

Pengenalan Aktivitas Manusia Melalui Analisis Data Gerakan *Smartphone*

Eunike Endariahna S¹, Andes Suciani², Philipus Silaen³, Septian Adiwibowo⁴

^{1,2,3,4}Fakultas Ilmu Komputer, Program Studi Magister Teknologi Informasi, Universitas Indonesia, Jakarta, Indonesia

¹Fakultas Teknik dan Informatika, Program Studi Informatika, Universitas Multimedia Nusantara, Tangerang, Indonesia

¹eunike.endahriana@umn.ac.id, ²andes.suciani@ui.ac.id, ³philipus.silaen@ui.ac.id, ⁴septian.adibowo@ui.ac.id

Diterima 18 Mei 2021

Disetujui 16 Juni 2021

Abstract— Technology whose benefits are felt by humans from the development of cellular telephones is the birth of smart phones or *smartphones*. The development of *smartphone* integration is growing very rapidly. Today's *smartphones* are not only communication tools but now offer many features and deployment of sensors. *Smartphones* are also designed to track the user's daily activities, learn and then help the user to make better decisions about what the user will take in the future. Applications that utilize the movement of a *smartphone* to analyze human activity are used by the Moves app, Fitbit Charge, Nike Fuelband, Apple Watch Health app. To perform human motion *recognition* activities, data is generated and collected from *smartphones* such as iPhones and Androids, or wearables such as the Apple Watch *smartwatch*, Nike Fuelband, and Fitbit Charge. Today the technology industry has succeeded in producing good quality devices at low prices. Sensors commonly used to collect data include an *accelerometer*, *gyroscope*, heart rate monitor, and thermometer. This study collects and manages data from the use of sensors on *smartphones*. The resulting data also combines these sensors with a magnetometer and GPS. So that we can find out the position, distance and number of points from using smart devices. The resulting data is very large, fast and real time data or what is called big data. Then these large data sets can produce complex and unstructured data. The processing requires more difficult and large computations and storage to produce useful data sets. The resulting benefits can provide problem solutions, business benefits and even new business opportunities. The resulting data can be used to seek opportunities for the benefits of human movement. The tangible benefits that can be provided are *Monitoring* city prisoners for government, community grouping, city density detection and distribution maps that can be used by business opportunities such as retail or banks.

Index Terms—*Accelerometer*, *Big Data Analytics*, *Human Movement Recognition Activity*, *Gyroscope*, *Heart Rate Monitor*, *Thermometer*.

I. PENDAHULUAN

Tujuan dari diciptakannya teknologi adalah memberikan kemudahan dan kenyamanan untuk membantu manusia. Salah satu teknologi yang

manfaatnya sangat dirasakan oleh manusia dari perkembangan telepon seluler adalah lahirnya telepon pintar atau *smartphone*. Di awal tahun 2000, belum banyak yang memiliki telepon pintar di Indonesia. Ketika itu, telepon pintar masih dianggap sebagai keperluan sekunder bahkan tersier oleh sebagian kalangan. Kini keadaannya telah berbeda, telepon pintar telah berubah menjadi kebutuhan primer yang dimiliki oleh setiap orang. Di Indonesia sendiri, negara ini berada di urutan ke enam dengan jumlah penduduknya diperkirakan sebanyak 261 juta jiwa, telah menggunakan telepon sebanyak 236 juta unit [1].

Telepon pintar kini menawarkan banyak fitur lain seperti multitasking dan penyebaran berbagai sensor, di samping sebagai alat komunikasi. Integrasi perangkat mobile ini dalam kehidupan kita sehari-hari berkembang pesat. *Smartphone* juga dirancang untuk melacak kegiatan penggunaannya setiap hari, belajar dan kemudian membantu pengguna untuk membuat keputusan yang lebih baik mengenai tindakan yang dilakukan pengguna di masa mendatang [2]. Dengan memanfaatkan gerakan dari *smartphone* untuk menganalisa aktivitas manusia yang digunakan oleh Moves app, Fitbit Charge, Nike Fuelband, Apple Watch Health app.

