

Klasifikasi Aktivitas Fisik Berbasis Data Accelerometer dan Kuesioner dengan Metode *Machine Learning*

Humaira Azzahra Putri Mulyana^{1*}, Adang Suherman², Jajat³, Imas Damayanti⁴, Kuston Sultoni⁵, Yati Ruhayati⁶, Nur Indri Rahayu⁷

Program Studi Ilmu Keolahragaan, Fakultas Pendidikan Olahraga dan Kesehatan, Universitas Pendidikan Indonesia. Jl. Dr. Setiabudhi No.229 Bandung, Jawa Barat 40154, Indonesia

*Korespondensi Penulis. E-mail: humairaazh0@upi.edu

ABSTRAK

Accelerometer dan kuesioner merupakan instrumen yang telah banyak digunakan para peneliti dalam studi aktivitas fisik. Penelitian ini bertujuan untuk menganalisis perbedaan akurasi klasifikasi level aktivitas fisik dengan metode *machine learning*. Partisipan dalam penelitian ini yaitu remaja berusia 18-21 tahun ($M=19,79$; $SD = 1,13$) dengan jumlah perempuan 44 orang dan laki-laki 17 orang. Instrumen yang digunakan dalam penelitian yaitu accelerometer Actigraph GT3X dan *International Physical Activity Questionnaire* (IPAQ). Adapun analisis klasifikasi level aktivitas fisik dilakukan dengan algoritma *machine learning decision tree*. Hasil analisis menunjukkan bahwa untuk dataset berbasis accelerometer Actigraph GT3X memiliki performa akurasi 98,36%, sedangkan akurasi dataset IPAQ menunjukkan performa akurasi sebesar 73,77%. Metode algoritma *machine learning decision tree* dapat digunakan untuk mengklasifikasi level aktivitas fisik pada kedua jenis sumber dataset dengan performa akurasi sedang sampai tinggi. Analisis lebih lanjut diperlukan dengan menggunakan algoritma *machine learning* lainnya untuk mendapatkan hasil penelitian yang lebih variatif.

Kata Kunci: *Actigraph, Artificial Intelligence, DecisionTree, Intensitas Aktivitas Fisik*

ABSTRACT

Accelerometers and questionnaires are instruments that have been widely used by researchers in physical activity studies. This study aims to analyze differences in the accuracy of classification of physical activity levels using machine learning methods. Participants in this study were teenagers aged 18-21 years ($M=19.79$; $SD = 1.13$) with 44 women and 17 men. The instruments used in the research were the Actigraph GT3X accelerometer and the International Physical Activity Questionnaire (IPAQ). The physical activity level classification analysis was carried out using a machine learning decision tree algorithm. The analysis results show that the Actigraph GT3X accelerometer-based dataset has an accuracy performance of 98.36%, while the IPAQ dataset shows an accuracy performance of 73.77%. The machine learning decision tree algorithm method can be used to classify physical activity levels in both types of dataset sources with moderate to high accuracy performance. Further analysis is needed using other machine learning algorithms to obtain more varied research results.

Keywords: *Actigraph, Artificial Intelligence, Decision Tree, Intensity of Physical Activity*

PENDAHULUAN

Kejadian obesitas meningkat pada orang dewasa (Caussy et al., 2020; Flegal et al., 2016; Ogden et al., 2017) maupun anak-anak (Bertapelli et al., 2016; Fryar et al., 2018; Ogden et al., 2016; Skinner et al., 2018) dan berhubungan erat dengan banyak penyakit kronis seperti diabetes (Bhupathiraju & Hu, 2016; Verma & Hussain, 2017), hipertensi (Seravalle & Grassi, 2017; Ziang et al., 2016), kanker (Arnold et al., 2016; Avgerinos et al., 2019; Colditz & Peterson, 2018), penyakit kardiovaskular (Ortega et al.,

2016; Koliaki et al., 2019), depresi (Patsalos et al., 2021; Quek et al., 2017) dan merupakan penyebab kematian secara global (Mills et al., 2020). Obesitas sendiri disebabkan oleh faktor fisiologis, genetik, keseimbangan energi, dan faktor-faktor kontekstual lainnya seperti geografis, budaya, lingkungan fisik dan sosial, jenis kelamin, usia, pola makan dan rendahnya aktivitas fisik (Williams et al., 2015), di mana penurunan aktivitas fisik telah menjadi peran utama dalam meningkatnya obesitas di seluruh dunia (Sahoo et al., 2015) termasuk di Indonesia. Bagaimanapun juga salah satu aspek yang mengkhawatirkan terkait obesitas pada usia anak yaitu terjadinya peningkatan resiko obesitas di masa dewasa (Liang et al., 2015; Weihrach-Blüher et al., 2019) di mana resiko kesehatan terkait dengan hal ini sudah banyak terjadi.

Secara konseptual, aktivitas fisik memiliki peran penting dalam mengurangi resiko obesitas (Anderson et al., 2016; Katzmarzyk et al., 2015; Wiklund, 2016). Ada hubungan yang signifikan antara level aktivitas fisik moderat dan tinggi dengan obesitas (Katzmarzyk et al., 2015). Artinya bahwa level aktivitas fisik menjadi salah satu faktor penentu resiko terjadinya obesitas. Namun demikian, untuk mengukur level aktivitas fisik secara akurat relatif masih samar. Sejumlah penelitian untuk mengukur level aktivitas fisik telah dilakukan, baik dengan menggunakan instrumen kuesioner maupun alat ukur lainnya seperti *pedometer*, *accelerometer* dan *heart rate monitor* (Ainsworth et al., 2015; Chandler et al., 2016; Ramdani et al., 2019; Prince et al., 2008), dan hasil dari pengukurannya bervariasi. Meskipun metode laporan diri (*self-report*) melalui kuesioner dan catatan aktivitas memiliki kontribusi besar terhadap pemahaman mengenai aktivitas fisik dan resiko kesehatan (Warburton et al., 2006) serta memiliki nilai ekonomis, praktis dan mudah digunakan (Strath et al., 2013), namun dianggap masih memiliki kelemahan. Sifat kuesioner yang subjektif dapat menyebabkan penilaian berlebihan dan cenderung meremehkan aktivitas fisik (Prince et al., 2008), sehingga tingkat akurasi masih dianggap kurang.

