouna, A. Tarhini, T. Elyas, and M. S. A. Trab, "Customer churn in mobile markets: a comparison of techniques," *International Business Research*, vol. 8, no. 8, pp. 224-237, 2015. doi: [10.5539/ibr.v8n6p224](https://doi.org/10.5539/ibr.v8n6p224)