Aplikasi-aplikasi ini mendapatkan data dari jenis sensor terdapat pada *smartphone* seperti *accelerometer*, *gyroscope*, sensor tekanan, sensor cahaya. *Accelerometer* merupakan sensor yang sudah menjadi fitur standar atau harus ada dari *smartphone*. *Accelerometer* merupakan elemen sensor yang mengukur percepatan, sudut kemiringan, tahanan, rotasi, benturan, vibrasi dan gravitasi. Kegunaannya bisa mendukung berbagai kegiatan pengguna seperti: membaca, bermain game, olahraga dan berbagai aktivitas lainnya. Contohnya adalah Moves app dari gerakan yang dihasilkan pengguna, aplikasi ini bisa mengetahui pengguna sedang jalan, lari pelan, lari sprint, bersepeda, naik tangga, turun tangga, naik kendaraan bermotor atau sedang dalam perjalanan di pesawat. Keuntungan dari data yang diolah aplikasi ini

membantu pengguna dalam meningkatkan kesehatan seperti menghitung jumlah langkah setiap hari. Pengguna dapat melacak area yang sudah ditempuh saat berolahraga atau pun lokasi yang dia datangi setiap harinya. Berikut Gambar 1. adalah perbandingan Moves app dengan aplikasi fitness lainnya:

	Moves	Gadgets Nike+ Fuelband, Fitbit, etc.	Tracker apps Nike+ Running, Runkeeper, Runastic, etc.
Automatic activity type recognition	✓		
Calorie counter	✓	✓	✓
Routes on map	✓		✓
Daily storyline with places	✓		
No need to start and stop	✓	✓	
No need to charge and carry an extra device	✓		✓

Gambar 1. Perbandingan Moves App dengan Aplikasi Fitness Lainnya [3]

Dalam penelitian ini, kami akan meneliti lebih lanjut perkembangan data yang bisa dimanfaatkan dari gerakan *smartphone* oleh pengguna setiap harinya. Aktivitas manusia setiap harinya akan terus bertumbuh dan menjadi big data. Cara mendapatkan data dari sensor *smartphone* kemudian diolah menggunakan metode machine learning agar menghasilkan informasi yang lebih berguna untuk kedepannya.

II. METODE PENELITIAN

Untuk melakukan aktivitas pengenalan gerakan manusia, data dihasilkan dan dikumpulkan dari telepon pintar seperti iPhone dan Android, atau peralatan yang dapat dipakai seperti jam tangan pintar Apple Watch, Nike Fuelband, dan Fitbit Charge (Gambar 2) [4]. Sensor yang biasa digunakan untuk mengumpulkan data di antaranya adalah *accelerometer*, *gyroscope*, monitor detak jantung, dan termometer. Metode lain juga mengkombinasikan sensor-sensor ini dengan magnetometer dan GPS (*Global Positioning System*). [2]

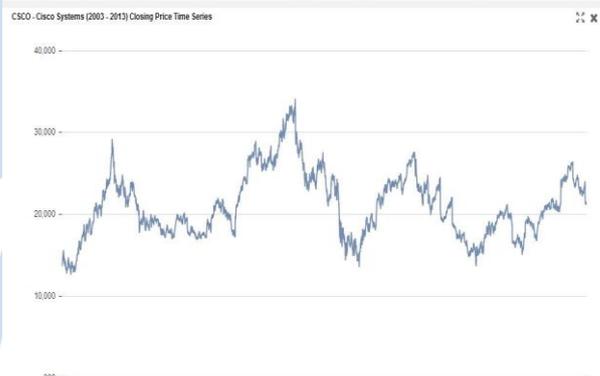


Gambar 2. Jam Tangan Pintar Fitbit Charge [5]

Data yang dihasilkan dari peralatan sensor ini berbentuk *time series* data, yaitu data yang berbentuk banyak titik data yang diurutkan berdasarkan ukuran waktu. *Time series* data ini diambil secara berurutan dengan rentang waktu atau frekuensi yang konsisten. Agar bisa mendapatkan konteks informasi, data jenis ini harus diperlakukan sebagai sebuah urutan data dan tidak bisa diperlakukan sebagai titik-titik data yang terpisah [6]. Contoh bentuk *time series* data yang umum digunakan adalah data pergerakan harga stok saham yang konteks informasinya baru bisa didapatkan apabila data ditampilkan dan diurutkan dalam suatu periode (Gambar 3).