Sebagai alternatif untuk menutupi kelemahan kuesioner tersebut, pengukuran secara langsung dengan menggunakan *accelerometer*, *pedometer* dan *heart rate monitor* yang dianggap dapat secara objektif mengukur intensitas dan volume aktivitas fisik (Hagstromer et al., 2010; Troiano et al., 2008). *Accelerometer* adalah sebuah sensor yang dikenakan pada tubuh seseorang bersifat efektif untuk mengukur klasifikasi aktivitas fisik seseorang (Long et al., 2009). Selain mengukur aktivitas fisik, *accelerometer* juga dapat mengukur perilaku *sedentary* dan waktu tidur (Ramdani et al., 2019). *Accelerometer* ini biasanya digunakan di bagian pinggang (Long et al., 2009) ataupun di bagian pergelangan tangan (Rainham et al., 2012). Namun demikian, meskipun *accelerometer* dianggap memiliki objektivitas lebih baik dari kuesioner, tetapi juga memiliki kekurangan seperti tidak dapat digeneralisasikan pada semua kelompok populasi dan beberapa masalah validitasnya (Pedišić & Bauman, 2015). Artinya bahwa masing-masing instrumen untuk mengukur aktivitas fisik memiliki kelebihan dan kekurangan.

Berkembangnya ilmu pengetahuan dan teknologi, salah satunya kecerdasan buatan (*artificial intelligence*) telah banyak dimanfaatkan oleh para peneliti termasuk dalam bidang aktivitas fisik (Ahmed et al., 2022; Maher et al., 2020). Kecerdasan buatan dengan metode *machine learning* dimanfaatkan dalam memprediksi (Hagenbuchner et al., 2015; van Doorn et al., 2021) maupun mengklasifikasi (Mannini & Sabatini, 2010; Sheng et al., 2020) level aktivitas fisik. Dilihat dari fungsi dan manfaatnya, *machine learning* menjadi metode yang cukup banyak di gunakan oleh para peneliti. Algoritma *machine learning* mampu memberikan analisis data yang tidak teramati oleh peneliti (Murdoch et al., 2019). Dalam konteks pengukuran aktivitas fisik dengan *accelerometer*, metode *machine learning* ini dapat memperoleh hasil data yang relevan dan akurat juga efektif dalam penggunaannya (Ellis et al., 2014) meskipun hasilnya cukup variatif. Perbedaan hasil tersebut dipengaruhi oleh karakteristik atribut, instrumen, serta model algoritma *machine learning* yang digunakannya (Mardini et al., 2021).

Berdasarkan hal tersebut, tujuan dari penelitian ini adalah untuk mengklasifikasi level aktivitas fisik dengan metode *machine learning* berbasis data *accelerometer Actigraph GT3X* dan kuesioner IPAQ. Adapun metode *machine learning* yang digunakan yaitu *decision tree*, di mana berdasarkan beberapa penelitian memiliki akurasi tinggi dalam mengklasifikasi level aktivitas fisik (Maswadi et al., 2021; Zhang et al., 2012). Penelitian ini juga mengkaji perbedaan akurasi klasifikasi level aktivitas fisik antara data berbasis kuesioner IPAQ dan *accelerometer Actigraph GT3X*.

METODE

Jenis penelitian

Penelitian ini menggunakan desain *comparative study*, yaitu membandingkan akurasi klasifikasi level aktivitas fisik dengan metode *algorithm machine learning* dari dua sumber data set instrumen *Accelerometer Actigraph GT3X* dan *IPAQ*.

Waktu dan tempat Penelitian

Data set pada penelitian ini berasal dari payung penelitian dosen dan mahasiswa Program Studi Ilmu Keolahragaan, Fakultas Pendidikan Olahraga dan Kesehatan (FPOK), Universitas Pendidikan Indonesia yang tergabung dalam kelompok bidang keilmuan aktivitas fisik (*Physical Activity*). Data set yang digunakan yaitu dari kelompok bidang keilmuan dari tahun 2021 sampai dengan tahun 2023 yang merupakan data beberapa penelitian dari Sekolah Menengah Atas (SMA) dan Perguruan Tinggi di Jawa Barat.

Target/ Sasaran

Target dan sasaran dari penelitian ini adalah usia remaja yang ada di Provinsi Jawa Barat.

Subjek penelitian

Subjek penelitian yaitu kelompok remaja usia 18-21 tahun ($M=19,79$; $SD = 1,13$) dengan jumlah perempuan 44 orang dan laki-laki 17 orang.

Prosedur

Pada tahap pengumpulan data, instrumen accelerometer Actigraph GT3X dipasang pada bagian pinggang sampel selama 7 hari tanpa dilepas (kecuali untuk aktivitas yang berhubungan dengan air seperti mandi dan berenang) yang berfungsi untuk merekam aktivitas fisik keseharian, dari mulai bangun tidur sampai kembali tidur.

Accelerometer Actigraph GT3X dipasang pada mereka yang menyatakan kesediaannya untuk dijadikan sampel dengan menyertakan surat pernyataan. Untuk kuesioner IPAQ disebar dan diisi oleh sampel pada saat setelah perekaman aktivitas dengan Accelerometer Actigraph GT3X dilakukan, yaitu pada sampel yang telah menyatakan kesediaannya untuk berpartisipasi dalam penelitian. Kuesioner IPAQ disebar kepada sampel melalui pemanfaatan aplikasi WhatsApp dan penggunaan google form. Total 102 orang usia remaja berusia antara 18-21 tahun yang berasal dari siswa SMA dan Mahasiswa di Jawa Barat menyatakan kesediaan untuk berpartisipasi dalam penelitian.

Instrumen

Penelitian ini menggunakan instrumen *accelerometer Actigraph GT3X* dan kuesioner *IPAQ*. Actigraph GT3X merupakan perangkat yang telah banyak digunakan oleh para peneliti dalam bidang aktivitas fisik. *Actigraph GT3X* (Gambar 1) memiliki bentuk yang kecil dan dapat dipasang pada pinggang atau lengan, sehingga tidak mengganggu pergerakan partisipan dalam melakukan aktivitas keseharian. Sementara itu IPAQ merupakan kuesioner yang juga telah banyak digunakan oleh para peneliti dalam bidang aktivitas fisik yang berisi pertanyaan mengenai aktivitas yang telah dilakukan oleh partisipan dalam waktu 7 (tujuh) hari terakhir.



Gambar 1. Accelerometer Actigraph GT3X

Klasifikasi Aktivitas Fisik

Metabolic Equivalent of Task (METs) merupakan standar banyaknya energi yang dikeluarkan oleh tubuh dalam keadaan istirahat duduk dan beraktivitas. Satuan ini digunakan untuk untuk mengklasifikasi kategori aktivitas fisik yang dilakukan oleh seseorang. Selain itu kelipatan dari resting metabolik rate (RMR) dimana 1 METs adalah energi yang dikeluarkan per menit/kg BB orang dewasa (1 METs = 1.2 kkal/menit) aktivitas fisik dinyatakan dalam skor yaitu METs-min sebagai jumlah kegiatan setiap menit. Adapun kuesioner IPAQ menetapkan skor klasifikasi aktivitas fisik dengan rumus pada tabel 1. Sementara itu pengkategorian METs berdasarkan norma IPAQ yaitu sebagaimana pada tabel 2.

