

Prediksi BMI Berdasarkan Level Aktivitas Fisik dengan Metode Analisis *Machine Learning*

Diki Saputra ¹⁾, Jajat ^{2)*}, Imas Damayanti ³⁾, Kuston Sultoni ⁴⁾,
Yati Ruhayati ⁵⁾, Nur Indri Rahayu ⁶⁾

^{1), 2), 3), 4), 5) dan 6)} Universitas Pendidikan Indonesia

E-mail : ¹⁾ saputradiki526@upi.edu, ²⁾ jajat_kurdul@upi.edu, ³⁾ imas_d@upi.edu,
⁴⁾ kuston.sultoni@upi.edu, ⁵⁾ yatiruhayati@upi.edu, ⁶⁾ nurindirahayu1910@upi.edu

ABSTRAK

Prevalensi obesitas telah menjadi salah satu isu global dalam bidang kesehatan di masyarakat. Sementara itu aktivitas fisik diakui menjadi salah satu yang memiliki peran penting dalam mengatasi prevalensi obesitas. Tujuan penelitian ini yaitu untuk menjelaskan hubungan aktivitas fisik dengan *Body Mass Index* (BMI) dengan metode *ML* yang saat ini tengah populer. Sumber data yang digunakan yaitu dari kelompok bidang keilmuan sport and *physical activity* program studi Ilmu Keolahragaan, Universitas Pendidikan Indonesia. Total 212 (usia 19-23 tahun) partisipan yang memenuhi kriteria, terlibat dalam penelitian ini. IPAQ-SF digunakan untuk memperoleh data terkait dengan aktivitas fisik partisipan. Empat metode algoritma *ML* yaitu *decision tree*, *naïve bayes*, *k-nearest neighbors* (KNN), dan *random forest* digunakan untuk menganalisis data. Hasil penelitian menunjukkan bahwa algoritma *naïve bayes* memiliki performa paling unggul (akurasi = 52,38%; sensitifitas = 51,65%; spesifisitas = 53,33%) dari ketiga model *ML* lainnya, sementara KNN paling rendah baik akurasi, sensitifitas, maupun spesifisitas (42,86%) dalam memprediksi BMI berdasarkan level aktivitas fisik. Aktivitas fisik memiliki peran penting dalam memprediksi BMI selain faktor lainnya seperti jenis kelamin dan perilaku *sedentary*.

Kata kunci : *body mass index; physical activity; decision tree*

ABSTRACT

The prevalence of obesity has become a global issue in the field of public health. Meanwhile, physical activity is recognized as having an important role in overcoming the prevalence of obesity. The aim of this research is to explain the relationship between physical activity and Body Mass Index (BMI) using the ML method which is currently popular. The data source used is from the sports and physical activity scientific field group, Sports Science study program, Indonesian University of Education. A total of 212 (aged 19-23 years) participants who met the criteria were involved in this research. IPAQ-SF was used to obtain data related to participants' physical activity. Four ML algorithm methods, namely decision tree, naïve Bayes, k-nearest neighbors (KNN), and random forest were used to analyze the data. The results showed that the Naive Bayes algorithm had the most superior performance (accuracy = 52,38%; sensitivity = 51,65%; specificity = 53,33%) of the three other ML models, while KNN had the lowest accuracy, sensitivity and specificity (42,86%) in predicting BMI based on physical activity level. Physical activity has an important role in predicting BMI apart from other factors such as gender and sedentary behavior.

Keywords : *body mass index; physical activity; decision tree*

Penulis Korespondensi : Jajat, Universitas Pendidikan Indonesia
E-mail : jajat_kurdul@upi.edu



Jurnal Pendidikan Kesehatan Rekreasi berlisensi di bawah [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-nc-sa/4.0/)

PENDAHULUAN

Pada satu dekade terakhir, prevalensi obesitas telah mengalami peningkatan yang signifikan, sehingga menjadi salah satu isu utama dalam bidang kesehatan masyarakat di dunia termasuk Indonesia (Dewi & Solechah, 2020). Pada tahun 2015-2016, hampir 40% (Milita et al., 2021) dari populasi dewasa di Indonesia yang berusia 20 tahun ke atas dan hampir 20% anak-anak serta remaja yang berusia 2-19 tahun mengalami obesitas (Rachmi & Baur, 2017). Masalah obesitas menimbulkan keprihatinan serius dalam masalah kesehatan masyarakat karena berpotensi menyebabkan dampak kesehatan yang serius, seperti peningkatan risiko hipertensi, hipercolesterolemia, serta diabetes tipe 2 (Visscher & Seidell, 2001), beberapa jenis kanker (Goodwin & Stambolic, 2015), bahkan risiko kematian dini (Frank et al, 2010). Untuk mengatasi penyakit-penyakit yang terkait dengan obesitas ini, Amerika Serikat mengeluarkan biaya sebesar USD 315,8 setiap tahun (Wyatt & Dubbert, 2006).

