



**Klasifikasi Aktivitas Fisik Berbasis Data *Accelerometer* *ActivPAL* dan *ActiGraph*:
Metode Analisis dengan *Machine Learning***

**Agum Sholahuddin¹, Jajat², Imas Damayanti³, Kuston Sultoni⁴, Adang Suherman⁵,
Nur Indri Rahayu⁶, Yati Ruhayati⁷, Mohammad Zaky⁸**

^{1,2,3,4,5,6,7,8} **Universitas Pendidikan Indonesia, Jawa Barat, Indonesia**

Jl. Dr. Setiabudi No.229, Isola, Kec. Sukasari, Kota Bandung, Jawa Barat 40152

Email: 06agum@upi.edu

Abstrak

Aktivitas fisik secara teratur dapat memberikan dampak positif terhadap kesehatan pada semua golongan usia. Saat ini sudah banyak penelitian terkait pengukuran aktivitas fisik yang dilakukan dengan memanfaatkan kecerdasan buatan (*Artificial Intelligence*) salah satunya menggunakan *machine learning* dalam mengklasifikasi aktivitas fisik. Studi ini bertujuan menganalisis klasifikasi aktivitas fisik menggunakan *machine learning* dengan sumber data *accelerometer* *ActivPAL* dan *ActiGraph* GT3X. Partisipan dalam penelitian ini 105 siswa Sekolah Menengah Atas berusia antara 17-19 Tahun. Penelitian ini menggunakan algoritma *Machine learning Decision tree*. Hasil analisis data menunjukkan akurasi sebesar 56,25% pada instrumen *ActivPAL* dan 93,33% pada instrumen *ActiGraph*. Performa akurasi *decision tree* sangat baik dalam mengklasifikasi aktivitas fisik yang bersumber dari data *accelerometer* *ActiGraph* dibandingkan dengan *accelerometer* *ActivPAL*. Selain waktu aktivitas fisik dan *sedentary*, jenis kelamin merupakan *predictor* lain untuk mengklasifikasi aktif atau tidaknya seseorang.

Kata Kunci: Artificial Intelligence, Decision Tree, Sedentari

PENDAHULUAN

Semakin berkembangnya zaman yang diikuti oleh teknologi modern ini memberi dampak positif dan negatif terhadap kehidupan (Bosamia, M. 2013). Dilihat dari dampak positif banyaknya kegiatan yang menjadi lebih mudah dan instan seperti penggunaan gadget yang memberi fitur berbelanja tanpa harus berpergian keluar (Hertzog, C. et al., 2008). Sedangkan dampak negatifnya yaitu orang-orang akan menjadi malas untuk bergerak dan hanya berfokus pada gadgetnya sehingga akan membawa pengaruh buruk terhadap kemampuan bersosialisasi nya (Naser Olimat, S. 2013). Dan ternyata semakin berkembangnya teknologi semakin banyak juga dampak yang diberikan, baik dari sisi positif maupun negatif terhadap aktifitas fisik dan kebugaran jasmani seseorang.

Melakukan Aktifitas fisik dapat memberikan dampak positif terhadap kebugaran jasmani (Ratey, J. J., & Loehr, J. E., 2011). Selain itu melakukan aktifitas fisik secara teratur juga memiliki manfaat terhadap kesehatan pada semua golongan usia (Warburton, D. E. et al., 2006). Dibalik dari dampak positif melakukan aktifitas fisik secara teratur, ternyata

ada juga dampak dari kurangnya melakukan aktifitas fisik khususnya pada anak yaitu kebugaran jasmani akan terganggu, pengalaman dan keterampilan gerakanya juga berkurang, baik dari sisi gerak lokomotor maupun nonlokomotor (Tanha, T et al., 2011). Kurangnya aktifitas fisik juga merupakan faktor yang mendorong seseorang mengidap penyakit kronis seperti penyakit jantung, stroke, diabetes melitus tipe 2, obesitas dan kanker payudara yang secara keseluruhan diperkirakan dapat menyebabkan kematian secara global (Booth, F. W. et al., 2012). Selain akibat dari penyakit kronis, kematian tertinggi di dunia di sebabkan oleh kurangnya melakukan aktifitas fisik (WHO, 2020). Hal ini menunjukkan bahwa melakukan aktivitas fisik penting untuk menjaga kesehatan dan menghindari seseorang terkena berbagai penyakit.

Aktivitas fisik adalah segala kegiatan atau aktivitas yang menyebabkan peningkatan energi oleh tubuh dan melampaui energi istirahat (Haskell et al., 2007). Aktifitas fisik yang dapat dilakukan setiap golongan usia yaitu aktifitas fisik ringan seperti berjalan, berlari, bersepeda dan naik-turun tangga yang manfaatnya baik untuk kesehatan (Powell, K. E., et al., 2011).