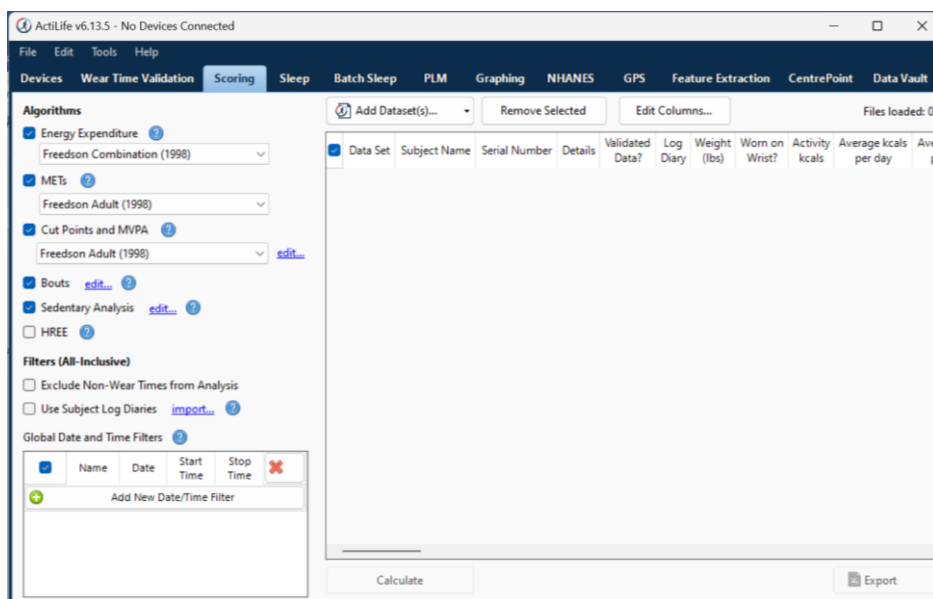
Tabel 1. Rumus skor METs IPAQ

$Walking\ MET\text{-minutes}/week = 3.3 * walking\ minutes * walking\ days$
 $Moderate\ MET\text{-minutes}/week = 4.0 * moderate\text{-intensity}\ activity\ minutes * moderate\ days$
 $Vigorous\ MET\text{-minutes}/week = 8.0 * vigorous\text{-intensity}\ activity\ minutes * vigorous\text{-intensity}\ days$
 $Total\ physical\ activity\ MET\text{-minutes}/week = sum\ of\ Walking + Moderate + Vigorous$
 $MET\text{-minutes}/week\ scores.$

Tabel 2. Kategori Norma Klasifikasi IPAQ

Kategori	METs (Menit/Minggu)
Berat	≥ 3000
Sedang	≥ 600
Ringan	< 600

Adapun untuk klasifikasi aktivis fisik pada *accelerometer* Actigraph GT3X yaitu mengacu pada freedson adult 1998, baik untuk energy expenditure, METs, maupun cut point dan aktivitas fisik sedang hingga berat (MVPA) yang ada pada aplikasi software ActiLife versi V6.13.5 sebagaimana pada gambar 2. Terdapat beberapa data yang berisi *Sedentary Bout Parameters* dan *Cut Points Values*. Pada *Sedentary Bout Parameters* menyimpan data *minimum length: 10 minutes*, *minimum count value: 0 counts per minute*, *maximum count value: 99 counts per minute*, *drop time: 0 minutes*, *vector magnitude: "false"* lalu data dari *cut point values* yaitu *sedentary 0 to 99*, *light 100 to 1951*, *moderate 1952 to 5724*, *vigorous 5725 to 9498*, *very vigorous* diatas 9499 dan *Moderate to Vigorous Physical Activity minimum count 1952*.



Gambar 2. Software ActiLife untuk analisis hasil perekaman Actigraph

Pre-Processing

Pada *pre processing* yaitu melakukan *screening* data, terutama data hasil perekaman dari *accelerometer* Actigraph GT3X. Tahap awal yang dilakukan setelah 7 hari perekaman yaitu mengunduh data hasil perekaman dengan menggunakan software ActiLife V6.13.4. Selanjutnya adalah memilih cut point yaitu dengan freedson adult (1998) sehingga diperoleh kalkulasi waktu, intensitas, volume aktivitas dan beberapa hasil lainnya selama perekaman dilakukan.

Berdasarkan hasil *screening*, dari 102 perekaman diperoleh 61 data yang valid yaitu 44 orang perempuan dan 17 orang laki-laki. Validitas data salah satunya ditentukan dari lengkap dan tidaknya perekaman data, sesuai dengan waktu perekaman yang telah ditentukan. Sementara untuk *screening* pada kuesioner IPAQ dilakukan pada jawaban yang diberikan oleh responden, yaitu kesesuaian antara jawaban yang diminta dengan jawaban yang diberikan. Untuk data yang tidak lengkap selanjutnya tidak digunakan dan dianalisis. Dengan demikian untuk data kuesioner, jumlahnya juga disesuaikan dengan hasil dari perekaman *accelerometer* Actigraph GT3X. Selanjutnya data yang valid tersebut digunakan untuk dianalisis lebih lanjut sesuai dengan permasalahan penelitian.

Data Latihan dan Tes


Klasifikasi dengan *decision tree* termasuk pada *supervised learning*, dan data set dibagi menjadi dua bagian, yaitu untuk data latihan (*training data*) dan data tes (*test data*). Adapun jumlah data yang digunakan untuk untuk latihan yaitu sebesar 80% dan data untuk tes yaitu 20%. Proses membagi data latihan dan data tes dilakukan dengan metode *cross validasi*.

Teknis Analisis data

Analisis model algoritma dalam penelitian ini yaitu dengan menggunakan aplikasi *RapidMiner Studio Educational* 10.1.002. Pada gambar 3 disajikan model *cross validation* yang merupakan tahapan dari input data sampai tahapan proses data latihan. Metode analisis yang digunakan untuk mengklasifikasi level aktivitas fisik yaitu menggunakan algoritma *machine learning decision tree*. Sebagaimana kemukakan sebelumnya bahwa *decision tree* memiliki akurasi tinggi dalam mengklasifikasi. Adapun variable atau atribut yang digunakan untuk mengklasifikasi level aktivitas fisik dalam penelitian ini adalah waktu aktivitas yang terekam dalam *accelerometer* Actigraph dan waktu aktivitas yang dilaporkan oleh responden melalui IPAQ.