Bab ini akan menjelaskan mengenai dua alat sensor utama yang digunakan untuk mengumpulkan data gerakan manusia, yaitu *accelerometer* dan *gyroscope* beserta contoh format data dari masing-masing peralatan tersebut. Berikutnya teknik-teknik pembersihan data (*data cleaning*) dan persiapan data (*data preparation*) yang umum dilakukan untuk kedua sensor ini akan dijabarkan. Pembahasan akan menitikberatkan ke riset utama yang dibahas di tulisan ini, yaitu penelitian dari Anguita, Ghio, Oneto, Llanas-Parra, & Reyes-Ortiz [2].

CSCO - Cisco Systems (2003 - 2013) Closing Price Time Series



Gambar 3. Time Series Data Pergerakan Harga Saham [7]

A. Accelerometer

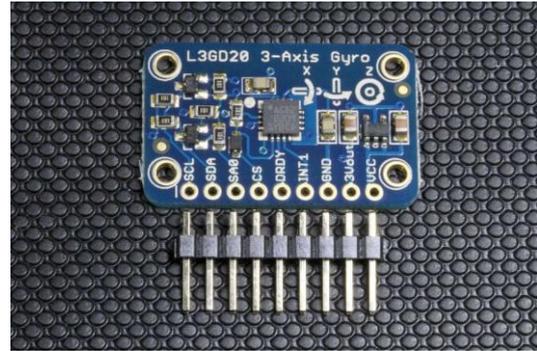
Accelerometer adalah alat untuk mengukur akselerasi atau percepatan, yaitu menghitung berapa banyak kecepatan suatu benda berubah dalam suatu rentang waktu [8]. Menggunakan prinsip tersebut, *accelerometer* bisa memberikan informasi mengenai perubahan arah dan pergerakan suatu benda.

Pada awalnya, *accelerometer* digunakan di pesawat luar angkasa (*space shuttle*) untuk mengukur perubahan kecepatan roket pesawat, mengukur *apogee* (ketika pesawat berada di titik terjauh dari bumi sehingga pengaruh akselerasi karena gravitasi berada di titik paling rendah), dan mengukur orientasi pesawat dengan cara mendeteksi sisi tekanan gravitasi bumi ketika pesawat berubah arah.

angkasa Hubble memiliki banyak *gyroscope* untuk menjaga orientasi mereka terhadap matahari [15].

Digital *gyroscope* (Gambar 7.) tidak memiliki roda bergerak, melainkan menggunakan 3 buah struktur *tuning fork* yang terbuat dari *silicon wafer*. Mereka akan bergetar bila distimulasi dengan sinyal elektrik. Ketika sumbu pergerakan benda diputar, *tuning fork* ini akan merasakan tekanan dikarenakan gaya Coriolis. Perbandingan tekanan ini proporsional dengan kecepatan rotasi benda. Ketiga buah *tuning fork* ini disusun secara ortogonal masing-masing untuk merepresentasikan sumbu X, Y, dan Z. Perputaran *gyroscope* akan direpresentasikan ke dalam data rotasi *degrees-per-second* untuk masing-masing sumbu tersebut [9] Sama seperti *accelerometer* yang pengambilan datanya menggunakan pola frekuensi, data yang dihasilkan dari *gyroscope* juga berbentuk *time series* data.

Meskipun sekilas mirip, perbedaan utama antara *accelerometer* dengan *gyroscope* adalah *accelerometer* tidak dapat mendeteksi rotasi. *Accelerometer* berguna untuk mendeteksi perpindahan, tetapi *gyroscope* bisa mendeteksi apabila rotasi terjadi tanpa perpindahan (hal yang tidak bisa dideteksi oleh *accelerometer*). Penggunaan keduanya secara bersamaan di *smartphone* dan *smartwatch* dalam frekuensi yang sama akan melengkapi satu sama lain untuk menghasilkan *dataset* yang bisa dianalisis dalam pengenalan aktivitas manusia.



