

KLASIFIKASI AKTIVITAS MANUSIA MENGGUNAKAN ALGORITME COMPUTED INPUT WEIGHT EXTREME LEARNING MACHINE DENGAN REDUKSI DIMENSI PRINCIPAL COMPONENT ANALYSIS

M. Sofyan Irwanto^{*1}, Fitra A. Bachtiar², Novanto Yudistira³

^{1,2,3}Universitas Brawijaya, Malang

Email: ¹sofyan17@student.ub.ac.id, ²fitra.bachtiar@ub.ac.id, ³yudistira@ub.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 15 September 2021, diterima untuk diterbitkan: 15 Desember 2022)

Abstrak

Salah satu bidang penelitian yang sangat penting yaitu pengenalan aktivitas manusia secara otomatis dikarenakan potensi penerapannya di berbagai bidang lain seperti pengawasan, lingkungan cerdas, maupun kesehatan. Dari berbagai pendekatan yang pernah dilakukan, teknik berbasis sensor diketahui lebih unggul daripada teknik lain seperti teknik berbasis visi komputer. Teknik berbasis sensor juga dapat dilakukan menggunakan ponsel cerdas, sehingga akan lebih dapat diterima dalam kehidupan sehari-hari. Meski begitu, pada penelitian terkait pengenalan aktivitas manusia menggunakan ponsel cerdas masih terdapat beberapa permasalahan, yaitu jumlah dimensi fitur yang tinggi serta keterbatasan prosesor yang ada pada ponsel cerdas untuk melakukan komputasi algoritme yang kompleks. Penelitian ini dilakukan untuk mengenali aktivitas sederhana seperti berjalan, menaiki tangga, menuruni tangga, duduk, berdiri, dan berbaring. Data yang digunakan pada penelitian ini adalah data sekunder dengan jumlah data sebanyak 10299 baris data dan 561 fitur. Dimensi fitur dari data tersebut direduksi menggunakan Principal Component Analysis (PCA) agar jumlah fiturnya berkurang. Data hasil reduksi dimensi tersebut kemudian digunakan untuk melakukan klasifikasi menggunakan Computed Input Weight Extreme Learning Machine (CIW-ELM). Pada penelitian ini juga dilakukan pemilihan *hyperparameter* terbaik menggunakan Grid Search Cross Validation. *Hyperparameter* terbaik yang didapatkan untuk algoritme PCA adalah dengan nilai $k = 207$, serta untuk algoritme CIW-ELM adalah dengan jumlah *hidden neuron* = 600 dan fungsi aktivasi *sigmoid*. Hasil akurasi yang didapatkan adalah 0,957 dan rata-rata *f-measure* sebesar 0,958 dengan waktu pelatihan selama 0,57 detik.

Kata kunci: klasifikasi, aktivitas manusia, reduksi dimensi, principal component analysis, computed input weight extreme learning machine

CLASSIFICATION OF HUMAN ACTIVITY USING COMPUTED INPUT WEIGHT EXTREME LEARNING MACHINE ALGORITHM WITH PRINCIPAL COMPONENT ANALYSIS DIMENSIONALITY REDUCTION

Abstract

One of the most important areas of research is the automatic human activity recognition due to its potential application in various other fields such as surveillance, intelligent environment, and health. From the various approaches that have been carried out, sensor-based techniques are known to be superior to other techniques such as computer vision-based techniques. Sensor-based techniques can also be carried out using smartphones, making them more acceptable in everyday life. Even so, in research related to the introduction of human activities using smartphones, there are still some problems, namely the high number of feature dimensions and the limitations of the existing processors on smartphones to perform complex algorithmic computations. This study was conducted to identify simple activities such as walking, climbing stairs, descending stairs, sitting, standing, and lying down. The data used in this study is secondary data with a total of 10299 data lines and 561 features. The feature dimensions of the data are reduced using Principal Component Analysis (PCA) so that the number of features is reduced. The data from the dimension reduction is then used to classify using the Computed Input Weight Extreme Learning Machine (CIW-ELM). In this study, the best hyperparameter selection was also carried out using Grid Search Cross Validation. The best hyperparameter obtained for the PCA algorithm is with a value of $k = 207$, and for the CIW-ELM algorithm is the number of hidden neurons = 600 and the activation function is sigmoid. The accuracy results obtained are 0.957 and the average *f-measure* is 0.958 with a training time of 0.57 seconds.