Untuk melakukan aktifitas fisik yang memerlukan energi berbeda-beda tergantung dari jenis aktifitas fisik yang dilakukan mulai dari aktifitas fisik ringan, sedang, berat dan sangat berat (Long, X., Yin, B., & Aarts, R. M., 2009).

Beberapa penelitian terkait pengukuran aktifitas fisik sudah dilakukan, salah satu instrumen yang digunakan adalah *accelerometers ActivPAL* dan *ActiGraph*. Peneliti saat ini lebih sering menggunakan *accelerometer* sebagai alat pengukur aktifitas fisik seseorang karena dapat menghasilkan data yang akurat serta penggunaannya yang efektif (Lee, I. M., & Shiroma, E. J., 2014). *Accelerometer* merupakan suatu alat yang berfungsi mengubah gerakan fisik agar sebanding dengan kekuatan otot saat melakukan gerakan (Melanson & Freedson, 1996). *Accelerometers ActivPAL* merupakan *accelerometer* yang sudah banyak digunakan untuk mengukur aktivitas fisik (Arvidsson, D., et al., 2019). Seperti perubahan postur tubuh, merekam banyaknya jumlah langkah dan irama jalan serta mengestimasi pengeluaran energi dalam satuan METs (Bussmann, J. B. et al, 2009). Selain untuk mengukur aktifitas fisik *Accelerometer ActivPAL* juga dapat mengukur durasi tidur dan perilaku *sedentary* (Dowd, K. P. et al., 2012). Saat ini peneliti lebih sering menggunakan *accelerometer* sebagai alat pengukur aktifitas fisik seseorang karena dapat menghasilkan data yang akurat serta penggunaannya yang efektif (Murphy, S. L. 2009).

Accelerometer ini biasa digunakan pada bagian paha, pergelangan tangan ataupun pada pinggang (Rainham et al., 2012; Sara et al., 2020; Xi Long, 2009).

Accelerometer ActivPAL juga memiliki kekurangan yaitu tidak akurat dalam mengukur beberapa aktivitas seperti bersepeda dan aktivitas di dalam air (Harrington, D. M et al., 2011). Berbeda dengan *accelerometer ActiGraph* yang dirancang khusus untuk mengukur intensitas aktivitas fisik dan pola tidur seseorang (Quante, M. et al., 2015). *Accelerometer* ini digunakan pada pergelangan tangan dan mampu merekam gerakan tubuh dengan akurasi yang tinggi (Yang, C. C., & Hsu, Y. L. 2010). Dalam *accelerometer* ini ada potensi ketidakakuratan pada saat pengukuran, jika pemasangannya tidak benar maka pada saat terkena guncangan dan getaran akan menghasilkan data yang tidak akurat.

Saat ini banyak peneliti yang memanfaatkan kecerdasan buatan untuk melakukan pengolahan data termasuk untuk pengukuran aktivitas fisik, salah satunya yaitu machine learning. *Machine learning* merupakan aplikasi buatan *Artificial Intelligence* (AI) yang memberikan fitur untuk meningkatkan kemampuan secara otomatis dari pengalaman tanpa harus diprogram secara sistematis (Cioffi, R. et al., 2020). *Machine learning* ini memiliki kelebihan yaitu dapat memperoleh hasil yang murni dan spesifik juga dapat memecahkan berbagai masalah dalam penelitian (Ellis et al., 2014., Roihan et al., 2019).

Dilihat dari fungsinya *Machine learning* digunakan untuk menganalisis prediksi, klasifikasi, kuantifikasi dan lainnya. Berdasarkan sumber data dan instrumen yang digunakan, hasilnya cukup bervariasi. Hal ini menunjukkan bahwa sumber data dan jenis instrumen yang digunakan untuk mengukur aktivitas fisik akan menentukan tingkat akurasi prediksi aktivitas fisik. Di Indonesia sendiri penelitian tentang perbandingan klasifikasi aktivitas fisik berbasis data *accelerometer ActivPAL* dan *ActiGraph* dengan analisis *machine learning* hampir tidak ada dan kebanyakan penelitian di Indonesia hanya menggunakan kuesioner. Oleh karena itu, penelitian ini menganalisis klasifikasi aktivitas fisik menggunakan *machine learning* dengan sumber data *accelerometer ActivPAL* dan *ActiGraph GT3X*.