Aktivitas fisik telah diakui sebagai salah satu faktor kunci dalam penanganan masalah obesitas. Sayangnya, tingkat kepatuhan terhadap pedoman aktivitas fisik di antara orang dewasa di Indonesia tetap rendah dan tidak mengalami perubahan yang signifikan (Chin & Binks, 2016). Data yang mencakup seluruh populasi menunjukkan bahwa hanya 18% (Parinduri & Djokosujono, 2021) dari individu yang mengalami obesitas yang memenuhi pedoman aktivitas fisik. Studi sebelumnya telah menunjukkan bahwa bahkan peningkatan kecil dalam aktivitas fisik dengan intensitas moderat hingga tinggi berkorelasi dengan risiko

obesitas yang lebih rendah. Individu yang berhasil mempertahankan berat badan yang sehat cenderung lebih aktif secara fisik (Fitri & Suryana, 2016). Selain itu, intervensi aktivitas fisik telah terbukti memberikan manfaat bagi anak-anak dan remaja yang mengalami obesitas (Nurcahyo, 2011), serta mengurangi risiko kesehatan yang terkait dengan kondisi tersebut (Villasana et al, 2020). Namun, ada juga penelitian yang menyiratkan bahwa hubungan antara aktivitas fisik dan status berat badan dapat memiliki korelasi yang rendah atau bahkan tidak ada hubungannya. Sebagai contoh, studi yang dilakukan oleh Luran dan rekannya, dengan menggunakan *Behavioral Risk Factor Surveillance System* (BRFSS) dan *National Health and Nutrition Examination Survey* (NHANES) (Dwyer et al, 2013), menemukan bahwa antara tahun 2001 hingga 2009, setiap peningkatan 1 poin persentase dalam prevalensi PA berkorelasi dengan penurunan prevalensi obesitas sekitar 0,11 poin persentase setelah mempertimbangkan faktor-faktor sosial seperti kemiskinan, pengangguran, dan urbanisasi (Dwyer et al, 2013). Ruth dan rekan-rekannya, yang menggunakan data NHANES dari tahun 1988 hingga 2006, juga menunjukkan bahwa faktor-faktor selain aktivitas fisik mungkin lebih berperan dalam peningkatan Indeks Massa Tubuh (IMT) dari waktu ke waktu (Samarayanake & Cheung, 2012). Suatu tinjauan sistematis sebelumnya bahkan menyimpulkan bahwa meskipun manfaat kesehatan dari aktivitas fisik telah terbukti, aktivitas fisik mungkin hanya memiliki peran yang relatif kecil dalam penyebab obesitas (Huang et al, 2015).

Oleh karena itu, meskipun aktivitas fisik telah diidentifikasi sebagai faktor penting dalam mengatasi masalah obesitas, hubungan yang lebih mendalam antara aktivitas fisik dan obesitas masih belum sepenuhnya terungkap. Berkat kemajuan teknologi baru-baru ini, metode *ML* (ML) telah menjadi alat yang kuat untuk membantu mengidentifikasi faktor-faktor risiko yang kompleks dalam konteks obesitas (DeGregory et al, 2018). Dibandingkan dengan pendekatan statistik konvensional, ML belajar dari data tanpa terpaku pada aturan kaku dan tidak hanya memperhatikan hubungan antar variabel, yang seringkali menjadi kendala dalam model regresi konvensional. Kemampuan ML dalam mengelola volume data besar yang rumit juga melampaui kemampuan model statistik tradisional (Nilashi et al, 2017). Namun, penting untuk dicatat bahwa meskipun ML menawarkan potensi yang besar, teknik ini tidak selalu mengungguli metode konvensional dalam pengaturan klinis. Tinjauan sistematis bahkan menunjukkan bahwa tidak ada manfaat kinerja yang signifikan dari model ML dibandingkan dengan regresi logistik tradisional dalam membangun model prediksi klinis. Selain itu, ada beberapa tantangan yang perlu diatasi dalam menggunakan model prediksi berbasis ML, seperti kesulitan dalam menginterpretasikan hasil yang lebih akurat dan tidak adanya pedoman baku mengenai seberapa besar peningkatan kinerja yang cukup untuk membenarkan penggunaan model yang kurang dapat diinterpretasikan (Murdoch et al, 2019).