Gambar 3. Kerangka Kerja Proses Training Data pada Rapidminer



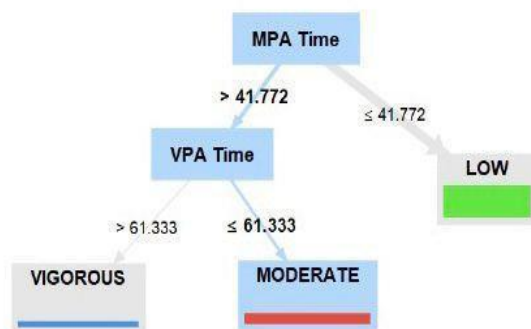
Gambar 4. Kerangka Kerja Proses Utama Training dan Tes Data Alogaritma *Decision Tree*

Gambar 4 menyajikan kerangka kerja proses latihan dan pengujian data serta analisis performa model algoritma *decision tree* pada aplikasi RapidMiner. *RapidMiner* merupakan software/perangkat lunak yang digunakan untuk pengolahan data. Dengan menggunakan prinsip dan algoritma data mining, *RapidMiner* mengekstrak data set yang besar dengan mengkombinasikan metode statistika, kecerdasan buatan dan database.

HASIL DAN PEMBAHASAN

Hasil

Sebagaimana dikemukakan sebelumnya bahwa variable atau atribut yang digunakan untuk mengklasifikasikan aktivitas fisik dalam penelitian ini adalah waktu aktivitas yang terekam pada accelerometer Actigraph GT3X dan waktu yang dilaporkan oleh responden pada kuesioner IPAQ. Adapun hasil pemodelan berbasis data accelerometer Actigraph GT3X yang dilakukan dengan *decision tree* sebagaimana disajikan pada gambar 5.



Gambar 5. *Decision Tree Model* Klasifikasi Aktivitas Fisik Menggunakan Actigraph

Berdasarkan pada gambar 5 bahwa klasifikasi level aktivitas fisik rendah ditentukan oleh waktu aktivitas sedang (moderat). Jika waktu aktivitas fisik moderat kurang dari atau sama dengan 41,722 menit per hari, maka aktivitas fisik diklasifikasikan rendah. Sementara itu untuk level aktivitas fisik sedang dan tinggi, selain ditentukan oleh waktu aktivitas moderat juga ditentukan oleh waktu aktivitas fisik berat (vigorous). Aktivitas fisik diklasifikasikan moderat jika waktu aktivitas moderat lebih dari 41,722 menit per hari dan waktu aktivitas vigorous nya kurang dari 61,333 menit per hari. Aktivitas fisik diklasifikasi ke dalam vigorous jika waktu aktivitas moderat lebih dari 41,722 menit per hari dan waktu aktivitas

vigorous nya lebih dari 61,33 menit per hari.

Selanjutnya hasil pemodelan algoritma *machine learning* yang telah terbentuk tersebut diuji melalui *cross validation* dan diukur performa akurasi dengan confusion matrix. Adapun pada gambar 6 disajikan ringkasan output hasil pengujian *cross validation* yang menunjukkan klasifikasi hasil latihan dengan prediksi klasifikasi. Adapun tabel 3 merupakan hasil analisis performa model *decision tree* confusion matrix.

Row No.	PA Class	prediction(P...	confidence(...	confidence(...	confidence(...	Gender	LPA Time	MPA Time
1	VIGOROUS	VIGOROUS	0	1	0	1	149.161	53.072
2	LOW	LOW	1	0	0	1	84.033	33.867
3	LOW	LOW	1	0	0	2	122.250	11.750
4	LOW	LOW	1	0	0	2	222.367	41.067
5	LOW	LOW	1	0	0	2	139.278	21.028
6	MODERATE	MODERATE	0	0	1	2	214.028	47.111
7	LOW	LOW	1	0	0	2	117.567	35.967
8	LOW	LOW	1	0	0	2	141.667	36.267
9	LOW	LOW	1	0	0	2	214.778	41.611
10	MODERATE	MODERATE	0	0	1	2	183.306	54.028
11	LOW	LOW	1	0	0	2	171.881	12.381
12	LOW	LOW	1	0	0	2	121.782	19.024

Gambar 6. Ringkasan Output Hasil Pengujian *Cross Validation* Data Actigraph

Tabel 3. *Confusion Matrix* Berdasarkan Waktu Aktivitas Fisik

accuracy: 98.57% +/- 4.52% (micro average: 98.36%)

	true VIGOROUS	true LOW	true MODERATE	class precision
pred. VIGOROUS	6	0	0	100.00%
pred. LOW	0	42	1	97.67%
pred. MODERATE	0	0	12	100.00%
class recall	100.00%	100.00%	92.31%	

Keterangan:

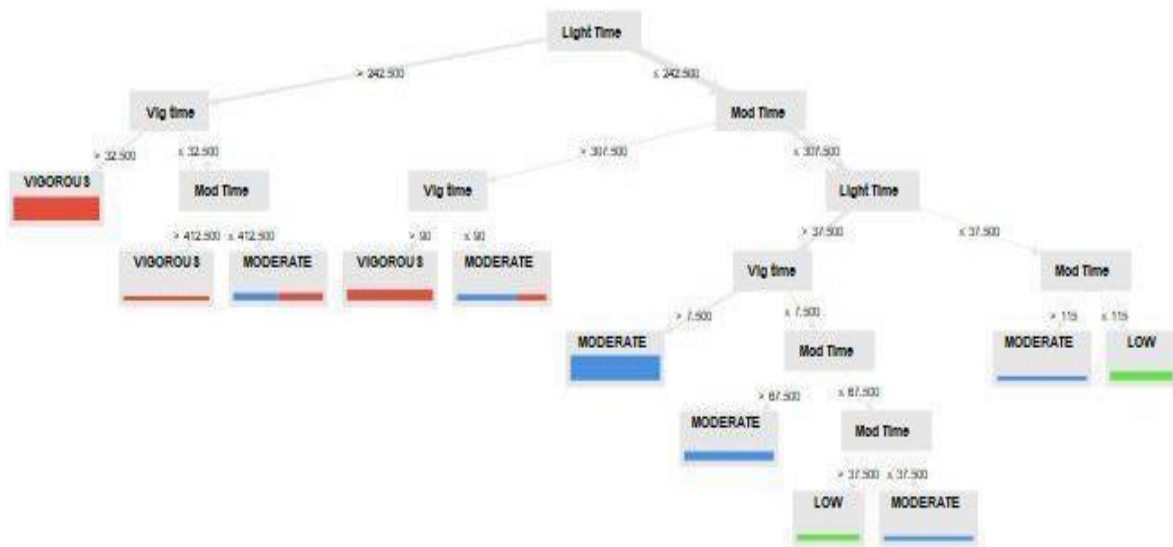
V = Pred Vigorous

L = Pred Low

M = Pred Moderate

Berdasarkan hasil analisis percobaan yang dilakukan terhadap atribut waktu aktivitas fisik sebagaimana pada tabel 3 bahwa (pred V – true V) jumlah data record yang diprediksi termasuk pada klasifikasi aktivitas fisik vigorous yaitu sebanyak 6 data sesuai atau benar dan tidak ada data diprediksi termasuk pada klasifikasi low maupun moderat. Artinya bahwa algoritma *decision tree* yang digunakan untuk mengklasifikasi aktivitas fisik vigorous berdasarkan waktu aktivitas fisik memiliki akurasi sebesar 100.00%. Selanjutnya untuk prediksi klasifikasi aktivitas fisik low (pred L – true L) yaitu sebanyak 42 data benar dan tidak ada data diprediksi termasuk pada klasifikasi vigorous maupun moderat. Tingkat kebenaran untuk kategori aktivitas fisik low yaitu sebesar 100.00%. Sementara itu untuk (pred M – true M) sebanyak 12 data benar diklasifikasikan pada aktivitas fisik moderat dan 1 data diklasifikasikan pada aktivitas fisik low dengan kebenaran klasifikasi sebesar 92,31%. Hasil analisis percobaan jumlah *true positive* atau jumlah *record* yang berhasil diprediksi dengan benar yaitu sebanyak 60 data *record*. Adapun jumlah seluruh data *record* yaitu sebanyak 61 *record*, sehingga dapat dihitung akurasi yaitu

$(60/61) * 100\% = 98,36\%$.



Gambar 7. Pohon Keputusan Klasifikasi Level Aktivitas Fisik Data IPAQ

Pengujian selanjutnya yaitu terhadap data dengan instrumen IPAQ. Adapun gambar 7 menyajikan hasil pohon keputusan dari training data klasifikasi level aktivitas fisik dari data IPAQ. Berbeda dengan pohon keputusan yang dihasilkan dari data berbasis accelerometer Actigraph, pohon keputusan berbasis data IPAQ memiliki cabang yang lebih banyak dalam mengklasifikasi level aktivitas fisik. Pada pohon keputusan berbasis data IPAQ, di paling atas adalah waktu aktivitas ringan (light physical activity). Baik level aktivitas fisik rendah, sedang maupun tinggi dipengaruhi oleh atribut waktu aktivitas fisik ringan. Untuk menguji performa model yang dihasilkan dari data selanjutnya dilakukan dengan *cross validation* dan performa *confusion matrix*. Adapun hasilnya sebagaimana disajikan pada gambar 8 dan tabel 4.

Row No.	PA Class	prediction(P...	confidence(...	confidence(...	confidence(...	Gender	Vig time	Mod Time
1	MODERATE	MODERATE	0	0.125	0.875	2	60	315
2	VIGOROUS	VIGOROUS	0	1	0	2	0	510
3	VIGOROUS	VIGOROUS	0	1	0	2	45	300
4	MODERATE	MODERATE	0	0	1	2	150	300
5	MODERATE	MODERATE	0	0.125	0.875	2	0	30
6	VIGOROUS	VIGOROUS	0	1	0	2	150	315
7	MODERATE	VIGOROUS	0	0.900	0.100	1	50	180
8	MODERATE	LOW	1	0	0	1	30	60
9	MODERATE	MODERATE	0.143	0	0.857	2	60	20
10	LOW	LOW	1	0	0	2	0	45
11	VIGOROUS	VIGOROUS	0	1	0	1	540	450
12	VIGOROUS	VIGOROUS	0	0.900	0.100	2	180	150

Gambar 8. Ringkasan Output Hasil Pengujian *Cross Validation* Data IPAQ

Tabel 4. *Confusion Matrix* Berdasarkan Waktu Aktivitas Fisik

accuracy: 74.05% +/- 12.87% (micro average: 73.77%)

	true MODERATE	true LOW	true VIGOROUS	class precision
pred. MODERATE	22	4	6	68.75%
pred. LOW	2	4	0	66.67%
pred. VIGOROUS	4	0	19	82.61%
class recall	78.57%	50.00%	76.00%	

Keterangan :

V = Pred Vigorous

L= Pred Low

M = Pred Moderate

Hasil analisis percobaan selanjutnya yaitu berdasarkan data set atribut kalkulasi kuesioner pada setiap klasifikasi aktivitas fisik. Sebagaimana pada tabel 2 untuk pred M – true M jumlah data record yang diprediksi termasuk klasifikasi aktivitas fisik moderat 22 data sesuai atau benar, sementara 4 data diprediksi termasuk pada klasifikasi aktivitas fisik low dan 6 data diprediksi termasuk pada klasifikasi aktivitas fisik vigorous. Artinya bahwa algoritma *decision tree* yang digunakan untuk mengklasifikasi aktivitas fisik vigorous berdasarkan kakulasi kuesioner aktivits fisik memiliki akurasi sebesar 78,57%. Selanjutnya untuk prediksi klasifikasi aktivitas fisik low (pred L – true L) yaitu sebanyak 4 data benar diklasifikasikan pada aktivitas fisik low dan 2 data diklasifikasikan pada aktivitas fisik moderat dengan kebenaran klasifikasi sebesar 50.00%. Sementara itu untuk (pred V – true V) yaitu sebanyak 19 data record benar diklasifikasikan pada aktivitas fisik vigorous dan 4 data record diklasifikasikan pada aktivitas fisik moderate dengan kebenaran klasifikasi sebesar 76,00%. Hasil analisis percobaan jumlah *true positive* atau jumlah *record* yang berhasil diprediksi dengan benar yaitu sebanyak 46 data *record*. Adapun jumlah seluruh data record yaitu sebanyak 61 data record, sehingga dapat dihitung akurasinya yaitu $(46/61) \cdot 100\% = 73,77\%$.

Pembahasan

Tujuan Penelitian ini mengkaji perbedaan klasifikasi level aktivitas fisik berbasis data *accelerometer ActiGraph* dan kuesioner dengan analisis metode *machine learning*. Adapun model algoritma yang digunakan untuk klasifikasi yaitu *decision tree*. Temuan penelitian menunjukkan bahwa algoritma *decision tree* dapat mengklasifikasi level aktivitas fisik berdasarkan atribut waktu aktivitas dengan sumber dataset *accelerometer* maupun kuesioner. Performa algoritma *decision tree* untuk mengklasifikasi level aktivitas fisik dimulai dari rentang 73% sampai dengan lebih dari 98%.