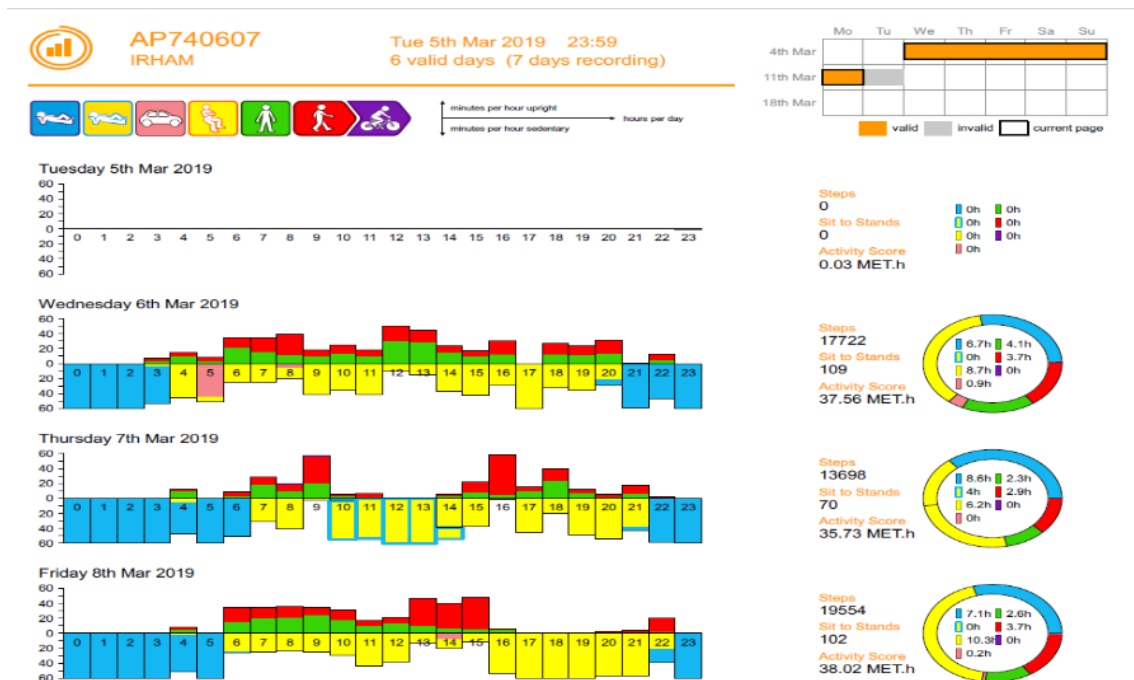
METODE PENELITIAN

Studi ini menganalisis perbedaan performa *machine learning decision tree* dalam mengklasifikasi aktivitas fisik, antara data dari *accelerometer ActivPAL* dengan

ActiGraph. Perbedaan performa diuji dengan analisis *confusion matrix* yang terdiri atas akurasi, sensitifitas, dan spesifisitas.

Data set aktivitas fisik yang digunakan dalam penelitian ini berasal dari Kelompok Bidang Keilmuan (KBK) aktivitas fisik pada program studi Ilmu Keolahragaan, Universitas Pendidikan Indonesia. Salah satu kajian KBK yaitu aktivitas fisik keseharian (*daily physical activity*) masyarakat pada berbagai jenjang usia. Instrument yang digunakan untuk mengukur aktivitas fisik keseharian diantaranya kuesioner dan *accelerometer*.

Sesuai dengan permasalahan penelitian, data set aktivitas fisik yang digunakan dalam penelitian ini yaitu data aktivitas fisik keseharian yang diukur dengan *accelerometer* ActivPAL dan ActiGraph GT3X. Jumlah partisipan penelitian yaitu 181 orang siswa Sekolah Menengah Atas berusia antara 17-19 Tahun. Berdasarkan hasil verifikasi data hasil perekaman *accelerometer*, jumlah data yang valid yaitu 54 orang partisipan untuk data *accelerometer* ActivPAL, dan 51 orang partisipan untuk data *accelerometer* ActiGraph. Hasil perekaman selanjutnya diunduh dan dianalisis dengan menggunakan PAL Analysis untuk ActivPAL (Gambar 1) dan ActiLife untuk ActiGraph (Gambar 2).



Gambar 1. Hasil Analisis Aktivitas Fisik dengan Software PAL Analysis

Worn on Wrist?	Activity kcals	Average kcals per day	Average kcals per hour	MET Rate	Total Sedentary Bouts	Total Length of Sedentary Bouts	Average Length of Sedentary Bouts	Max Length of Sedentary Bouts
<input type="checkbox"/>	60868055438617933,361	7608506929827241,670	362309853801297,222	1,237	132	2D 1H 48M 20S	22M 38S	1H 20M 30S
<input type="checkbox"/>	60868055438617933,361	7608506929827241,670	362309853801297,222	1,237	132	2D 1H 48M 20S	22M 38S	1H 20M 30S

Gambar 2. Hasil Analisis Aktivitas Fisik dengan Software ActiLife

Level aktivitas fisik merupakan variabel utama dalam penelitian ini. Level aktivitas yang diuji diklasifikasikan menjadi dua, yaitu aktif dan tidak aktif melakukan aktivitas fisik. Klasifikasi aktif dan tidak aktif mengacu pada pedoman aktivitas fisik dan perilaku sedentari yang dikeluarkan oleh *World Health Organization* (WHO). Klasifikasi dibagi ke dalam dua kategori yaitu aktif dan tidak aktif. Sebagaimana rekomendasi WHO bahwa untuk remaja setidaknya harus melakukan aktivitas fisik moderat hingga kuat 60 menit perhari, sementara untuk aktivitas sedentari tidak lebih dari 60 menit secara berturut-turut (WHO, 2020).