Gambar 7. Digital Gyroscope [16]

C. Koleksi dan Pembersihan Data

Pada Riset Anguita, Ghio, Oneto, Llanas-Parra, & Reyes-Ortiz uji coba dilakukan dengan membuat dan mengembangkan *dataset* pengenalan aktivitas manusia dengan total sukarelawan yang berpartisipasi yaitu 30 orang dengan usia 19 hingga 48 tahun [2]. Penelitian dilakukan dengan mengumpulkan rangkaian gerakan yang terdiri dari 6 usulan Activities of Daily Living (ADL) (berdiri, duduk, berbaring, berjalan, berjalan ke atas dan berjalan turun). Setiap subjek melakukan protokol percobaan dua kali, dan setiap aktivitas setidaknya dilakukan dua kali pada setiap percobaan untuk mensimulasikan pengulangan.

Tabel 1. Protokol Percobaan [2]

No.	Static	Time (sec)	No.	Dynamic	Time (sec)
0	Start (Standing Pos)	0	7	Walk (1)	15
1	Stand (1)	15	8	Walk (2)	15
2	Sit (1)	15	9	Walk Downstairs (1)	12
3	Stand (2)	15	10	Walk Upstairs (2)	12
4	Lay Down (1)	15	11	Walk Downstairs (1)	12
5	Sit (2)	15	12	Walk Upstairs (2)	12
6	Lay Down (2)	15	13	Walk Downstairs (3)	12
			14	Walk Upstairs (3)	12
			15	Stop	0
				Total	192

Basis data yang diperoleh dipartisi menjadi data pelatihan dan data tes dalam proporsi 70% hingga 30%. Partisi diacak tetapi dipastikan bahwa tidak ada sampel yang berasal dari pengguna yang sama di kedua himpunan bagian. Data pelatihan digunakan untuk melatih *Multiclass SVM classifiers*. Percobaan diimplementasikan menggunakan *smartphone* Samsung Galaxy S II dilengkapi dengan baterai Li-Ion 1650 mAh dengan pengoperasian siaga hingga 610 jam dan sistem operasi Android *Gingerbread* versi 2.3.4.

Smartphone yang digunakan menggunakan *accelerometer*. Sinyal akselerasi dicatat pada frekuensi konstan 50Hz yang cukup cepat untuk memperoleh informasi gerak tubuh manusia. Proses pelabelan dilakukan manual dengan memilih video yang direkam dari percobaan sebagai kebenaran dasar dan membandingkannya dengan *file log* dari sinyal inersia.



Gambar 8. Pipa Proses Activity Recognition

III. HASIL DAN PEMBAHASAN

Penelitian dengan judul “Energy Efficient Smartphone-Based Activity Recognition using Fixed-point Arithmetic” [2] bertujuan untuk menerapkan aritmatika *fixed-point* untuk mengusulkan algoritma pembelajaran *Multiclass* Vector Machine yang dimodifikasi (SVM) yaitu dengan model *Multiclass* Hardware Friendly SVM (MC-HF-SVM) dengan *dataset* yang telah dibahas pada Bab 2. Berikut adalah langkah-langkah dalam model *Multiclass* HF-SVM (MC-HF-SVM):

1. Menyelesaikan masalah minimalisasi *Constrained Quadratic Programming* (CQP) dengan cara menggunakan Lagrange *multipliers* α_i . Representasi tersebut mempunyai nama lain yaitu *dual formulation* dengan rumus yaitu:

$$\min_{\alpha} \frac{1}{2} \alpha^T Q \alpha - r^T \alpha$$

$$0 \leq \alpha_i \leq C \forall i \in [1, \dots, l], y^T \alpha = 0 \quad (1)$$

Dimana Q adalah matriks kernel dan sebuah *semidefinite* positif simetris $l \times l$ matrix dimana $q_{ij} = y_i y_j K(x_i, x_j)$.