Dengan latar belakang tersebut, dalam studi eksploratif ini, penelitian

bertujuan untuk : 1) menyelidiki lebih lanjut hubungan antara aktivitas fisik dan status berat badan dengan menggunakan teknik ML serta data aktivitas fisik nasional yang terukur secara objektif; dan 2) membandingkan hasil serta kinerja antara penggunaan metode berbasis ML dan metode statistik konvensional dalam menilai hubungan antara aktivitas fisik dan status berat badan. Kami berhipotesis bahwa aktivitas fisik adalah salah satu faktor penting dalam memprediksi obesitas dan bahwa model ML mungkin mampu memberikan prediksi yang lebih akurat dibandingkan dengan metode statistik konvensional.

METODE PENELITIAN

Penelitian ini membandingkan performa empat algoritma *ML* dalam memprediksi status BMI berdasarkan level aktivitas fisik. Perbandingan dikaji dari performa masing-masing algoritma melalui *confusion matrix*. *Confusion matrix* merupakan metode untuk mengevaluasi keakuratan model dari hasil yang didapatkan dalam proses mengklasifikasi algoritma (Zeng, 2020).

Data set yang digunakan dalam penelitian ini merupakan gabungan dari data yang diambil secara langsung dan data Kelompok Bidang Keilmuan (KBK) *physical activity and sport*, pada program studi Ilmu Keolahragaan, Universitas Pendidikan Indonesia. KBK *physical activity and sport* yang mengkaji berbagai permasalahan aktivitas fisik dan olahraga pada berbagai level dan jenjang usia. Salah satu yang dikaji yaitu pada kategori usia remaja pada jenjang sekolah menengah atas (SMA) dan mahasiswa.

Penelitian ini menggunakan data aktivitas fisik mahasiswa (N=372) yang bersumber dari KBK *physical activity and sport* berupa laporan diri partisipan melalui *International Physical Activity Questionnaire Short Form* (IPAQ-SF). Sumber data ini paling memungkinkan untuk digunakan dalam penelitian karena memuat data sesuai permasalahan. Adapun analisis sampel terfokus pada mahasiswa berusia 19-23 tahun di mana informasi mengenai demografi, karakteristik antropometrik (tinggi dan berat badan) serta aktivitas fisik tersedia pada data yang diperoleh. Kami mengeluarkan data yang tidak lengkap dari responden, sehingga total data yang diteliti berjumlah 212 sampel.

BMI atau status berat badan merupakan variabel utama dalam penelitian ini. BMI dihitung melalui kalkulasi data tinggi dan berat badan yang dilaporkan oleh partisipan dengan rumus Berat Badan (kg) dibagi Tinggi Badan (meter) Kuadrat. Adapun cut point yang digunakan untuk klasifikasi BMI yaitu kategori Asia Pasifik yang berbeda dengan kategori WHO (Jajat & Suherman, 2020; Lim et al., 2017). Adapun klasifikasi BMI Asia Pasifik yaitu; <18,5 underweight, 18,5-22,9

normal, 23-24,9 overweight, dan >25 obesitas.

Variabel prediktor yang digunakan yaitu level aktivitas fisik. Klasifikasi level aktivitas fisik mengacu pada rumus kalkulasi *Metabolic Equivalent of Task* (METs) dari IPAQ-SF. METs merupakan standar banyaknya energi yang dikeluarkan oleh tubuh dalam keadaan istirahat duduk dan beraktivitas 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. Berikut adalah rumus METs IPAQ-SF; $Walking\ MET\text{-minutes}/week = 3.3 * walking\ minutes * walking\ days$ $Moderate\ MET\text{-minutes}/week = 4.0 * moderate\text{-intensity}\ activity\ minutes * moderate\ days$ $Vigorous\ MET\text{-minutes}/week = 8.0 * vigorous\text{-intensity}\ activity\ minutes * vigorous\text{-intensity}\ days$ $Total\ physical\ activity\ MET\text{-minutes}/week = sum\ of\ Walking + Moderate + Vigorous\ MET\text{-minutes}/week\ scores$. Adapun tabel pengkategorian METs berdasarkan norma IPAQ (Suwandaru et al., 2021).