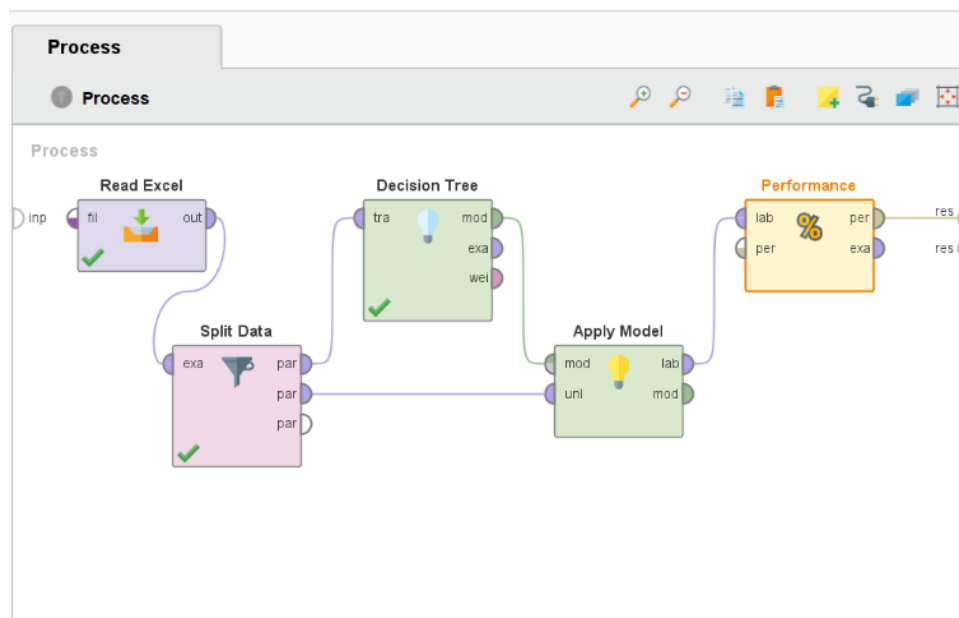
Variabel prediktor yang digunakan untuk mengklasifikasi aktivitas fisik dari data *accelerometer* ActivPAL yaitu gender, waktu berdiri, waktu melangkah, waktu duduk, dan waktu rebahan (*laying time*). Sementara prediktor untuk data dari *accelerometer* ActiGraph yaitu gender, waktu aktivitas sedentari, waktu aktivitas fisik ringan, waktu aktivitas fisik sedang, dan waktu aktivitas fisik tinggi. Kalkulasi waktu dari masing-masing variabel prediktor diperoleh dari hasil unduhan dan analisis software masing-masing *accelerometer* sebagaimana dijelaskan.

Data dalam penelitian ini diperoleh dengan cara melakukan eksperimen pada usia remaja dengan menggunakan *accelerometer* ActivPAL dan ActiGraph. *Accelerometer* ActivPAL dan ActiGraph sudah banyak digunakan untuk mengukur aktifitas fisik karena menghasilkan data yang akurat dan penggunaannya yang efektif (Anggunadi & Sutarina, 2017; Kurniawan et al., 2019). *Accelerometer* ActivPAL ini biasa digunakan pada bagian paha kanan sedangkan *accelerometer* ActiGraph pada bagian pinggang selama 5 hari,

kedua instrument accelerometer tersebut akan menghasilkan rekaman aktifitas fisik yang dilakukan oleh sampel.

Algoritma *machine learning* yang digunakan dalam penelitian ini yaitu *decision tree*. Pada beberapa penelitian sebelumnya, algoritma *decision tree* diyakini memiliki akurasi yang baik dalam mengklasifikasi aktivitas fisik (Biswas et al., 2021; Maswadi et al., 2021; Trost et al., 2016; Zhang et al., 2021). Selain menghasilkan performa akurasi prediksi maupun klasifikasi, *decision tree* menghasilkan pohon keputusan mengenai atribut atau prediktor apa saja yang digunakan untuk mengklasifikasi aktivitas fisik. Analisis dan pengujian dilakukan dengan menggunakan software Rapidminer yang telah banyak digunakan dalam analisis machine learning.

Untuk melatih model data peneliti menggunakan data yang telah diproses sebelumnya. Jumlah data yang digunakan yaitu sebanyak 54 data ActivPAL dan 51 data untuk ActiGraph. Jumlah data traini yaitu sebesar 70% untuk masing-masing data, sedangkan data uji sebesar 30% dari masing-masing data. Pembagian data latih dan data uji dilakukan secara otomatis dengan aplikasi Rapidminer yang prosesnya sebagaimana pada gambar 3.