Keywords: *classification, human activity, dimensionality reduction, principal component analysis, computed input weight extreme learning machine*

1. PENDAHULUAN

Pengenalan aktivitas manusia secara otomatis merupakan salah satu bidang penelitian yang sangat penting, karena potensi penerapannya di berbagai bidang lain seperti pengawasan, lingkungan cerdas, maupun kesehatan (Khan et al., 2010). Salah satu pendekatan yang dapat digunakan untuk melakukan pengenalan aktivitas manusia adalah dengan teknik berbasis sensor yang secara umum lebih unggul dibandingkan dengan teknik berbasis visi komputer karena tidak sensitif terhadap *noise*, murah, dan membutuhkan konsumsi daya yang lebih efisien (Bevilacqua et al., 2019). Penelitian terdahulu sudah mulai memanfaatkan ponsel cerdas untuk melakukan pengenalan aktivitas manusia, karena pada ponsel cerdas juga terdapat sensor seperti *gyroscope* dan *accelerometer*, sehingga pengguna tidak perlu memakai komponen sensor tambahan, serta tidak akan mengganggu dan lebih dapat diterima dalam kehidupan sehari-hari (Reiss et al., 2013).

Namun, penggunaan ponsel cerdas dalam melakukan pengenalan aktivitas manusia juga memiliki beberapa kekurangan. Ponsel cerdas memiliki kekurangan dalam melakukan komputasi algoritme yang kompleks. (Doewes et al., 2017). Selain itu, pada beberapa penelitian yang pernah dilakukan sebelumnya menunjukkan bahwa data hasil ekstraksi fitur dari sinyal yang ditangkap oleh sensor pada ponsel cerdas memiliki dimensi yang tinggi (Anguita et al., 2013; Garcia-Gonzalez et al., 2020; Micucci et al., 2017). Hal tersebut tentu akan semakin membuat komputasi menjadi semakin berat. Kerugian lain dari fitur dengan dimensi yang tinggi adalah adanya kemungkinan bahwa beberapa fitur tersebut tidak relevan dan tidak memberikan informasi baru untuk meningkatkan akurasi klasifikasi, atau bahkan malah membingungkan dalam proses klasifikasi sehingga akurasi yang didapatkan akan menurun (Zhang & Sawchuk, 2012).

Penelitian mengenai pengenalan aktivitas manusia menggunakan sensor yang terdapat pada ponsel cerdas sudah banyak sekali dilakukan. Penelitian pertama seperti yang dilakukan oleh Wang, et al (2016) yang menggunakan metode seleksi fitur gabungan dari metode filter dan wrapper (FW), serta algoritme Naïve Bayes dan K-Nearest Neighbors (KNN), dengan Naïve Bayes berhasil mendapatkan akurasi sebesar 90,1% menggunakan 74 fitur, sedangkan KNN hanya memperoleh akurasi sebesar 87,8% menggunakan 66 fitur. Kemudian Doewes, et al (2017) menggunakan metode minimum Redudancy Maximum Relevance (mRMR) sebagai seleksi fitur serta Support Vector Machine (SVM) dan menghasilkan akurasi tertinggi sebesar 96,54% menggunakan 480 fitur. Penelitian selanjutnya dilakukan oleh Junita & Bachtiar (2019) yang

menggunakan Information Gain untuk melakukan seleksi fitur dan algoritme Decision Tree C4.5 yang menghasilkan akurasi tertinggi sebesar 81% dengan menggunakan 90% dari jumlah fitur asli (561). Selain beberapa metode machine learning diatas, metode deep learning juga pernah digunakan untuk mengatasi permasalahan klasifikasi aktivitas manusia. Salah satu contoh nya adalah seperti yang dilakukan oleh Hernandez, et al (2019) yang menggunakan Bidirectional LSTM dan berhasil memperoleh akurasi sebesar 92,67% dengan 3 layer dan 175 nodes.

Namun, metode-metode yang disebutkan diatas masih memiliki kekurangan dalam hasil akurasi, kebutuhan sumber daya, serta kecepatan komputasi. Dengan mempertimbangkan kekurangan yang ada pada ponsel cerdas, banyaknya jumlah data, serta tingginya dimensi fitur yang ada pada data seperti yang ditunjukkan pada beberapa penelitian sebelumnya, maka diperlukan sebuah metode yang tidak terlalu kompleks yang dapat digunakan untuk mengurangi dimensi fitur dari sebuah *dataset* dengan tetap mempertahankan informasi penting yang ada pada data tersebut, sehingga beban komputasi yang diperlukan menjadi berkurang. Selain itu, dibutuhkan juga metode klasifikasi yang dapat digunakan untuk melakukan klasifikasi aktivitas manusia dengan tepat. Metode tersebut juga harus dapat berjalan dengan cepat agar dapat melakukan klasifikasi aktivitas manusia secara langsung.