Tabel 1
Norma IPAQ dan GPAQ

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

Studi ini menggunakan empat algoritma klasifikasi dari ML untuk memprediksi BMI berdasarkan level aktivitas fisik. Empat model algoritma

tersebut yaitu *decision tree*, *naïve bayes*, *k-nearest neighbors* (KNN), dan *random forest*.

Supervised ML digunakan dalam penelitian ini, artinya data atau variabel *outcome* diberikan label. Dari 212 jumlah data kemudian dibagi ke dalam data latih dan data uji. Sebanyak 80% data digunakan sebagai data latih, dan 20% digunakan untuk data uji atau data tes.

HASIL DAN PEMBAHASAN

Tabel 2 menyajikan karakteristik sampel penelitian, termasuk status BMI dan level aktivitas fisik. Sebanyak 212 orang partisipan terlibat dalam penelitian ini, dimana 69% (147 orang) berjenis kelamin perempuan. Sebanyak 31 orang laki-laki atau 47% memiliki status BMI tidak normal yaitu kurus, kelebihan berat badan dan obesitas. Sementara itu 47% perempuan memiliki status tidak normal, di mana 40 orang diantaranya kelebihan berat badan dan obesitas.

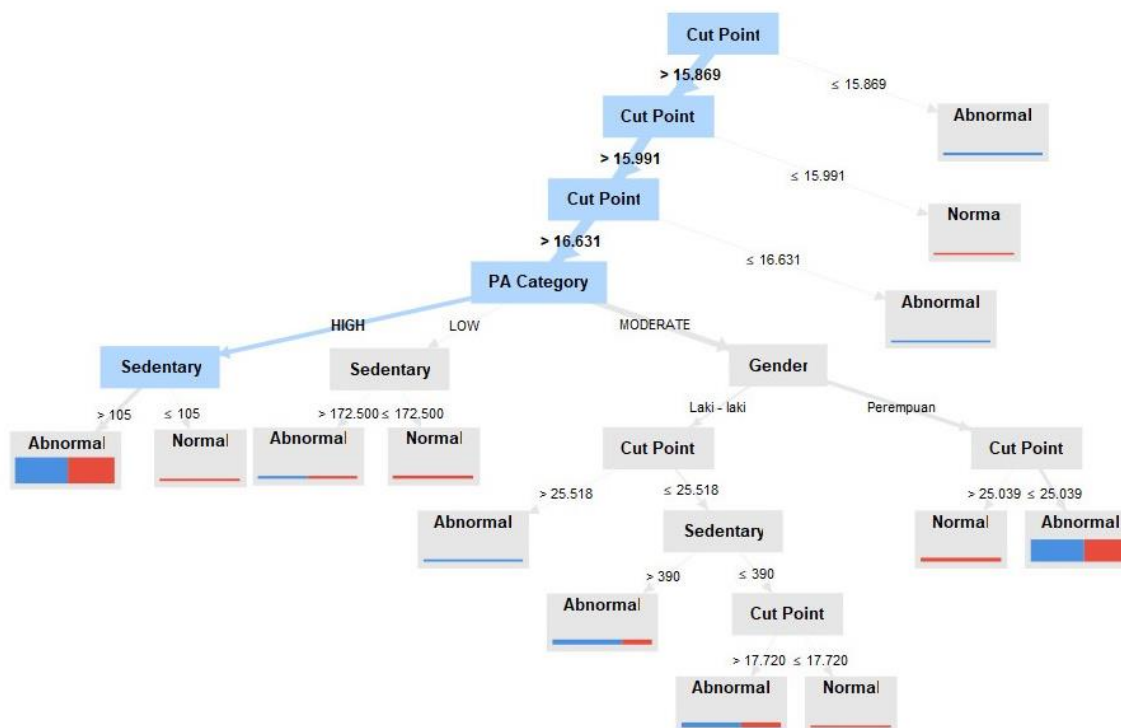
Dari total keseluruhan partisipan, hanya 49% mahasiswa yang memiliki status BMI normal, dan sisanya pada status kurus, kelebihan berat badan dan obesitas. Berdasarkan laporan diri, sebanyak 7% partisipan status level aktivitas fisiknya pada klasifikasi rendah, dan sisanya pada level aktivitas fisik sedang dan tinggi. Pada laki-laki, kurang dari 1% partisipan level aktivitas fisik rendah, sementara pada perempuan lebih dari 6% memiliki level aktivitas fisik rendah. Lebih lanjut jika dilihat dari status BMI dan level aktivitas fisik, partisipan yang termasuk pada status BMI normal dengan level aktivitas fisik sedang persentasenya paling tinggi yaitu 24,53%. Sementara persentase terendah yaitu pada status BMI obesitas dengan level aktivitas rendah yaitu satu orang.