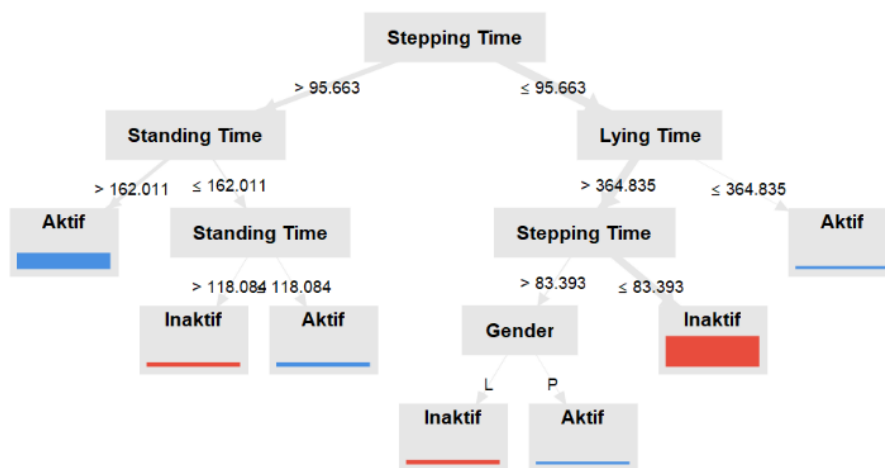


Gambar 3. Proses Split Data dan Pengujian Decision Tree dengan Rapidminer

HASIL DAN PEMBAHASAN

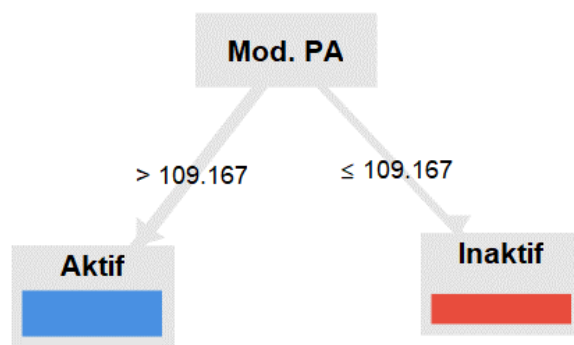
Hasil

Gambar 1 menyajikan pohon keputusan yang dihasilkan dari algoritma *machine learning decision tree* dari data accelerometer ActivPAL. Waktu melangkah (*stepping time*) berada pada posisi paling atas sebagai *root* dari algoritma yang dihasilkan. Artinya bahwa waktu melangka menjadi indikator utama *decision tree* dalam mengklasifikasikan apakah seseorang aktif atau tidak aktif melakukan aktivitas fisik. Jika waktu melangkah lebih dari 95,66 menit, maka untuk melihat seseorang aktif dan tidak selanjutnya dilihat waktu berdirinya (*standing time*). Jika waktu berdirinya >162 menit maka diklasifikasikan aktif. Selain waktu melangkah, waktu rebahan (*laying time*) dan gender juga menjadi factor penentu dari algoritma *decision tree* dalam mengklasifikasikan seseorang aktif atau tidak.



Gambar 4. Hasil Pohon Keputusan Klasifikasi Aktivitas Fisik Data ActivPAL

Berbeda dengan data yang bersumber dari *accelerometer* ActivPAL, pohon keputusan algoritma *machine learning decision tree* yang dihasilkan dari data *accelerometer* ActiGraph lebih sederhana. Sebagaimana pada gambar 4, klasifikasi aktif dan tidak aktif hanya didasarkan pada waktu aktivitas moderat saja. Jika waktu aktivitas fisik moderat > 109,167 menit maka diklasifikasikan aktif, dan jika waktu aktivitas fisik moderat <= 109,167 menit maka diklasifikasikan tidak aktif oleh *decision tree*.



Gambar 2. Hasil Pohon Keputusan Klasifikasi Aktivitas Fisik Data ActiGraph

Selanjutnya yaitu menguji performa yang dihasilkan dari kedua sumber data *accelerometer* ActivPAL dan ActiGraph. Tabel 1 merupakan *confusion matrix* hasil pengujian performa untuk data dari *accelerometer* ActivPAL, dan tabel 2 hasil pengujian data *accelerometer* ActiGraph. Hasil pengujian menunjukkan akurasi algoritma *machine learning decision tree* data *accelerometer* ActivPAL dalam mengklasifikasi aktivitas fisik sebesar 56,25%, sementara sensitifitas 40% dan spesitifitas 63,64%. Hasil pengujian data dari *accelerometer* ActiGraph pada tabel 2 menunjukkan performa akurasi lebih tinggi 93,33%, dengan sensitifitas 90% dan spesifisitas 100%.