Salah satu metode yang dapat digunakan untuk mengurangi dimensi fitur dari sebuah *dataset* adalah Principal Component Analysis (PCA) yang memiliki ide sederhana, yaitu mengurangi dimensi dari sekumpulan data dengan mempertahankan variabilitas sebanyak mungkin (Jolliffe & Cadima, 2016). Selain dapat menyederhanakan sekaligus mempercepat komputasi karena dapat mengurangi jumlah fitur yang ada, hasil reduksi dimensi dari PCA juga terbukti dapat meningkatkan akurasi dari sebuah algoritme klasifikasi (Wang et al., 2019). Kemudian untuk melakukan klasifikasi, salah satu algoritme yang dapat digunakan adalah Extreme Learning Machine (ELM) yang diketahui dapat menghasilkan generalisasi yang sangat baik dengan kecepatan pembelajaran yang sangat cepat (Huang et al., 2004). ELM juga cocok untuk digunakan pada *dataset* yang memiliki jumlah data yang besar dengan berhasil mengungguli algoritme Support Vector Machine (SVM) dan Random Forest (RF) (Ahmad et al., 2018). Pada penelitian lain, dikembangkan sebuah teknik inialisasi bobot pada ELM yang diberi nama Computed Input Weight Extreme Learning Machine (CIW-ELM) yang membuat algoritme tersebut membutuhkan lebih sedikit *hidden neuron* daripada ELM konvensional untuk menghasilkan akurasi yang

sama, sehingga akan lebih menyederhanakan dan mempercepat komputasi ketika digunakan pada *dataset* yang besar (Tapson et al., 2015). Oleh karena itu, pada penelitian ini akan menggunakan algoritme Principal Component Analysis (PCA) dan Computed Input Weight Extreme Learning Machine (CIW-ELM) untuk melakukan klasifikasi aktivitas manusia.

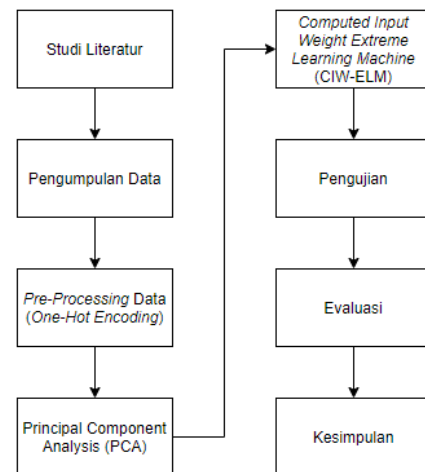
Data yang digunakan pada penelitian ini adalah data sekunder yang di ambil dari situs *UCI Machine Learning Repository*, yaitu data *Human Activity Recognition Using Smartphone Dataset* (Anguita et al., 2013). *Dataset* tersebut cukup populer dan banyak digunakan pada penelitian terkait pengenalan aktivitas manusia seperti beberapa penelitian yang disebutkan sebelumnya. Penelitian ini merupakan tahap awal dari pengembangan perangkat lunak untuk melakukan pengenalan aktivitas manusia menggunakan ponsel cerdas secara langsung. Tujuan dari penelitian ini adalah untuk mengetahui nilai hyperparameter terbaik pada masing-masing algoritme, serta menguji performa dari penggunaan kedua algoritme tersebut dalam melakukan klasifikasi aktivitas manusia. Penggunaan kedua algoritme tersebut diharapkan dapat menghasilkan akurasi yang lebih unggul, serta dapat mengatasi kelemahan-kelemahan yang ada pada metode sebelumnya. Jika penggunaan kedua algoritme ini sesuai dengan yang diharapkan, maka penelitian ini dapat dijadikan sebagai dasar untuk penelitian selanjutnya dalam melakukan pengenalan aktivitas manusia menggunakan ponsel cerdas secara langsung. Sehingga untuk penggunaan dalam skala kecil, pengguna tidak perlu lagi menggunakan komputer atau menyewa sebuah server untuk melakukan komputasi, melainkan cukup hanya menggunakan ponsel cerdas. Hal tersebut tentu akan lebih menghemat biaya yang dikeluarkan untuk diterapkan pada bidang pengawasan maupun kesehatan dalam skala kecil.

2. METODE PENELITIAN

Terdapat beberapa tahapan yang dilakukan untuk menyelesaikan permasalahan yang ada pada penelitian ini seperti yang ditunjukkan pada Gambar 1.

2.1. Studi Literatur

Studi literatur dilakukan dengan mempelajari teori-teori yang akan digunakan dalam menyelesaikan masalah penelitian dari berbagai sumber. Beberapa teori yang dipelajari adalah mengenai aktivitas manusia, sensor, *accelerometer*, *gyroscope*, *dimensionality reduction*, Principal Component Analysis, klasifikasi, Extreme Learning Machine, Computed Input Weight Extreme Learning Machine, fungsi aktivasi, One-Hot Encoding, K-Fold Cross Validation, Grid Search Cross Validation, dan metode evaluasi yang digunakan, yaitu akurasi dan *f-measure*.