2. Setelah didapatkan pola yang baru maka dapat dilakukan SVM Feed-Forward Phase (FFP) dengan rumus:

$$f(x) = \sum_{i=1}^l y_i \alpha_i K(x_i, x) + b. \quad (2)$$

3. Kemudian karena adanya isu bahwa hasil yang diperoleh tidak valid dalam penggunaan *fixed-point arithmetic* karena nilai α_i masuk ke dalam kelompok bilangan real yang dibatasi antara 0 dan C, maka dilakukanlah proses normalisasi tanpa mempengaruhi tanda *output*

dari *classifier*-nya tetapi justru besarnya dan membuat akurasi dari SVMnya tetap sama. Rumus normalisasinya yaitu:

$$\beta_i = \alpha_i \frac{2^k - 1}{C} \quad (3)$$

4. Kemudian karena parameter dari *dataset* penelitian ini berupa *integer* dilakukanlah modifikasi rumus menjadi seperti berikut :

$$\begin{aligned} \min_{\beta} \frac{1}{2} \beta^T Q \beta - s^T \beta \text{ s.t. } 0 \leq \beta_i \\ \leq \frac{2^k - 1}{C} \forall i \in [1, \dots, l] \end{aligned} \quad (4)$$

5. Untuk akhirnya memiliki FFP penuh dengan hanya nilai *integer*, perlu dilakukan perubahan representasi dari kernel $K(\cdot, \cdot)$ dan vektor input x dalam hal jumlah bit (u dan v bit masing-masing). Perubahan representasi ini menghasilkan rumus:

$$0 \leq K(x_i, x) \leq 1 - 2^{-u} \forall i \in [1, \dots, l],$$

$$0 \leq x_i \leq 1 - 2^{-v} \forall i \in [1, \dots, m]. \quad (5)$$

Jika digabungkan maka berikut rumus vektor *fixed-point* FFP yang sudah dimodifikasi :

$$f(x) = \sum_{i=1}^l y_i \beta_i K(x_i, x) \quad (6)$$

6. Untuk memperluas masalah biner menjadi masalah *Multiclass*, digunakan metode OVA untuk membandingkan masing-masing kelas c terhadap kelas-kelas lain, tetapi sebelumnya sebuah prosedur untuk memungkinkan perbandingan dalam kelompok pengklasifikasi SVM diperlukan. Hasilnya, dilakukan pengukuran perkiraan probabilitas

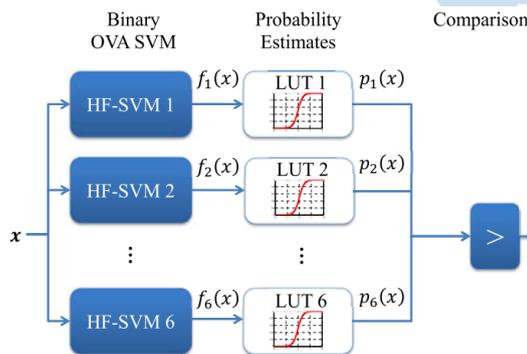
untuk setiap PC SVM (x) dan memilih kelas aktual c^* sebagai probabilitas *output* tertinggi untuk sampel uji yang diberikan

7. Kemudian *probability estimation* yang sudah didapatkan akan di implementasi menggunakan pendekatan dimana training set dan model SVM diberlakukan agar sesuai dengan nilai *output* FFP $f(x)$ dengan fungsi sigmoid dari rumus berikut :

$$p(x) = \frac{1}{1 + e^{(\Gamma f(x) + \Delta)}} \quad (7)$$

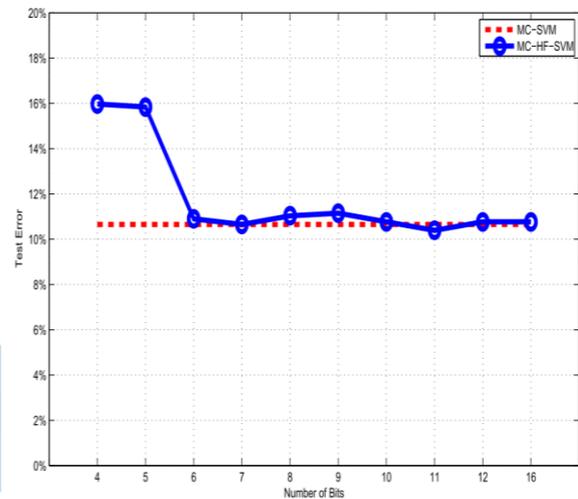
Dimana $p(x)$ adalah perkiraan probabilitas, dan Γ dan Δ adalah parameter fungsi yang dipasang dengan benar pada sampel pembelajaran yang tersedia.