Tabel 1. Evaluasi Akurasi, Sensitifitas, dan Spesifisitas Klasifikasi Aktivitas Fisik *Decision Tree* Data ActivPAL

accuracy: 56.25%

	true Aktif	true Inaktif	class precision
pred. Aktif	2	3	40.00%
pred. Inaktif	4	7	63.64%
class recall	33.33%	70.00%	

Tabel 2. Evaluasi Akurasi, Sensitifitas, dan Spesifisitas Klasifikasi Aktivitas Fisik Model *Machine Learning* Data ActiGraph

accuracy: 93.33%

	true Aktif	true Inaktif	class precision
pred. Aktif	9	1	90.00%
pred. Inaktif	0	5	100.00%
class recall	100.00%	83.33%	

PEMBAHASAN

Penelitian ini berfokus pada analisis faktor-faktor yang dapat digunakan untuk mengklasifikasi seseorang aktif atau tidak dalam melakukan aktivitas fisik. Hasil analisis menunjukkan bahwa waktu melangkah, waktu berdiri, dan waktu tiduran/berbaring (*laying time*) menjadi faktor-faktor yang mengklasifikasi aktivitas fisik. Selain itu, waktu aktivitas fisik moderat dan jenis kelamin juga menjadi salah satu faktor penentu klasifikasi aktivitas fisik. Penelitian sebelumnya menemukan bahwa perilaku sedentari (duduk, tiduran/berbaring) berhubungan dengan perilaku aktivitas fisik (Mansoubi et al., 2014). Lebih lanjut bahwa anak laki-laki lebih aktif secara fisik dibandingkan dengan perempuan (Pearson, 2009). Artinya faktor-faktor perilaku sedentari dan gender merupakan salah satu penentu yang mempengaruhi aktivitas fisik.

Penelitian ini juga membandingkan performa akurasi *decision tree* berdasarkan dua jenis instrumen aktivitas fisik accelerometer ActivPAL dan ActiGraph. Hasil pengujian dengan *confusion matrix* menunjukkan bahwa performa algoritma *machine learning decision tree* untuk data accelerometer ActiGraph lebih tinggi daripada data ActivPAL. Selain itu, sensitifitas, dan spesifisitas pengujian dari data ActiGraph jauh lebih unggul dibandingkan dengan ActivPAL. Penelitian sebelumnya yang membandingkan performa *accelerometer* ActivPAL dan ActiGraph menunjukkan bahwa data *ActiGraph* dapat menentukan perilaku *sedentary* dengan akurasi sedang hingga tinggi jika dibandingkan dengan *ActivPAL* (Koster et al., 2016). Temuan lainnya bahwa software ActivPAL memperkirakan aktivitas fisik ringan ditaksir terlalu tinggi dan aktivitas sedang hingga tinggi diestimasi lebih kecil, sedangkan *machine learning Artificial Neural Network* (ANN) memperkirakan waktu aktivitas *sedentary* dan aktivitas fisik ringan berbeda dari kriteria dan aktivitas fisik sedang hingga tinggi ditaksir terlalu tinggi (Felez-Nobrega et al., 2018). Penelitian lainnya secara statistik menemukan perbedaan kecil namun signifikan antara ActivPAL dan ActiGraph dalam mengukur perilaku *sedentary* dan aktivitas fisik (Martin et al., 2011).

Penelitian lain yang mendukung hasil penelitian ini yaitu klasifikasi aktivitas fisik menggunakan *machine learning* berdasarkan data berbasis kuesioner dan *accelerometer* menemukan bahwa penggunaan model *machine learning* dengan metode SVM menunjukkan akurasi yang tinggi, dimana basis data *accelerometer* lebih signifikan dalam kondisi uji statis dibandingkan dengan kondisi uji dinamis (Rivera et al., 2023). Selain

sumber data, ukuran sampel, ukuran fitur serta banyaknya prediktor, jenis algoritma *machine learning* yang digunakan juga menghasilkan performa yang berbeda-beda (Jollans et al., 2019). Kualitas data juga merupakan salah satu faktor yang dapat mempengaruhi perbedaan performa akurasi algoritma *machine learning* (Budach et al., 2022). Artinya bahwa sumber data dan instrumen yang digunakan serta jenis analisis akan menentukan hasil yang mungkin berbeda-beda.

Beberapa limitasi dari penelitian ini diantaranya, jumlah partisipan yang relatif masih terbatas sehingga memungkinkan performa akurasi model *machine learning* dipengaruhi oleh banyaknya data. Selain jumlah, variabilitas karakteristik partisipan juga diperlukan pada penelitian selanjutnya untuk menilai kinerja performa *machine learning*. Selanjutnya bahwa ActiGraph GT3X tidak tahan air, sehingga untuk aktivitas-aktivitas yang berhubungan dengan air harus dilepas sehingga tidak terdeteksi. Diperlukan daftar (*log*) laporan aktivitas yang dilakukan oleh partisipan termasuk lamanya aktivitas yang dilakukan.