Tabel 2
Karakteristik Status BMI dan Aktivitas Fisik Partisipan

Variabel	BMI Status							
	Underweight ($< 18,5$)		Normal ($18,5-22,9$)		Overweight ($23 - 24,9$)		Obese (>25)	
Gender	N	(%)	N	(%)	N	(%)	N	(%)
Laki-laki	17	8,02	26	12,26	6	2,83	8	3,77
Perempuan	29	13,68	78	36,79	18	8,49	22	10,38
Variabel	Level Aktivitas Fisik							
	Light		Moderate		Vigorous			
Gender	N	(%)	N	(%)	N	(%)		
Laki-laki	2	0,94	33	15,57	30	14,15		
Perempuan	13	6,13	77	36,32	57	26,89		
PA Level	Level Aktivitas Fisik by BMI Status							
	N	(%)	N	(%)	N	(%)	N	(%)
Light	2	0,94	10	4,72	2	0,94	1	0,47
Moderate	26	12,26	52	24,53	16	7,55	16	7,55
Vigorous	18	8,49	40	18,87	14	6,60	13	6,13

Gambar 1 menyajikan hasil uji *ML* algoritma *decision tree* yang merupakan penjelasan klasifikasi status BMI berdasarkan faktor-faktor gender, *cut point* BMI, aktivitas fisik rendah, aktivitas fisik sedang, aktivitas fisik tinggi, dan perilaku sedentari. Dilihat dari pohon keputusan yang dihasilkan

bahwa selain *cut point*, level aktivitas fisik dan waktu perilaku sedentari merupakan faktor utama *decision tree* dalam mengklasifikasi status BMI. Selain itu, gender juga menjadi faktor lain yang juga menjadi penentu klasifikasi BMI pada level aktivitas fisik moderat.



Gambar 1
Pohon Keputusan Prediksi BMI Algoritma *Decision Tree*

Penelitian ini memprediksi BMI berdasarkan level aktivitas fisik. Pengelompokan BMI dibagi menjadi dua yaitu normal dan abnormal, di mana klasifikasi abnormal yaitu termasuk kategori kurus (*underweight*), gemuk (*overweight*), dan obesitas. Tabel 3 menunjukkan hasil pengujian performa

klasifikasi menggunakan empat algoritma *ML*. *Naive bayes* memiliki performa akurasi paling tinggi diantara algoritma yang lain yaitu 52,38%. Sementara itu, *KNN* performa akurasinya paling rendah dalam memprediksi BMI berdasarkan level aktivitas fisik sebesar 42,86%. Selain

memiliki akurasi paling tinggi, *naive bayes* juga memiliki tingkat sensitifitas paling tinggi yaitu 51,85%. Demikian juga dengan KNN, selain memiliki akurasi paling rendah juga memiliki sensitifitas paling rendah dari keempat

model. Lebih lanjut untuk spesifisitas, *naive bayes* juga memiliki spesifisitas paling tinggi dari keempat model sebesar 53,33%. Sementara spesifisitas paling rendah ditunjukkan pada model algoritma *decision tree* dengan 25%.

Tabel 3
Evaluasi Akurasi, Sensitifitas, dan Spesifisitas Prediksi Model ML pada Status BMI dan Level Aktivitas Fisik

<i>Method</i>	<i>Decision Tree</i>	<i>Naive Bayes</i>	<i>KNN</i>	<i>Random Forest</i>
Akurasi	45,24%	52,38%	42,86%	45,24%
Sensitifitas	47,37%	51,85%	42,86%	45,83%
Spesifisitas	25%	53,33%	42,86%	44,44%

Penelitian ini yaitu menilai resiko indeks masa tubuh terutama overweight dan obesitas di masa mendatang dengan menggunakan data aktivitas fisik yang diukur dengan laporan diri dan metode *ML*. Hasil pengujian menunjukkan bahwa aktivitas fisik, terutama intensitas sedang hingga tinggi merupakan faktor utama dalam memprediksi BMI. Selain level aktivitas fisik, jenis kelamin juga menjadi faktor penentu *ML* dalam mengklasifikasi BMI. Sebagaimana penelitian terdahulu bahwa level aktivitas fisik memiliki peranan penting dalam menurunkan dan memelihara berat badan (Fogelholm & Kukkonen-Harjula, 2000; Swift et al., 2018). Demikian juga dengan jenis kelamin dan usia yang menjadi salah satu atribut penentu terhadap status berat badan (Belcher et al., 2010; Bolton et al., 2014).