8. Lalu dengan mempertimbangkan batasan aritmatik *fixed-point*, maka fungsi sigmoid yang juga bekerja dengan bilangan real, tidak dapat langsung digunakan untuk memperkirakan $p(x)$. Isu ini dapat diselesaikan dengan menggunakan Look-Up-Tables (LUTs). Pertama, sejumlah tetap bit t harus didefinisikan dan kemudian perkiraan probabilitas $p(x)$ dapat dipetakan dengan $f(x)$ tanpa perlu aritmatika *floating-point*. Proses MC-HF-SVM secara lengkap diilustrasikan dalam gambar 9.



Gambar 9. MC-HF-SVM Menggunakan LUT Untuk Probability Estimates [2]

Kemudian dari langkah-langkah tersebut menunjukkan bahwa $t = 8$ adalah nilai yang cocok untuk aplikasi ini dan hanya dibutuhkan LUT dengan 256 elemen. Lalu dilakukan evaluasi dengan membandingkan hasil *error rates* dan hasil *classification* pada test data dari MC-HF-SVM dan MC-SVM. Berikut perbandingan hasil *error rates* yang didapatkan dari kedua pendekatan tersebut dengan *range bits* dari k antara 4 sampai 16 bits:



Gambar 17. Perbandingan Antara Tingkat Kesalahan yang Diperoleh Dengan MC-SVM (Garis Putus-Putus Merah) dan MC-HF-SVM (Garis Biru) Karena k Bervariasi [2]

Dari tes yang dilakukan pada bits ke 6 sampai 16 test *error* yang ada cukup stabil (hampir 1 % variasi). Ketika test dilakukan pada bits dibawah 6 maka test *error* naik secara signifikan sebanyak kira-kira dua kali lipat. Selain itu, juga terlihat dari grafik bahwa beberapa test *error* dengan pendekatan *fixed-point* lebih kecil dari yang ditemukan dengan pendekatan MC-SVM Kemudian perbandingan hasil *classification* dari kedua pendekatan tersebut dengan menggunakan $k=8$ bits dapat dilukiskan melalui tabel berikut:

Tabel 2. Confusion matrix Dari Hasil Classification Pada Test Data Menggunakan MC-SVM dan MC-HF-SVM

Method	MC-SVM							MC-HF-SVM $k = 8$ bits						
	Walking	Upstairs	Downstairs	Standing	Sitting	Laying	Recall %	Walking	Upstairs	Downstairs	Standing	Sitting	Laying	Recall %
Walking	109	0	5	0	0	0	95.6	109	2	3	0	0	0	95.6
Upstairs	1	95	40	0	0	0	69.8	1	98	37	0	0	0	72.1
Downstairs	15	9	119	0	0	0	83.2	15	14	114	0	0	0	79.7
Standing	0	5	0	132	5	0	93.0	0	5	0	131	6	0	92.2
Sitting	0	0	0	4	108	0	96.4	0	1	0	3	108	0	96.4
Laying	0	0	0	0	0	142	100	0	0	0	0	0	142	100
Precision %	87.2	87.2	72.6	97.1	95.6	100	89.3	87.2	81.7	74.0	97.8	94.7	100	89.0

(Sumber: Anguita, Ghio, Oneto, Llanas-Parra, & Reyes-Ortiz, 2013)

Tabel 2. merupakan *Confusion matrix* dari hasil *classification* pada test data menggunakan *traditional floating point* MC-SVM (kiri) dan MC-HF-SVM dengan $k = 8$ bits (kanan). Baris mewakili kelas yang sebenarnya dan kolom mewakili kelas yang terprediksi. Angka yang di bold secara diagonal menunjukkan jumlah sampel tes yang dengan benar diklasifikasikan. Pada tabel 2. dilakukan perbandingan yang mengukur keseluruhan dari *accuracy*, *recall* dan *precision* dari kedua pendekatan tersebut.