Hasil dari penelitian ini sejalan dengan penelitian sebelumnya yang mengklasifikasi aktivitas fisik menggunakan metode *machine learning* menggunakan teknik *machine learning* dan sensor dengan melibatkan tiga puluh partisipan. Hasil temuan penelitiannya menunjukkan bahwa metode yang digunakan memiliki tingkat kinerja yang sangat tinggi di atas 96% dan mampu mengklasifikasikan aktivitas kehidupan sehari-hari (Alsareii et al., 2022). Penelitian sejalan lainnya mengenai klasifikasi aktivitas fisik menggunakan metode *classical machine* dan *deep learning*, yang berfokus pada memprediksi aktivitas fisik berdasarkan informasi konteks yang dikumpulkan oleh sensor seperti giroskop dan *accelerometer*, menemukan bahwa *machine learning* model *deep neural network* mencapai kinerja akurasi yang konsisten secara keseluruhan dan kuat dibandingkan dengan teknik pengklasifikasian lainnya akurasi yang diperoleh hingga 96,81% dan rata-rata kesalahan absolut hingga 0,03 pada dataset UCI-HAR. (Bozkurt, 2022). Lebih lanjut kajian mengenai klasifikasi aktivitas fisik berdasarkan data akselerasi mentah dari GENE (Gravity Estimator of Normal EverydayActivity) dengan menggunakan perangkat lunak *Waikato Environment for Knowledge Analysis (WEKA)* yang melibatkan 60 partisipan, memperoleh hasil bahwa algoritma *machine learning* dapat mengklasifikasikan aktivitas fisik secara akurat sebesar 95,8% (Zhang et al., 2012).

Adapun kajian sejalan lainnya yang memanfaatkan sumber dataset IPAQ guna mengklasifikasi level aktivitas fisik dengan menggunakan beberapa teknik *machine learning* menunjukkan bahwa akurasi

algoritma memiliki akurasi antara 89% sampai dengan 99% (Galasso et al., 2023). Lebih lanjut temuan lainnya yang bertujuan mengembangkan klasifikasi baru menggunakan algoritma *machine learning* untuk memprediksi IPAQ dengan tiga model algoritma *machine learning* menunjukkan akurasi klasifikasi masing-masing 95%, 99%, dan 89% (Rivera et al., 2022). Artinya bahwa dataset yang berasal dari sumber sejenis dapat menghasilkan performa akurasi berbeda-beda, tergantung pada algoritma *machine learning* yang digunakan. Namun demikian berdasarkan beberapa penelitian tentang aktivitas fisik menggunakan metode *machine learning* rata-rata kinerja yang diperoleh menunjukkan hasil yang baik (Aziz et al., 2021).

Lebih lanjut, temuan lainnya yaitu bahwa performa akurasi model *decision tree* berbasis sumber data set *accelerometer* Actigraph GT3X lebih tinggi yaitu 98,36% dibandingkan dengan sumber data set kuesioner IPAQ 73,77%. Data set dari hasil pengukuran secara langsung memungkinkan prediksi akurasi klasifikasi aktivitas fisik lebih baik. Meskipun demikian, penelitian lain menemukan bahwa pengukuran secara langsung untuk mengklasifikasi level aktivitas fisik dapat dilakukan dengan teknik *machine learning* dan memiliki korelasi dengan pengukuran tidak langsung menggunakan IPAQ (Rivera et al., 2023). Pengukuran secara langsung dapat mendukung validitas pengukuran tidak langsung dengan menggunakan IPAQ dalam memprediksi klasifikasi aktivitas fisik.

Limitasi utama dari penelitian ini adalah terbatasnya jumlah partisipan yang terlibat. Selain itu, bahwa atribut yang digunakan untuk mengklasifikasi hanya terbatas pada waktu aktivitas yang terekam pada *accelerometer* dan jawaban dari responden terhadap kuesioner yang diberikan. Pengamatan secara langsung terhadap aktivitas fisik partisipan diperlukan guna memperoleh validitas yang lebih baik. Analisis terhadap atribut lainnya juga diperlukan untuk memperoleh informasi lengkap terkait prediksi level aktivitas fisik. Sebagaimana temuan penelitian sebelumnya bahwa tingkat pendidikan, jenis kelamin, dan usia memengaruhi perbedaan antara PA dan perilaku sedentary yang diukur dengan kuesioner (IPAQ-S) dan PA yang diukur dengan akselerometer (Dyrstad et al., 2014). Selain itu, variasi usia partisipan juga diperlukan pada penelitian lebih lanjut sehingga hasil kajian dapat digeneralisasi secara luas dan tidak terbatas pada kelompok usia tertentu saja.

SIMPULAN

Studi ini membuktikan bahwa klasifikasi level aktivitas fisik berbasis data pengukuran langsung menggunakan *accelerometer* Actigraph dan tidak langsung menggunakan IPAQ melalui metode *machine learning* memiliki akurasi prediksi klasifikasi yang baik. Data dari pengukuran secara langsung memiliki akurasi performa lebih baik dibandingkan dengan data hasil pengukuran tidak langsung meskipun menggunakan algoritma yang sama, yaitu dalam penelitian ini menggunakan *decision tree*. Artinya bahwa sumber data dan instrumen yang digunakan untuk mengklasifikasi level aktivitas fisik berpengaruh terhadap hasil dan performa akurasinya.

DAFTAR PUSTAKA

- Ahmed, A., Aziz, S., Qidwai, U., Farooq, F., Shan, J., Subramanian, M., ... & Sheikh, J. (2022). Wearable Artificial Intelligence for Assessing Physical Activity in High School Children. *Sustainability*, 15(1), 638.
- Ainsworth, B., Cahalin, L., Buman, M., & Ross, R. (2015). The current state of physical activity assessment tools. *Progress in cardiovascular diseases*, 57(4), 387-395.
- Alsareii, S. A., Awais, M., Alamri, A. M., AlAsmari, M. Y., Irfan, M., Aslam, N., & Raza, M. (2022). Physical Activity Monitoring and Classification Using Machine Learning Techniques. *Life*, 12(8).
- Anderson, A. A., Yoo, H., & Franke, W. D. (2016). Associations of physical activity and obesity with the risk of developing the metabolic syndrome in law enforcement officers. *Journal of occupational and environmental medicine*, 58(9), 946-951.
- Arnold, M., Leitzmann, M., Freisling, H., Bray, F., Romieu, I., Renehan, A., & Soerjomataram, I. (2016). Obesity and cancer: an update of the global impact. *Cancer epidemiology*, 41, 8-15.
- Avgerinos, K. I., Spyrou, N., Mantzoros, C. S., & Dalamaga, M. (2019). Obesity and cancer risk: Emerging biological mechanisms and perspectives. *Metabolism*, 92, 121-135.
- Aziz, F., Usman, S., & Jeffry, J. (2021). Klasifikasi Physical Activity Berbasis Sensor

Accelerometer, Gyroscope, dan Gravity menggunakan Algoritma Multi-class Ensemble GradientBoost. *Jurnal Media Informatika Budidarma*, 5(4), 1265.