Penelitian juga membandingkan perbedaan performa algoritma *ML* dalam memprediksi status BMI, di mana KNN memiliki akurasi paling rendah. Sementara itu *naive bayes* paling tinggi akurasinya dalam memprediksi status

BMI dari empat model algoritma *ML*. Namun demikian, meskipun *naive bayes* memiliki akurasi paling tinggi dari tiga model lainnya, akurasinya relatif masih lemah. Selain akurasi, *naive bayes* juga memiliki sensitifitas dan spesifisitas paling tinggi dari tiga model algoritma lainnya. Sensitifitas *naive bayes* dalam memprediksi status BMI, 8,99% lebih tinggi dari KNN yang memiliki sensitifitas paling rendah dari keempat model algoritma *ML*. Lebih lanjut, spesifisitas *naive bayes* 28,33% lebih tinggi dari *decision tree* yang memiliki spesifisitas paling rendah di antara keempat model algoritma *ML*.

Dibandingkan dengan penelitian terdahulu yang mengkaji perbedaan sebelas algoritma *ML* dalam memprediksi obesitas berdasarkan aktivitas fisik melaporkan bahwa model algoritma *random subspace* memiliki akurasi paling tinggi 67,03% dibandingkan model lainnya, di mana *naive bayes* akurasinya paling rendah dengan 49,64% (Cheng et al., 2021). Senada dengan penelitian lainnya yang mengkaji permasalahan serupa dengan

menggunakan metode *Recurrent Neural Networks* (RNNs) menunjukkan akurasi 77% (Xue et al., 2018). Lebih lanjut kajian prediksi status berat badan menggunakan algoritma *ML neural network* berdasarkan perilaku aktivitas fisik melaporkan akurasi prediksi 75,8% (Rousset et al., 2023). Penelitian lainnya mengembangkan dua model prediksi menggunakan data *accelerometer* untuk memperkirakan jenis aktivitas fisik dan pengeluaran energi. Model-model ini menggunakan algoritma random forest dan mencakup fitur-fitur seperti magnitudo percepatan, sudut roll, pitch, dan yaw, serta arah gerakan utama. Hasilnya menunjukkan bahwa model random forest berhasil dalam memperkirakan pengeluaran energi dan mengklasifikasikan jenis aktivitas dengan akurasi lebih tinggi ketika menggunakan data dari *accelerometer* pada pinggul dan pergelangan tangan, dan penambahan data detak jantung lebih lanjut meningkatkan prediksi (Ellis, Kerr, et al., 2014). Dengan demikian, algoritma *ML* memiliki kemampuan yang berbeda-beda dalam memprediksi status berat badan termasuk BMI berdasarkan atribut-atribut demografi, gender, maupun aktivitas keseharian termasuk level aktivitas fisik.

Beberapa limitasi dari penelitian ini diantaranya; instrumen yang digunakan untuk mengukur aktivitas fisik menggunakan kuesioner laporan diri IPAQ-SF, di mana kemungkinan jawaban responden dengan kebenaran aktivitas yang dilakukannya mungkin berbeda. Pengukuran aktivitas fisik dengan menggunakan instrumen objektif seperti *accelerometer* (*Actigraph* & *ActivPal*) diperlukan agar data memiliki

akurasi yang lebih baik. Yang kedua, keterlibatan jumlah sampel yang lebih banyak dan usia yang variatif menjadi rencana ke depannya dalam penelitian ini.