Variasi kecil diperhatikan dalam *recognition accuracy* dari aktivitas dinamis dalam dua pendekatan tersebut, seperti dalam kegiatan *walking downstairs* dan *walking upstairs*, yang juga menampilkan beberapa kesalahan *classification* terutama untuk kesamaan gerakan mereka. Aktivitas statis di sisi lain berkinerja lebih baik, seperti *laying*, *classification error* yang didapat sebesar 0%. Selain itu, ada kesalahan klasifikasi kecil yang ditemukan antara *standing* dan *sitting*, yang dikaitkan dengan lokasi fisik telepon seluler pintar yang dipasang di pinggang dan kesulitan untuk membedakan di antara kedua aktivitas tersebut.

Hasil dari penelitian ini yaitu model *Multiclass SVM* standar yang dapat diubah dengan representasi *fixed-point* yang lebih efisien. Keuntungan dari penerapan model yang diusulkan dibandingkan dengan pendekatan tradisional SVM yang lain yaitu waktu proses yang lebih cepat, dan penggunaan sumber daya sistem yang lebih sedikit dimana hasilnya memberikan penghematan dalam konsumsi energi baterai perangkat dan juga kemungkinan untuk menggunakan pendekatan ini pada perangkat dengan harga murah (misalnya perangkat keras *fixed-point*).

IV. KESIMPULAN

Sistem pengenalan aktivitas manusia dikembangkan sebagai bagian dari kerangka kerja untuk memungkinkan pemantauan terus menerus perilaku manusia di bidang kehidupan dibantu lingkungan, deteksi cedera olahraga, perawatan lansia, rehabilitasi, hiburan dan pengawasan di lingkungan rumah pintar. Proses pembelajaran mesin yang relevan adalah bagian yang paling menantang dari pengenalan aktivitas manusia yang dapat diaktifkan dan berdasarkan sensor. Metode yang digunakan juga berbagai macam dalam mengolah data.

Berdasarkan metode cara pembelajaran mengelola data aktivitas manusia, jika ingin dikembangkan teknologi ini bisa diterapkan pada:

1. *Monitoring* tahanan kota, tahanan kota yang ditahan tidak boleh meninggalkan satu kota yang menjadi tempat penahanannya. Pengawasannya, tahanan wajib melapor dua kali dalam seminggu. Dengan memberikan alat pendeteksi aktivitas

- manusia ini, membantu kepolisian dalam *monitoring* keberadaan tahanan setiap waktu.
2. *Monitoring* Orang Tanpa Gejala (OTG) penderita COVID-19 yang melakukan isolasi mandiri. Dengan pengawasan ini, OTG dapat dipantau posisinya. Jika keluar dari area yang di ijin maka sensor pada *smartwatch* memberikan notifikasi peringatan awal atau memberitahukan tim medis yang bertanggung jawab dalam *monitoring* pasien yang melakukan isolasi mandiri.
3. Pendeteksian komunitas, adalah cara untuk memahami struktur jaringan yang kompleks, untuk akhirnya mengekstrak informasi yang berguna yang bisa didapatkan. Aplikasi beragam mulai dari perawatan, kesehatan, geografi regional, interaksi manusia, mobilitas hingga ekonomi [17][18].
4. Kepadatan kota dan peta distribusi, informasi yang diperoleh mengetahui titik dimana orang banyak berkumpul. Dari aktivitas yang mereka lakukan, kita dapat informasi bukan hanya gender, tetapi rentang usia, dan kapan tanggal aktivitas ini dilakukan. Pola yang didapatkan ini dapat digunakan untuk dijual kepada pelaku bisnis seperti Warunk Upnormal, Indomaret, Alfamart, pom bensin dan lain lain dalam membuka cabang baru.
5. Di tengah kondisi pandemi ini, kita bisa mendeteksi kerumunan padat suatu daerah sehingga bisa dicapai langkah awal pembubaran masa. Selain itu pendeteksian suhu, detak jantung, tekanan darah dan alat vital lainnya di tubuh manusia dapat diketahui dengan penggunaan sensor pada *smartwatch* dan terintegrasi pada *smartphone*. Mendeteksi alat vital pasien dengan menggunakan sensor dapat mengurangi kontak fisik antara pasien dengan dokter dan tim medis. Data alat vital pasien menjadi syarat awal ketika ingin melakukan pemeriksaan lebih lanjut. Pendeteksian ini juga bisa membantu mengurangi tingkat penyebaran virus COVID 19.