Bertapelli, F., Pitetti, K., Agiovlasitis, S., & Guerra-Junior, G. (2016). Overweight and obesity in children and adolescents with Down syndrome—prevalence, determinants, consequences, and interventions: A literature review. *Research in developmental disabilities*, 57, 181-192.

Bhupathiraju, S. N., & Hu, F. B. (2016). Epidemiology of obesity and diabetes and their cardiovascular complications. *Circulation research*, 118(11), 1723-1735.

Bozkurt, F. (2022). A Comparative Study on Classifying Human Activities Using Classical Machine and Deep Learning Methods. *Arabian Journal for Science and Engineering*, 47(2), 1507-1521.

Caussy, C., Pattou, F., Wallet, F., Simon, C., Chalopin, S., Telliarn, C., ... & Disse, E. (2020). Prevalence of obesity among adult inpatients with COVID-19 in France. *The Lancet Diabetes & Endocrinology*, 8(7), 562-564.

Chandler, J. L., Brazendale, K., Beets, M. W., & Mealing, B. A. (2016). Classification of physical activity intensities using a wrist-worn accelerometer in 8-12-year-old children. *Pediatric Obesity*, 11(2), 120-127.

Colditz, G. A., & Peterson, L. L. (2018). Obesity and cancer: evidence, impact, and future directions. *Clinical chemistry*, 64(1), 154-162.

Ellis, K., Godbole, S., Marshall, S., Lanckriet, G., Staudenmayer, J., & Kerr, J. (2014). Identifying active travel behaviors in challenging environments using GPS, accelerometers, and machine learning algorithms. *Frontiers in Public Health*, 2(APR), 1-8.

Flegal, K. M., Kruszon-Moran, D., Carroll, M. D., Fryar, C. D., & Ogden, C. L. (2016). Trends in obesity among adults in the United States, 2005 to 2014. *Jama*, 315(21), 2284-2291.

Fryar, C. D., Carroll, M. D., & Ogden, C. L. (2018). Prevalence of overweight, obesity, and severe obesity among children and adolescents aged 2-19 years: United States, 1963-1965 through 2015-2016.

Hagenbuchner, M., Cliff, D. P., Trost, S. G., Van Tuc, N., & Peoples, G. E. (2015). Prediction of activity type in preschool children using machine learning techniques. *Journal of Science and Medicine in Sport*, 18(4), 426-431.

Hagstromer, M., Ainsworth, B. E., Oja, P., & Sjostrom, M. (2010). Comparison of a subjective and an objective measure of physical activity in a population sample. *Journal of Physical Activity and Health*, 7(4), 541-550.

Jiang, S. Z., Lu, W., Zong, X. F., Ruan, H. Y., & Liu, Y. (2016). Obesity and hypertension. *Experimental and therapeutic medicine*, 12(4), 2395-2399.

Katzmarzyk, P. T., Barreira, T. V., Broyles, S. T., Champagne, C. M., Chaput, J. P., Fogelholm, M., ... & Church, T. S. (2015). Physical activity, sedentary time, and obesity in an international sample of children. *Med Sci Sports Exerc*, 47(10), 2062-9.

Koliaki, C., Liatis, S., & Kokkinos, A. (2019). Obesity and cardiovascular disease: revisiting an old relationship. *Metabolism*, 92, 98-107.

Liang, Y., Hou, D., Zhao, X., Wang, L., Hu, Y., Liu, J., ... & Mi, J. (2015). Childhood obesity affects adult metabolic syndrome and diabetes. *Endocrine*, 50, 87-92.

Long, X., Yin, B., & Aarts, R. M. (2009). Single-accelerometer-based daily physical activity classification. *Proceedings of the 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society: Engineering the Future of Biomedicine, EMBC 2009*, 6107-6110.

Maher, C. A., Davis, C. R., Curtis, R. G., Short, C. E., & Murphy, K. J. (2020). A physical activity and diet program delivered by artificially intelligent virtual health coach: proof-of-concept study. *JMIR mHealth and uHealth*, 8(7), e17558.

Mannini, A., & Sabatini, A. M. (2010). Machine learning methods for classifying human physical activity from on-body accelerometers. *Sensors*, 10(2), 1154-1175.

Maswadi, K., Ghani, N. A., Hamid, S., & Rasheed, M. B. (2021). Human activity classification using Decision Tree and Naive Bayes classifiers. *Multimedia Tools and Applications*, 80, 21709-21726.

Murdoch, W. J., Singh, C., Kumbier, K., Abbasi-Asl, R., & Yu, B. (2019). Definitions, methods, and applications in interpretable machine learning. *Proceedings of the National Academy of Sciences of the United States of America*, 116(44), 22071-22080.

Ogden, C. L., Carroll, M. D., Lawman, H. G., Fryar, C. D., Kruszon-Moran, D., Kit, B. K., & Flegal,

K. M. (2016). Trends in obesity prevalence among children and adolescents in the United States, 1988-1994 through 2013-2014. *Jama*, *315*(21), 2292-2299.

Ogden, C. L., Fakhouri, T. H., Carroll, M. D., Hales, C. M., Fryar, C. D., Li, X., & Freedman, D. S. (2017). Prevalence of obesity among adults, by household income and education—United States, 2011–2014. *Morbidity and Mortality Weekly Report*, *66*(50), 1369.

Ortega, F. B., Lavie, C. J., & Blair, S. N. (2016). Obesity and cardiovascular disease. *Circulation research*, *118*(11), 1752-1770.

Patsalos, O., Keeler, J., Schmidt, U., Penninx, B. W., Young, A. H., & Himmerich, H. (2021). Diet, obesity, and depression: a systematic review. *Journal of personalized medicine*, *11*(3), 176.

Pedišić, Ž., & Bauman, A. (2015). Accelerometer-based measures in physical activity surveillance: current practices and issues. *British journal of sports medicine*, *49*(4), 219-223.