Gambar 1. Tahapan penelitian

2.2. Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data sekunder, yaitu data *Human Activity Recognition Using Smartphone Dataset* yang di ambil dari situs *UCI Machine Learning Repository*. Data tersebut dikumpulkan dari 30 sukarelawan yang berusia 19 hingga 30 tahun menggunakan sensor *accelerometer* dan *gyroscope* yang terdapat pada ponsel cerdas Samsung Galaxy S II yang diletakkan pada pinggang pengguna. Setiap orang diminta untuk melakukan enam aktivitas berupa berjalan, naik tangga, turun tangga, duduk, berdiri, dan berbaring. Selanjutnya dilakukan ekstraksi fitur pada data yang didapatkan serta diberi label secara manual, kemudian data tersebut dibagi secara acak dengan 70% dipilih sebagai data latih dan 30% dipilih secara data uji. Jumlah data yang terkumpul adalah sebanyak 10299 data dengan 561 fitur dan enam kelas, dimana 7352 data digunakan sebagai data latih dan 2947 data digunakan sebagai data uji.

2.3. One-Hot Encoding

One-Hot Encoding merupakan sebuah teknik dalam merubah bentuk data kategorik menjadi bentuk biner, dengan panjang sesuai dengan banyaknya kategori data yang berbeda (Potdar et al., 2017). Perubahan label atau kelas menggunakan One-Hot Encoding umumnya digunakan pada saat bekerja menggunakan algoritme jaringan saraf tiruan, karena hasil keluaran setiap label dihitung secara terpisah. One-Hot Encoding dilakukan dengan cara merubah nilai setiap kelas menjadi nilai biner, dengan indeks kelas yang bersangkutan diberi nilai 1 dan yang lain diberi nilai 0. Pada penelitian ini, One-Hot Encoding digunakan untuk mengubah label dari *dataset* yang terdiri dari enam kelas aktivitas manusia.

2.4. Principal Component Analysis

Principal Component Analysis (PCA) merupakan salah satu teknik untuk mengurangi

dimensi fitur dari sebuah *dataset*, meningkatkan makna fitur, sekaligus meminimalkan kehilangan informasi yang ada pada *dataset* tersebut (Jolliffe & Cadima, 2016). PCA biasanya digunakan untuk mengurangi dimensi fitur dari sebuah *dataset* yang memiliki dimensi fitur yang tinggi dengan tujuan untuk meningkatkan hasil klasifikasi, serta mengurangi waktu komputasi. Langkah-langkah algoritme PCA adalah sebagai berikut (Wang et al., 2019):

Input: Data latih $X_{m \times n}$, Jumlah *principal component* k

Output: Data hasil reduksi dimensi $X_{m \times k}$

Proses:

1. Hitung nilai X baru dengan Persamaan (1).

$$X_{baru} = X_{m \times n} - X_{mean} \quad (1)$$
2. Hitung matriks kovarians dengan Persamaan (2).

$$Cov = \frac{1}{m-1} (X_{baru}^T \cdot X_{baru}) \quad (2)$$
3. Hitung dan urutkan *eigenvalue* dan *eigenvector* dari yang terbesar.
4. Pilih k *eigenvector* $W_{n \times k}$ berdasarkan k *eigenvalue* terbesar.
5. Hitung proyeksi data baru dengan Persamaan (3).

$$X_{m \times k} = X_{baru} \cdot W_{n \times k} \quad (3)$$

2.5. Computed Input Weight Extreme Learning Machine

Pada tahun 2015, Tapson, *et al* (2015) mengembangkan algoritme ELM dengan mengusulkan sebuah teknik inisialisasi bobot yang dapat menghasilkan bobot awal yang dipilih secara acak menggunakan kombinasi linier dari data masukan atau data latih, sehingga bobot yang dihasilkan dapat tersusun secara sistematis. Pengembangan dari algoritme ELM berdasarkan teknik inisialisasi bobot diatas diberi nama *Computed Input Weight ELM* (CIW-ELM). Jika pada ELM konvensional inisialisasi bobot nya dilakukan dengan memilih bilangan acak dalam rentang nilai $(-1, 1)$, maka pada CIW-ELM inisialisasi bobot nya dihitung berdasarkan langkah-langkah berikut (Tapson et al., 2015):

Input: Pasangan data latih dan target/kelas yang bersangkutan (X, T) , jumlah *hidden neuron* d

Output: Bobot w

Proses:

1. Normalisasi data latih.
2. Inisialisasi nilai jumlah hidden neuron d , jumlah kelas keluaran C , jumlah data latih

tiap kelas K , dan ukuran blok B yang dapat dihitung menggunakan Persamaan (4).

$$B = d/C \quad (4)$$

3. Untuk setiap $i = 1$ hingga C , lakukan langkah 4 sampai dengan 6.
4. Bangkitkan matriks $R_{B \times K}$ secara acak dengan nilai 1 atau -1.
5. Hitung bobot w menggunakan Persamaan (5).