KESIMPULAN

Algoritma *machine learning decision tree* dapat mengklasifikasi aktivitas fisik berdasarkan waktu aktivitas keseharian dan waktu sedentari. Performa akurasi *decision tree* sangat baik dalam mengklasifikasi aktivitas fisik yang bersumber dari data accelerometer ActiGraph dibandingkan dengan data dari accelerometer ActivPAL. Selain waktu aktivitas fisik dan sedentary, jenis kelamin juga menjadi salah satu prediktor algoritma *machine learning* dalam mengklasifikasi apakah seseorang termasuk dalam kategori aktif atau tidak aktif.

DAFTAR PUSTAKA

- Bosamia, M. (2013). Positive and negative impacts of information and communication technology in our everyday life. *Dostupno na: [https://www. Research gate.net/publication/325570282_Positive_and_Negative_Impacts_of_Information_and_Communication_Technology_in_our_Everyday_Life](https://www.researchgate.net/publication/325570282_Positive_and_Negative_Impacts_of_Information_and_Communication_Technology_in_our_Everyday_Life)* [30. kolovoza 2021.].
- Hertzog, C., Kramer, A. F., Wilson, R. S., & Lindenberger, U. (2008). Enrichment effects on adult cognitive development: can the functional capacity of older adults be preserved and enhanced?. *Psychological science in the public interest*, 9(1), 1-65.
- Naser Olimat, S. (2013). Positive and negative impact of technology and information revolution on compiling the dictionary. *American academic & scholarly research journal*, 5(3).

- Naser Olimat, S. (2013). Positive and negative impact of technology and information revolution on compiling the dictionary. *American academic & scholarly research journal*, 5(3)
- Ratey, J. J., & Loehr, J. E. (2011). The positive impact of physical activity on cognition during adulthood: a review of underlying mechanisms, evidence and recommendations.
- Warburton, D. E., Nicol, C. W., & Bredin, S. S. (2006). Health benefits of physical activity: the evidence. *Cmaj*, 174(6), 801-809.
- Tanha, T., Wollmer, P., Thorsson, O., Karlsson, M. K., Lindén, C., Andersen, L. B., & Dencker, M. (2011). Lack of physical activity in young children is related to higher composite risk factor score for cardiovascular disease. *Acta paediatrica*, 100(5), 717-721.
- Booth, F. W., Roberts, C. K., & Laye, M. J. (2012). Lack of exercise is a major cause of chronic diseases. *Comprehensive physiology*, 2(2), 1143.
- WHO. (2020). *10 besar penyebab kematian*.
- Haskell, W. L., Lee, I.-M., Pate, R. R., Powell, K. E., Blair, S. N., Franklin, B. A., & Bauman, . . (2007). Physical Activity and Public Health: Updated Recommendation for Adults From the American College of Sports Medicine and the American Heart Association. *Circulation*, 116(9), 1081-1093. <https://doi.org/10.1161/CIRCULATION.107.185649>
- Powell, K. E., Paluch, A. E., & Blair, S. N. (2011). Physical activity for health: What kind? How much? How intense? On top of what?. *Annual review of public health*, 32, 349-365.
- Long, X., Yin, B., & Aarts, R. M. (2009, September). Single-accelerometer-based daily physical activity classification. In *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 6107-6110). IEEE.
- Lee, I. M., & Shiroma, E. J. (2014). Using accelerometers to measure physical activity in large-scale epidemiological studies: issues and challenges. *British journal of sports medicine*, 48(3), 197-201.
- Melanson, E. L., & Freedson, P. S. (1996). Physical Activity Assessment: A Review of Methods. In *Critical Reviews in Food Science and Nutrition* (Vol. 36, Issue 5, pp. 385-396). Taylor and Francis Inc. <https://doi.org/10.1080/10408399609527732>
- Arvidsson, D., Fridolfsson, J., & Börjesson, M. (2019). Measurement of physical activity in clinical practice using accelerometers. *Journal of internal medicine*, 286(2), 137-153.
- Bussmann, J. B., Ebner-Priemer, U. W., & Fahrenberg, J. (2009). Ambulatory activity monitoring: Progress in measurement of activity, posture, and specific motion patterns in daily life. *European Psychologist*, 14(2), 142-152.
- Dowd, K. P., Harrington, D. M., Bourke, A. K., Nelson, J., & Donnelly, A. E. (2012). The measurement of sedentary patterns and behaviors using the ActivPAL™ professional physical activity monitor. *Physiological measurement*, 33(11), 1887.
- Murphy, S. L. (2009). Review of physical activity measurement using accelerometers in older adults: considerations for research design and conduct. *Preventive medicine*, 48(2), 108-114.
- 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). <https://doi.org/10.1016/j.amepre.2012.02.011>
- Sara, K., Risma, R., & Sutisna, N. (2020). Hubungan Durasi Tidur dan Perilaku Sedentari dengan Body Mass Index pada Siswa SMA Negeri 3 Ciamis. *Jurnal Terapan Ilmu Keolahragaan*, 5(2), 120-127. <https://doi.org/10.17509/jtikor.v5i2.27960>