DAFTAR PUSTAKA

- [1] A. T. Sahlol, P. Kollmannsberger, and A. A. Ewees, "Efficient *Classification* of White Blood Cell Leukemia with Improved Swarm Optimization of *Deep* Features," *Sci. Rep.*, vol. 10, no. 1, pp. 1–11, 2020, doi: 10.1038/s41598-020-59215-9.
- [2] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [3] A. S. Lundervold and A. Lundervold, "An overview of *deep* learning in medical imaging focusing on MRI," *Z. Med. Phys.*, vol. 29, no. 2, pp. 102–127, 2019, doi: 10.1016/j.zemedi.2018.11.002.
- [4] L. D. Nguyen, D. Lin, Z. Lin, and J. Cao, "Deep CNNs for microscopic image *classification* by exploiting *transfer*

- learning and feature concatenation,” *Proc. - IEEE Int. Symp. Circuits Syst.*, vol. 2018-May, pp. 3–7, 2018, doi: 10.1109/ISCAS.2018.8351550.
- [5] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
- [6] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual learning for image recognition,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-December, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [7] C. Szegedy *et al.*, “Going deeper with convolutions,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 07-12-June-2015, pp. 1–9, 2015, doi: 10.1109/CVPR.2015.7298594.
- [8] O. Russakovsky *et al.*, “ImageNet Large Scale Visual Recognition Challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, 2015, doi: 10.1007/s11263-015-0816-y.
- [9] H. C. Shin *et al.*, “Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer learning,” *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1285–1298, 2016, doi: 10.1109/TMI.2016.2528162.
- [10] T. Pansombut, S. Wikaisuksakul, K. Khongkrapan, and A. Phon-On, “Convolutional neural networks for recognition of lymphoblast cell images,” *Comput. Intell. Neurosci.*, vol. 2019, 2019, doi: 10.1155/2019/7519603.
- [11] A. Çınar and S. A. Tuncer, “Classification of lymphocytes, monocytes, eosinophils, and neutrophils on white blood cells using hybrid Alexnet-GoogleNet-SVM,” *SN Appl. Sci.*, vol. 3, no. 4, pp. 1–11, 2021, doi: 10.1007/s42452-021-04485-9.
- [12] A. Kensert, P. J. Harrison, and O. Spjuth, “Transfer learning with Deep Convolutional Neural Networks for Classifying Cellular Morphological Changes,” *SLAS Discov.*, vol. 24, no. 4, pp. 466–475, 2019, doi: 10.1177/2472555218818756.
- [13] H. M. Ahmad, S. Ghuffar, and K. Khurshid, “Classification of Breast Cancer Histology Images Using Transfer learning,” *Proc. 2019 16th Int. Bhurban Conf. Appl. Sci. Technol. IBCAST 2019*, pp. 328–332, 2019, doi: 10.1109/IBCAST.2019.8667221.
- [14] S. Hosseinzadeh Kassani and P. Hosseinzadeh Kassani, “A comparative study of deep learning architectures on melanoma detection,” *Tissue Cell*, vol. 58, no. April, pp. 76–83, 2019, doi: 10.1016/j.tice.2019.04.009.
- [15] V. Maeda-Gutiérrez *et al.*, “Comparison of convolutional neural network architectures for classification of tomato plant diseases,” *Appl. Sci.*, vol. 10, no. 4, 2020, doi: 10.3390/app10041245.