$$w_{B \times k} = R_{B \times K} \cdot X_{K \times k} \quad (5)$$

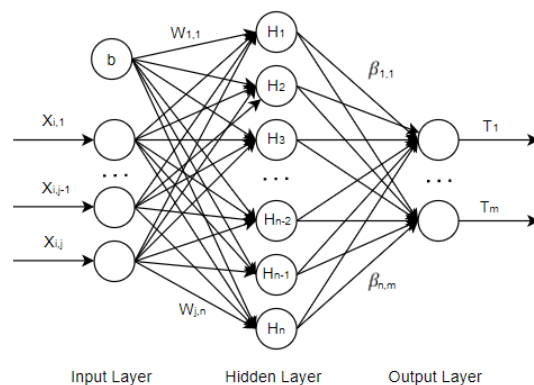
6. Normalisasi bobot menggunakan Persamaan (6), dengan α sebagai indeks kolom.

$$w_{\alpha} = \frac{R_{\alpha}}{|R_{\alpha}|} \quad (6)$$

7. Gabungkan C blok bobot menjadi sebuah matriks bobot $w_{d \times k}$

2.6. Extreme Learning Machine

Extreme Learning Machine (ELM) merupakan algoritme yang dibuat untuk mengatasi masalah pelatihan *feedforward neural network* yang dinilai lebih lambat daripada yang seharusnya dibutuhkan, sehingga menghambat penerapan algoritme tersebut secara umum (Huang et al., 2004). Secara teori, ELM cenderung dapat memberikan kinerja generalisasi yang lebih baik dengan kecepatan pelatihan yang sangat cepat. Algoritme ini termasuk ke dalam kelompok *single hidden layer feedforward neural networks* (SLFNs) yang memilih nilai bobot secara acak dan menentukan bobot keluaran SLFNs secara analitis. Arsitektur algoritme ELM ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur ELM

Arsitektur ELM memiliki tiga parameter penting, yaitu bobot (w), bias (b), dan bobot keluaran (β). Bobot dan bias biasanya diinisialisasi secara acak, sedangkan bobot keluaran didapatkan dari hasil perhitungan pada proses pelatihan. Kemudian untuk *hyperparameter*, kita dapat menentukan berapa jumlah hidden neuron dan fungsi aktivasi apa yang ingin digunakan. Langkah-langkah pelatihan algoritme ELM adalah sebagai berikut:

Input: Pasangan data latih dan target kelas yang bersangkutan (X, T) , fungsi aktivasi $g(x)$, dan jumlah *hidden neuron* N .

Output: Bobot w , bias b , bobot keluaran β .

Proses:

1. Inisialisasi bobot dan bias secara acak.
2. Hitung keluaran *hidden layer* H dengan Persamaan (7).

$$H = X \cdot w^T + b \quad (7)$$

3. Aktivasi nilai H sesuai dengan fungsi aktivasi yang digunakan.
4. Hitung matriks *Moore Penrose Pseudo-Inverse* H^\dagger dengan Persamaan (8)

$$H^\dagger = (H^T \cdot H)^{-1} \cdot H^T \quad (8)$$

5. Hitung matriks bobot keluaran β dengan Persamaan (9).

$$\beta = H^\dagger \cdot T \quad (9)$$

Setelah proses pelatihan selesai, tahap prediksi atau klasifikasi pada data uji dilakukan dengan langkah-langkah berikut:

Input: Data uji X , fungsi aktivasi $g(x)$, jumlah *hidden neuron* N , bobot w , bias b , bobot keluaran β .

Output: Prediksi target

Proses:

1. Hitung keluaran *hidden layer* H dengan Persamaan (7).
2. Aktivasi nilai H sesuai dengan fungsi aktivasi yang digunakan.
3. Hitung hasil prediksi target dengan Persamaan (10).

$$\hat{T} = H \cdot \beta \quad (10)$$

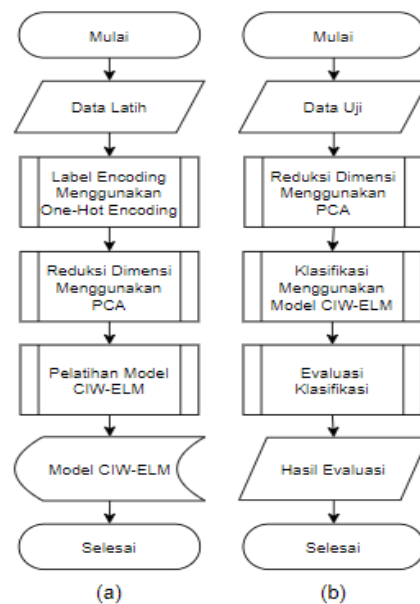
2.7. Perancangan Algoritme

Diagram alir algoritme yang digunakan pada penelitian ini ditunjukkan pada Gambar 3.