- Xi Long. (2009). *Single-Accelerometer-Based Daily Physical Activity Classification*. IEEE
- Harrington, D. M., Welk, G. J., & Donnelly, A. E. (2011). Validation of MET estimates and step measurement using the ActivPAL physical activity logger. *Journal of sports sciences*, 29(6), 627-633.
- Quante, M., Kaplan, E. R., Rueschman, M., Cailler, M., Buxton, O. M., & Redline, S. (2015). Practical considerations in using accelerometers to assess physical activity, sedentary behavior, and sleep. *Sleep health*, 1(4), 275-284.
- Yang, C. C., & Hsu, Y. L. (2010). A review of accelerometry-based wearable motion detectors for physical activity monitoring. *Sensors*, 10(8), 7772-7788.
- Cioffi, R., Travaglioni, M., Piscitelli, G., Petrillo, A., & De Felice, F. (2020). Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions. *Sustainability*, 12(2), 492.
- Ellis, K., Kerr, J., Godbole, S., Lanckriet, G., Wing, D., & Marshall, S. (2014). A random forest classifier for the prediction of energy expenditure and type of physical activity from wrist and hip accelerometers. *Physiological Measurement*, 35(11), 2191-2203. <https://doi.org/10.1088/0967-3334/35/11/2191>.
- Roihan, A., Abas Sunarya, P., & Rafika, A. S. (2019). IJCIT (Indonesian Journal on Computer and Information Technology) Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper. In *IJCIT (Indonesian Journal on Computer and Information Technology)* (Vol. 5, Issue 1).
- Anggunadi, A., & Sutarina, N. (2017). *MANFAAT ACCELEROMETER UNTUK PENGUKURAN AKTIVITAS FISIK*.
- Kurniawan, R., Jajat, *, & Sutisna, N. (2019). *Physical Self-Concept dan Aktivitas Fisik Remaja SMA* (Vol. 78). <http://ejournal.upi.edu/index.php/ITIKOR/>
- Koster, A., Shiroma, E. J., Caserotti, P., Matthews, C. E., Chen, K. Y., Glynn, N. W., & Harris, T. B. (2016). Comparison of Sedentary Estimates between ActivPAL and Hip- and Wrist-Worn ActiGraph. *Medicine and Science in Sports and Exercise*, 48(8), 1514-1522. <https://doi.org/10.1249/MSS.0000000000000924>
- Zhou, M., Fukuoka, Y., Goldberg, K., Vittinghoff, E., & Aswani, A. (2019). Applying machine learning to predict future adherence to physical activity programs. *BMC Medical Informatics and Decision Making*, 19(1). <https://doi.org/10.1186/s12911-019-0890-0>
- Felez-Nobrega, M., Hillman, C. H., Dowd, K. P., Cirera, E., & Puig-Ribera, A. (2018). ActivPAL™ determined sedentary behaviour, physical activity and academic achievement in college students. *Journal of sports sciences*, 36(20), 2311-2316.
- Pearson, N., Atkin, A. J., Biddle, S. J., Gorely, T., & Edwardson, C. (2009). Patterns of adolescent physical activity and dietary behaviours. *International Journal of Behavioral Nutrition and Physical Activity*, 6(1), 1-7.
- Mansoubi, M., Pearson, N., Biddle, S. J., & Clemes, S. (2014). The relationship between sedentary behaviour and physical activity in adults: a systematic review. *Preventive medicine*, 69, 28-35.
- Martin, A., McNeill, M., Penpraze, V., Dall, P., Granat, M., Paton, J. Y., & Reilly, J. J. (2011). Objective measurement of habitual sedentary behavior in pre-school children: comparison of ActivPAL With ActiGraph monitors. *Pediatric exercise science*, 23(4), 468-476.
- Jollans, L., Boyle, R., Artiges, E., Banaschewski, T., Desrivieres, S., Grigis, A., ... & Whelan, R. (2019). Quantifying performance of machine learning methods for neuroimaging data. *NeuroImage*, 199, 351-365.

- Budach, L., Feuerpfeil, M., Ihde, N., Nathansen, A., Noack, N., Patzlaff, H., ... & Harmouch, H. (2022). The effects of data quality on machine learning performance. *arXiv preprint arXiv:2207.14529*.
- 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.
- Biswas, A., Chen, C., Dobson, K. G., Prince, S. A., Shahidi, F. V., Smith, P. M., & Fuller, D. (2023). Identifying the sociodemographic and work-related factors related to workers' daily physical activity using a decision tree approach. *BMC Public Health*, *23*(1), 1853.
- 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.
- Trost, S. G., Fragala-Pinkham, M., Lennon, N., & O'Neil, M. E. (2016). Decision trees for detection of activity intensity in youth with cerebral palsy. *Medicine and science in sports and exercise*, *48*(5), 958.