SIMPULAN DAN SARAN

Algoritma *ML* dapat memprediksi BMI berdasarkan level aktivitas fisik. Algoritma *naive bayes* memiliki keunggulan dibandingkan dengan tiga model lainnya dalam memprediksi BMI berdasarkan level aktivitas fisik, meskipun performanya relatif masih rendah. Meskipun level aktivitas fisik merupakan menjadi prediktor penting terhadap BMI, karakteristik demografi lainnya seperti jenis kelamin dan perilaku sedentari juga merupakan faktor penting lainnya yang terkait dengan status BMI. Penelitian lebih lanjut dengan menggunakan algoritma machine learning selain empat model yang digunakan diperlukan untuk melihat performanya. Selain itu juga faktor-faktor lain yang dapat memprediksi BMI perlu dikaji lebih lanjut.

DAFTAR PUSTAKA

- Belcher, B. R., Berrigan, D., Dodd, K. W., Emken, B. A., Chou, C. P., & Spuijt-Metz, D. (2010). Physical activity in US youth: impact of race/ethnicity, age, gender, & weight status. *Medicine and science in sports and exercise*, 42(12), 2211.
- Bolton, K., Kremer, P., Rossthorn, N., Moodie, M., Gibbs, L., Waters, E., & de Silva, A. (2014). The effect of gender and age on the association between weight status and health-related quality of life in Australian adolescents. *BMC Public Health*, 14, 1-8.

- Cheng, X., Lin, S. Y., Liu, J., Liu, S., Zhang, J., Nie, P., Fuemmeler, B. F., Wang, Y., & Xue, H. (2021). Does physical activity predict obesity—a ML and statistical method-based analysis. *International Journal of Environmental Research and Public Health*, 18(8). <https://doi.org/10.3390/ijerph18083966>
- Chin, S. H., Kahathuduwa, C. N., & Binks, M. (2016). Physical activity and obesity: what we know and what we need to know. *Obesity Reviews*, 17(12), 1226-1244. <https://doi.org/10.1111/obr.12460>
- DeGregory, K. W., Kuiper, P., DeSilvio, T., Pleuss, J. D., Miller, R., Roginski, J. W., & Thomas, D. M. (2018). A review of machine learning in obesity. *Obesity reviews*, 19(5), 668-685. <https://doi.org/10.1111/obr.12667>
- Dewi, N. U., Tanziha, I., & Solechah, S. A. (2020). Obesity Determinants and the Policy Implications for the Prevention and Management of Obesity in Indonesia. *Current Research in Nutrition & Food Science*, 8(3). https://www.researchgate.net/profile/Bohari-Bohari/publication/349044345_Obesity_Determinants_and_the_Policy_Implications_for_the_Prevention_and_Management_of_Obesity_in_Indonesia_Article_History/links/601ca71d92851c4ed54bd7ac/Obesity-Determinants-and-the-Policy-Implications-for-the-Prevention-and-Management-of-Obesity-in-Indonesia-Article-History.pdf
- Dwyer-Lindgren, L., Freedman, G., Engell, R. E., Fleming, T. D., Lim, S. S., Murray, C. J., & Mokdad, A. H. (2013). Prevalence of physical activity and obesity in US counties, 2001–2011: a road map for action. *Population health metrics*, 11(1), 1-11. <https://doi.org/10.1186/1478-7954-11-7>
- Ellis, K., Godbole, S., Marshall, S., Lanckriet, G., Staudenmayer, J., & Kerr, J. (2014). Identifying active travel behaviors in challenging environments using GPS, accelerometers, and ML algorithms. *Frontiers in Public Health*, 2(APR), 1–8. <https://doi.org/10.3389/fpubh.2014.00036>
- Fitri, Y., Mulyani, N. S., Fitrianiingsih, E., & Suryana, S. (2016). Pengaruh pemberian aktifitas fisik (aerobic exercise) terhadap tekanan darah, IMT dan RLPP pada wanita obesitas. *Action: Aceh Nutrition Journal*, 1(2), 105-110. DOI : 10.30867/action.v1i2.19
- Fogelholm, M., & Kukkonen-Harjula, K. (2000). Does physical activity prevent weight gain—a systematic review. *Obesity reviews*, 1(2), 95-111.
- Goodwin, P. J., & Stambolic, V. (2015). Impact of the obesity epidemic on cancer. *Annual review of medicine*, 66, 281-296. <https://doi.org/10.1146/annurev-med-051613-012328>
- Huang, C. J., McAllister, M. J., Slusher, A. L., Webb, H. E., Mock, J. T., & Acevedo, E. O. (2015). Obesity-related oxidative stress: the impact of physical activity and diet manipulation. *Sports medicine-open*, 1, 1-12.