Dari 10299 data yang ada, sebanyak 70% data digunakan sebagai data latih, dan 30% digunakan sebagai data uji. Sehingga, jumlah data latih yang digunakan adalah 7352 data, sedangkan data uji yang digunakan adalah 2947 data.

2.8. Teknik Pengujian

Pengujian dilakukan untuk mencari *hyperparameter* terbaik dari setiap metode yang digunakan, sehingga mampu memperoleh hasil terbaik dengan waktu komputasi yang lebih efisien. Pemilihan nilai k atau jumlah *principal component* yang akan di uji merujuk pada penelitian sebelumnya yang menggunakan *dataset* yang sama berdasarkan kontribusi dari sebuah fitur, yaitu dengan nilai 1, 8, 97, 207, 339, 381, dan 406 (Kishore et al., 2017).



Gambar 3. Diagram alir algoritme, (a) Fase Pelatihan, (b) Fase Pengujian

Selanjutnya, jumlah *hidden neuron* yang akan diuji adalah sebanyak 10, 50, 100, 200, 300, 400, 500, dan 600. Sedangkan fungsi aktivasi yang akan diuji adalah *sigmoid*, *tanh*, *sine*, dan *hardlim*. Pengujian tersebut dilakukan pada data latih menggunakan *Grid Search Cross Validation* dengan 10 *Fold*, dan di ukur menggunakan skor yang dihitung berdasarkan rata-rata nilai akurasi dan *f-measure* untuk menentukan *hyperparameter* terbaik dari masing-masing metode. Pasangan *hyperparameter* terbaik akan digunakan untuk membuat model akhir menggunakan keseluruhan data latih, yang kemudian digunakan untuk menguji performa model pada data uji.

3. DASAR TEORI

3.1. Aktivitas Manusia

Menurut Kamus Besar Bahasa Indonesia (KBBI), kata aktivitas berarti keaktifan atau kegiatan. Sehingga, aktivitas manusia bisa juga diartikan sebagai suatu kegiatan yang dilakukan oleh manusia. Berdasarkan kompleksitas nya, aktivitas manusia dibagi menjadi empat tingkatan, yaitu gerak tubuh, tindakan, interaksi, dan kegiatan kelompok (Aggarwal & Ryoo, 2011). Gerak tubuh adalah gerakan dasar bagian tubuh seseorang, seperti meregangkan lengan dan mengangkat kaki. Tindakan adalah aktivitas seseorang yang terdiri dari beberapa gerakan yang terorganisir, seperti berjalan, melambai, dan memukul. Interaksi adalah aktivitas manusia yang melibatkan dua atau lebih orang dan/atau objek. Sedangkan kegiatan kelompok adalah kegiatan yang dilakukan oleh sekelompok orang dan/atau objek.

3.2. Sensor

Sensor merupakan sumber pengumpulan data mentah yang digunakan pada pengenalan aktivitas

manusia. Sensor dapat diklasifikasikan menjadi tiga kategori, yaitu sensor video, sensor berbasis lingkungan, dan sensor yang dapat dikenakan (Su et al., 2014). Sensor yang dapat dikenakan (wearable sensor) merupakan sensor yang banyak digunakan dalam mengenali aktivitas manusia karena ukurannya yang kecil dan dapat dikenakan oleh manusia dalam melakukan aktivitas sehari-hari. Contoh sensor yang dapat dikenakan yaitu *accelerometer*, *microphone*, GPS, *barometer*, *gyroscope*, dan lain sebagainya, yang sebagian besar sensor tersebut terdapat pada ponsel cerdas.

4. HASIL DAN PEMBAHASAN

Pada pengujian *hyperparameter* terbaik, terdapat 224 pasangan *hyperparameter* yang diuji. Hasil pengujian *hyperparameter* ditunjukkan pada Tabel 1.

Tabel 1. Hasil Pengujian *Hyperparameter*

No.	K	Jumlah Neuron	Fungsi Aktivasi	Skor Akhir	Waktu Pelatihan
1	1	10	<i>sigmoid</i>	0,442	0,00838
2	1	10	<i>tanh</i>	0,426	0,013101
3	1	10	<i>sine</i>	0,448	0,007327
4	1	10	<i>hardlim</i>	0,231	0,008256
5	1	50	<i>sigmoid</i>	0,314	0,025549
...
125	207	600	<i>sigmoid</i>	0,986	0,52784
...
220	406	500	<i>hardlim</i>	0,917	13,37551
221	406	600	<i>sigmoid</i>	0,985	0,584002
222	406	600	<i>tanh</i>	0,983	0,812493
223	406	600	<i>sine</i>	0,983	0,592092
224	406	600	<i>hardlim</i>	0,931	19,52797

Dari hasil pengujian diatas, didapatkan pasangan *hyperparameter* terbaik pada pasangan ke 125 dengan nilai $k = 207$, jumlah *hidden neuron* = 600, dan fungsi aktivasi *sigmoid* dengan skor akhir sebesar 0,986 serta rata-rata waktu pelatihan pada masing-masing *Fold* selama 0,52784 detik.