Prince, S. A., Adamo, K. B., Hamel, M. E., Hardt, J., Gorber, S. C., & Tremblay, M. (2008). A comparison of direct versus self-report measures for assessing physical activity in adults: a systematic review. *International journal of behavioral nutrition and physical activity*, *5*(1), 1-24.

Prince, S. A., Adamo, K. B., Hamel, M. E., Hardt, J., Gorber, S. C., & Tremblay, M. (2008). A comparison of direct versus self-report measures for assessing physical activity in adults: a systematic review. *International journal of behavioral nutrition and physical activity*, *5*(1), 1-24.

Quek, Y. H., Tam, W. W., Zhang, M. W., & Ho, R. C. (2017). Exploring the association between childhood and adolescent obesity and depression: a meta-analysis. *Obesity reviews*, *18*(7), 742-754.

Rainham, D. G., Bates, C. J., Blanchard, C. M., Dummer, T. J., Kirk, S. F., & Shearer, C. L. (2012). Spatial classification of youth physical activity patterns. *American Journal of Preventive Medicine*, *42*(5), 1–10.

Ramdani, R., Jajat, J., Sutisna, N., Sudrazat, A., & Risma, R. (2019). Aktivitas Fisik dan Body Mass Index Pada Anak Usia Dini: Pengukuran METs dengan Accelerometer ActivPAL. *Jurnal Keolahragaan*, *5*(2), 45.

Rivera, O., Avilés, O. F., & Castillo-Castaneda, E. (2023). Classifying the physical activity indicator using machine learning and direct measurements: a feasibility study. *Acta Scientiarum. Technology*, *45*, e61317-e61317.

Rivera, O., Castillo-Castaneda, E., Avilés, O. F., & Hernández, R. (2022). Index of Physical activity and Fall Efficacy scale classification through biomechanical signals and Machine Learning. *Journal of Engg. Research Online First Article*, *1*.

Sahoo, K., Sahoo, B., Choudhury, A. K., Sofi, N. Y., Kumar, R., & Bhadoria, A. S. (2015). Childhood obesity: causes and consequences. *Journal of family medicine and primary care*, *4*(2), 187.

Seravalle, G., & Grassi, G. (2017). Obesity and hypertension. *Pharmacological research*, *122*, 1-7.

Sheng, B., Moosman, O. M., Del Pozo-Cruz, B., Del Pozo-Cruz, J., Alfonso-Rosa, R. M., & Zhang, Y. (2020). A comparison of different machine learning algorithms, types and placements of activity monitors for physical activity classification. *Measurement*, *154*, 107480.

Skinner, A. C., Ravanbakht, S. N., Skelton, J. A., Perrin, E. M., & Armstrong, S. C. (2018). Prevalence of obesity and severe obesity in US children, 1999–2016. *Pediatrics*, *141*(3).

Strath, S. J., Kaminsky, L. A., Ainsworth, B. E., Ekelund, U., Freedson, P. S., Gary, R. A., ... & Swartz, A. M. (2013). Guide to the assessment of physical activity: clinical and research applications: a scientific statement from the American Heart Association. *Circulation*, *128*(20), 2259-2279.

Troiano, R. P., Berrigan, D., Dodd, K. W., Masse, L. C., Tilert, T., & McDowell, M. (2008). Physical activity in the United States measured by accelerometer. *Medicine and science in sports and exercise*, *40*(1), 181.

van Doorn, W. P., Foreman, Y. D., Schaper, N. C., Savelberg, H. H., Koster, A., van der Kallen, C. J., ... & Brouwers, M. C. (2021). Machine learning-based glucose prediction with use of continuous glucose and physical activity monitoring data: The Maastricht Study. *PloS one*, *16*(6), e0253125.

Verma, S., & Hussain, M. E. (2017). Obesity and diabetes: an update. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, *11*(1), 73-79.

Warburton, D. E., Nicol, C. W., & Bredin, S. S. (2006). Health benefits of physical activity: the evidence. *Cmaj*, *174*(6), 801-809.

Weihrauch-Blüher, S., Schwarz, P., & Klusmann, J. H. (2019). Childhood obesity: increased risk

for cardiometabolic disease and cancer in adulthood. *Metabolism*, 92, 147-152.

Wiklund, P. (2016). The role of physical activity and exercise in obesity and weight management: Time for critical appraisal. *Journal of sport and health science*, 5(2), 151-154.

Williams, E. P., Mesidor, M., Winters, K., Dubbert, P. M., & Wyatt, S. B. (2015). Overweight and obesity: prevalence, consequences, and causes of a growing public health problem. *Current obesity reports*, 4, 363-370.

Zhang, S., Rowlands, A. V., Murray, P., & Hurst, T. L. (2012). Physical activity classification using the GENE wrist-worn accelerometer. *Medicine and Science in Sports and Exercise*, 44(4), 742-748.

Zhang, T., Tang, W., & Sazonov, E. S. (2012, August). Classification of posture and activities by using decision trees. In *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 4353-4356). IEEE.

PROFIL SINGKAT

Sebagai penulis utama pada artikel ini, Humaira Azzahra Putri Mulyana merupakan seorang mahasiswi dan putri dari Bapak Rudi Mulyana yang lahir di Bandung pada tanggal 27, bulan Januari, tahun 2023. Saat ini Humaira sedang menyelesaikan studi pada jenjang program sarjana (S1) pada Program Studi Ilmu Keolahragaan (Prodi Ikor), Fakultas Pendidikan Olahraga dan Kesehatan (FPOK), Universitas Pendidikan Indonesia. Diterima di Prodi Ikor pada tahun akademik 2020/2022, pada tahun ke-3 semester 7 tahun 2023 Humaira memasuki tahap akhir penyelesaian studi dengan mengambil jalur publikasi. Selain menjalani aktivitas sebagai mahasiswa, Humaira juga memiliki aktivitas lainnya yaitu sebagai coach renang di salah satu club renang di Bandung.

Adapun penulis lainnya dalam artikel ini yaitu Prof. Dr. Adang Suherman, MA., Dr. Jajat, S.Si., M.Pd., merupakan dosen pembimbing 1 dan 2 dalam menyelesaikan tugas akhir. Sementara Dr., dr. Imas Damayanti, M.Kes., Kuston Sul-toni, S.Si, M.Pd., Dra. Yati Ruhayati, M.Pd., dan Dr. Nur Indri Rahayu, M.Ed. merupakan kontributor yang berperan dalam memberikan saran dan masukan serta kontributor data dalam penulisan artikel ini dan tergabung pada kelompok bidang keilmuan aktivitas fisik Prodi Ikor FPOK Universitas Pendidikan Indonesia.