- <https://doi.org/10.1186/s40798-015-0031-y>
- Jajat, J., & Suherman, A. (2020). Indonesian Children and Adolescents' Body Mass Index: WHO and Asia-Pacific Classification. In 4th International Conference on Sport Science, Health, and Physical Education (ICSSHPE 2019) (pp. 263-266). Atlantis Press
- Lim, J. U., Lee, J. H., Kim, J. S., Hwang, Y. I., Kim, T. H., Lim, S. Y., & Rhee, C. K. (2017). Comparison of World Health Organization and Asia-Pacific body mass index classifications in COPD patients. *International journal of chronic obstructive pulmonary disease*, 2465-2475
- Milita, F., Handayani, S., & Setiaji, B. (2021). Kejadian diabetes mellitus tipe II pada lanjut usia di Indonesia (analisis riskesdas 2018). *Jurnal Kedokteran Dan Kesehatan*, 17(1), 9-20.
<https://doi.org/10.24853/jkk.17.1.9-20>
- 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*, 116(44), 22071-22080.
<https://doi.org/10.1073/pnas.1900654116>
- Nilashi, M., bin Ibrahim, O., Ahmadi, H., & Shahmoradi, L. (2017). An analytical method for diseases prediction using machine learning techniques. *Computers & Chemical Engineering*, 106, 212-223.
<https://doi.org/10.1016/j.compchemeng.2017.06.011>
- Nurchayyo, F. (2011). Kaitan antara obesitas dan aktivitas fisik. *Medikora*, (1). DOI:10.21831/medikora.v0i1.4663
- Parinduri, F. K., Djokosujono, K., & Parinduri, S. K. (2021). Faktor Dominan Obesitas Sentral pada Usia 40-60 tahun di Indonesia (Analisis Data Indonesian Family Life Survey 5 Tahun 2014/2015). *HEARTY: Jurnal Kesehatan Masyarakat*, 9(2), 58-70.
<https://doi.org/10.32832/hearty.v9i2.5397>
- Rachmi, C. N., Li, M., & Baur, L. A. (2017). Overweight and obesity in Indonesia: prevalence and risk factors—a literature review. *Public health*, 147, 20-29.
<https://doi.org/10.1016/j.puhe.2017.02.002>
- Rousset, S., Angelo, A., Hamadouche, T., & Lacomme, P. (2023). Weight Status Prediction Using a Neuron Network Based on Individual and Behavioral Data. In *Healthcare* (Vol. 11, No. 8, p. 1101). MDPI
- Suwardaru, C., Hidayat S-, T., Rekreasi, dan, & Ilmu Olahraga, F. (2021). Hubungan Aktivitas Fisik dengan Prestasi Belajar Siswa SMK Negeri 1 Surabaya.
<https://ejournal.unesa.ac.id/index.php/jurnal-pendidikan-jasmani>
- Swift, D. L., McGee, J. E., Earnest, C. P., Carlisle, E., Nygard, M., & Johannsen, N. M. (2018). The effects of exercise and physical activity on weight loss and maintenance. *Progress in cardiovascular diseases*, 61(2), 206-213

- Villasana, M. V., Pires, I. M., Sá, J., Garcia, N. M., Zdravevski, E., Chorbev, I., & Flórez-Revuelta, F. (2020). Promotion of healthy nutrition and physical activity lifestyles for teenagers: A systematic literature review of the current methodologies. *Journal of personalized medicine*, 10(1), 12. <https://doi.org/10.3390/jpm10010012>
- Visscher, T. L., & Seidell, J. C. (2001). The public health impact of obesity. *Annual review of public health*, 22(1), 355-375. <https://doi.org/10.1146/annurev.publhealth.22.1.355>
- Wyatt, S. B., Winters, K. P., & Dubbert, P. M. (2006). Overweight and obesity: prevalence, consequences, and causes of a growing public health problem. *The American journal of the medical sciences*, 331(4), 166-174. <https://doi.org/10.1097/00000441-200604000-00002>
- Xue, Q., Wang, X., Meehan, S., Kuang, J., Gao, J. A., & Chuah, M. C. (2018, December). Recurrent neural networks based obesity status prediction using activity data. In 2018 17th IEEE International Conference on ML and Applications (ICMLA) (pp. 865-870). IEEE
- Zeng, G. (2020). On the confusion matrix in credit scoring and its analytical properties. *Communications in Statistics-Theory and Methods*, 49(9), 2080-2093