Hyperparameter terbaik yang didapatkan pada pengujian sebelumnya kemudian digunakan untuk menguji performa dari algoritme yang diusulkan menggunakan keseluruhan data. Hasil *confusion matrix* yang didapatkan dari pengujian akhir ditunjukkan pada Tabel 2.

Tabel 2. *Confusion matrix* pengujian

Prediksi	Aktual					
	W	WU	WD	SI	ST	L
W	495	10	3	0	0	0
WU	1	461	14	3	0	0
WD	0	0	403	0	0	0
SI	0	0	0	438	20	0
ST	0	0	0	50	512	25
L	0	0	0	0	0	512

Pada Tabel 2, masing-masing label mewakili aktivitas manusia secara berturut-turut yaitu *WALKING*, *WALKING_UPSTAIRS*, *WALKING*

DOWNSTAIRS, *SITTING*, *STANDING*, dan *LAYING*. Dari hasil *confusion matrix* tersebut, dapat dihitung nilai akurasi dan *f-measure* dari hasil penggunaan algoritme PCA dan CIW-ELM pada masalah klasifikasi aktivitas manusia. Nilai akurasi yang didapatkan pada penelitian ini adalah sebesar 0,957 serta rata-rata nilai *f-measure* sebesar 0,958. Sedangkan waktu komputasi yang dibutuhkan untuk melakukan pelatihan pada model CIW-ELM pada keseluruhan data latih yang terdiri dari 7352 data adalah selama 0,57 detik.

Kemudian untuk mengetahui kontribusi dari metode yang diusulkan, akan ditunjukkan perbandingan hasil dengan metode yang sudah ada. Perbandingan metode yang diusulkan dengan metode yang sudah ada ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan dengan metode yang sudah ada

Metode	Akurasi
PCA_BP (Kishore et al., 2017)	96,8%
mRMR_SVM (Doewes et al., 2017)	96,54%
PCA_CIW-ELM	95,7%
LSTM (Hernandez et al., 2019)	92,67%
FW_NB (Wang et al., 2016)	90,1%
FW_KNN (Wang et al., 2016)	87,8%

Berdasarkan Tabel 3, hasil akurasi yang didapatkan oleh metode yang diusulkan dapat mengungguli beberapa metode yang sudah ada. Namun, akurasi yang didapatkan pada metode mRMR_SVM dan PCA_BP terlihat lebih baik daripada metode yang diusulkan, meskipun tidak terlalu signifikan.

5. KESIMPULAN DAN SARAN

Penggunaan metode yang diusulkan yaitu PCA dan CIW-ELM untuk melakukan klasifikasi aktivitas manusia berhasil mendapatkan akurasi sebesar 0,957 dan rata-rata *f-measure* sebesar 0,958 dengan hanya membutuhkan waktu pelatihan selama 0,57 detik. Hasil tersebut didapatkan dengan menggunakan nilai *hyperparameter* terbaik dari masing-masing metode berdasarkan pengujian Grid Search Cross Validation, yaitu dengan nilai $k = 207$, jumlah *hidden neuron* = 600, dan fungsi aktivasi *sigmoid*. Penggunaan metode PCA memiliki pengaruh positif terhadap hasil yang didapatkan dari metode CIW-ELM, yaitu dapat meningkatkan akurasi dan *f-measure* serta mengurangi waktu komputasi yang dibutuhkan.

Hasil akurasi dari penggunaan kedua metode yang diusulkan juga terbukti lebih unggul daripada beberapa metode yang sudah ada, meskipun metode mRMR_SVM dan PCA_LBP diketahui memiliki akurasi yang sedikit lebih baik. Meski begitu, metode PCA dan CIW-ELM masih memiliki keunggulan lain yaitu membutuhkan sumber daya yang lebih rendah dan dapat berjalan dengan sangat cepat. Oleh karena itu, dengan mempertimbangkan hasil akurasi dan waktu komputasi yang dibutuhkan, metode PCA dan CIW-ELM seharusnya lebih cocok digunakan untuk

melakukan pengenalan atau klasifikasi aktivitas manusia secara langsung menggunakan ponsel cerdas yang diketahui memiliki kapasitas prosesor yang terbatas.

Meskipun PCA terbukti dapat mengurangi dimensi fitur data dari yang semula 561 menjadi 207, namun jumlah dimensi fitur tersebut masih tergolong tinggi. Untuk penelitian selanjutnya mungkin dapat menggunakan algoritme lain yang dapat mengurangi dimensi fitur menjadi lebih rendah. Kemudian, pada algoritme CIW-ELM masih terdapat ketidakpastian terhadap hasil klasifikasi yang dilakukan karena inisialisasi *random matrix* pada inisialisasi bobot, serta inisialisasi bias yang dilakukan secara acak. Oleh karena itu, dapat dilakukan optimasi pada proses tersebut untuk menghasilkan model klasifikasi yang lebih baik.

DAFTAR PUSTAKA

- AGGARWAL, J. K., & RYOO, M. S., 2011. Human activity analysis: A review. *ACM Computing Surveys*, 43(3).
- AHMAD, I., BASHERI, M., IQBAL, M. J., & RAHIM, A. 2018. Performance Comparison of Support Vector Machine, Random Forest, and Extreme Learning Machine for Intrusion Detection. *IEEE Access*, 6(c), 33789–33795. <https://doi.org/10.1109/ACCESS.2018.2841987>
- ANGUITA, D., GHIO, A., ONETO, L., PARRA, X., & REYES-ORTIZ, J. L., 2013. A Public Domain Dataset for Human Activity Recognition Using Smartphone. *ESANN 2013 Proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*. Bruges (Belgium), 24-26 April 2013, I6doc.Com, April, 437–442.
- BEVILACQUA, A., MACDONALD, K., RANGAREJ, A., WIDJAYA, V., CAULFIELD, B., & KECHADI, T., 2019. Human activity recognition with convolutional neural networks. In *arXiv* (Vol. 1). Springer International Publishing.
- DOEWES, A., SWASONO, S. E., & HARJITO, B., 2017. Feature selection on Human Activity Recognition dataset using Minimum Redundancy Maximum Relevance. 2017 IEEE International Conference on Consumer Electronics - Taiwan, ICCE-TW 2017, 1, 171–172.
- GARCIA-GONZALEZ, D., RIVERO, D., FERNANDEZ-BLANCO, E., & LUACES, M. R., 2020. A public domain dataset for real-life human activity recognition using smartphone sensors. *Sensors* (Switzerland), 20(8).
- HERNANDEZ, F., SUAREZ, L. F., VILLAMIZAR, J., & ALTUVE, M., 2019. Human Activity Recognition on Smartphones Using a Bidirectional LSTM Network.
- HUANG, G. BIN, ZHU, Q. Y., & SIEW, C. K., 2004. Extreme learning machine: A new learning scheme of feedforward neural networks. *IEEE International Conference on Neural Networks - Conference Proceedings*, 2(February 2014), 985–990.
- JOLLIFE, I. T., & CADIMA, J., 2016. Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065).
- JUNITA, V., & BACHTIAR, F. A., 2019. Klasifikasi Aktivitas Manusia menggunakan Algoritme Decision Tree C4 . 5 dan Information Gain untuk Seleksi Fitur. 3(10), 9426–9433.
- KHAN, A. M., LEE, Y. K., LEE, S. Y., & KIM, T. S., 2010. A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer. *IEEE Transactions on Information Technology in Biomedicine*, 14(5), 1166–1172.
- MICUCCI, D., MOBILIO, M., & NAPOLETANO, P., 2017. UniMiB SHAR: A dataset for human activity recognition using acceleration data from smartphones. *Applied Sciences* (Switzerland), 7(10).
- POTDAR, K., S., T., & D., C., 2017. A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers. *International Journal of Computer Applications*, 175(4), 7–9.
- REISS, A., HENDEBY, G., & STRICKER, D., 2013. A competitive approach for human activity recognition on smartphones. *ESANN 2013 Proceedings, 21st European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, April, 455–460.
- SU, X., TONG, H., & JI, P., 2014. Activity recognition with smartphone sensors. *Tsinghua Science and Technology*, 19(3), 235–249.
- TAPSON, J., DE CHAZAL, P., & VAN SCHAIK, A., 2015. Explicit Computation of Input Weights in Extreme Learning Machines. *June*, 41–49.
- WANG, A., CHEN, G., YANG, J., ZHAO, S., & CHANG, C., 2016. A Comparative Study on Human Activity Recognition Using Inertial Sensors in a Smartphone.
- WANG, B., CHEN, Q., WANG, Z., & HU, Y., 2019. The Research on Improved LVQ Neural

Network Method. 2019 3rd International Conference on Circuits, System and Simulation, ICCSS 2019, 206–209.

ZHANG, M., & SAWCHUK, A. A., 2012. A feature selection-based framework for human activity recognition using wearable multimodal sensors. BODYNETS 2011 - 6th International ICST Conference on Body Area Networks, January 2011, 92–98. <https://doi.org/10.4108/icst.bodynets.2011.247018>