



Analisis Resiko Obesitas Berdasarkan Aktivitas Fisik: Implementasi Metode *Artificial Intelligence Machine Learning*

Syam Hardwis¹, Jajat^{2*}

^{1,2}Program Studi Ilmu Keolahragaan, Universitas Pendidikan Indonesia, Bandung, Indonesia

Email: jajat_kurdul@upi.edu

ABSTRACT

Obesity has become a global issue faced by various countries worldwide. Physical activity and sedentary behavior are considered key factors contributing to the occurrence of obesity. This study aims to analyze the relationship between physical activity and sedentary behavior with body mass index (BMI) using a machine learning approach. A total of 280 students from Universitas Pendidikan Indonesia, representing various study programs, participated in this research, consisting of 101 males and 179 females aged 17–23 years. Physical activity was measured using an Actigraph GT3X accelerometer. This study employed four machine learning algorithms—k-nearest neighbours (KNN), decision tree, random forest, and Classification via Regression (CVR)—to analyze obesity risk. The analysis was conducted using RapidMiner software. Based on physical activity, sedentary behavior, and demographic status variables, the random forest algorithm achieved the highest accuracy at 71.09% compared to the other algorithms. Similarly, in terms of sensitivity, the random forest algorithm outperformed others with a score of 37.50%. Meanwhile, the decision tree algorithm recorded the highest specificity at 77.5%. Physical activity, total Metabolic Equivalent of Task (MET), and sedentary behavior duration are critical factors in predicting obesity risk. Therefore, promoting physical activity and implementing campus policies play a crucial role in reducing obesity prevalence among students.

Keywords: Physical activity, artificial intelligence, BMI, machine learning, obesity

ABSTRAK

Obesitas telah menjadi masalah global yang dihadapi oleh berbagai negara di seluruh dunia. Aktivitas fisik dan perilaku sedentari dianggap sebagai faktor kunci yang berkontribusi terhadap terjadinya obesitas. Penelitian ini bertujuan untuk menganalisis hubungan antara aktivitas fisik dan perilaku sedentari dengan indeks massa tubuh (BMI) menggunakan pendekatan algoritma machine learning. Sebanyak 280 mahasiswa Universitas Pendidikan Indonesia dari berbagai program studi berpartisipasi dalam penelitian ini, terdiri atas 101 laki-laki dan 179 perempuan berusia 17–23 tahun. Aktivitas fisik diukur menggunakan accelerometer Actigraph GT3X. Penelitian ini menggunakan tujuh algoritma machine learning, yaitu k-nearest neighbours (KNN), decision tree, random forest, dan Classification via Regression (CVR) untuk analisis risiko obesitas. Pengujian dilakukan dengan menggunakan perangkat lunak RapidMiner. Berdasarkan variabel aktivitas fisik, perilaku sedentari, dan status demografi, algoritma random forest menunjukkan akurasi tertinggi sebesar 71,09% dibanding algoritma lainnya. Demikian juga dengan sensitivitas, algoritma random forest paling tinggi dari algoritma lainnya sebesar 37,50%. Sementara untuk spesifisitas, algoritma decision tree paling tinggi dengan 77,5%. Aktivitas fisik, total Metabolic Equivalent of Task (MET), dan durasi perilaku sedentari merupakan faktor penting dalam memprediksi risiko obesitas. Oleh karena itu, promosi aktivitas fisik dan kebijakan kampus memiliki peran krusial dalam mengurangi prevalensi obesitas di kalangan mahasiswa.

Kata Kunci: Aktivitas fisik, artificial intelligence, BMI, machine learning, obesitas

Cara sitasi:

Hardwis, S. dan Jajat. J. (2024). Analisis Resiko Obesitas Berdasarkan Aktivitas Fisik: Implementasi Metode Artificial Intelligence Machine Learning. *Jurnal Keolahragaan*, 10(2), 29-36

Sejarah Artikel:

Dikirim 26 November 2024, Direvisi 27 November 2024, Diterima. 27 November 2024

PENDAHULUAN

Obesitas telah menjadi salah satu tantangan kesehatan masyarakat yang paling mendesak di abad ke-21 (Wyatt et al., 2006; Egger, & Dixon, 2014; Huang et al., 2009). Menurut data dari Organisasi Kesehatan Dunia (WHO), prevalensi obesitas secara global telah meningkat lebih dari tiga kali lipat sejak tahun 1975 (WHO, 2021). Sementara itu, lebih dari 23% populasi usia 18 tahun ke atas di Indonesia mengalami obesitas (Kemenkes RI, 2023).

Obesitas tidak hanya berdampak pada individu dalam bentuk risiko penyakit kronis seperti diabetes tipe 2 (Sullivan, Ghushchyan, & Ben-Joseph, 2008; Chobot et al., 2018), hipertensi (Nguyen & Lau, 2012; Jiang et al., 2016; Seravalle & Grassi, 2024), penyakit kardiovaskular (Chrostowska, 2013; Zalesin, 2008) dan kanker tertentu (Schmitz, 2013; Krupa-Kotara & Dakowska, 2021) tetapi juga memberikan beban ekonomi yang besar pada sistem kesehatan (Spieker & Pyzocha, 2016; Specchia et al., 2015). Kondisi ini membutuhkan perhatian khusus, terutama mengingat kompleksitas faktor-faktor yang berkontribusi, termasuk genetik (Golden & Kessler, 2020), lingkungan, pola makan (Sominisky & Spencer, 2014; Morales & Berkowitz, 2016), dan aktivitas fisik (Koolhaas et al., 2017; Gawlik, Zwierzchowska, & Celebańska, 2018).

Aktivitas fisik merupakan salah satu determinan utama dalam pencegahan dan pengelolaan obesitas (Pan et al., 2021; Bray et al., 2016; Hruby et al., 2016). Aktivitas fisik yang teratur membantu menjaga keseimbangan energi (Swift, et al., 2018; Wiklund, 2018) meningkatkan metabolisme tubuh (Myers, Kokkinos, & Nyelin, 2019), serta mengurangi akumulasi lemak tubuh (Rondanelli, 2016). Namun, gaya hidup modern yang cenderung sedentari telah menjadi tantangan besar dalam mendorong individu untuk tetap aktif secara fisik (Yang et al., 2019). Perkembangan teknologi informasi termasuk media massa internet memberikan pengaruh besar terhadap sikap seseorang untuk melakukan aktivitas fisik (Jajat, 2020). Sementara itu, pola aktivitas fisik individu sering kali sangat bervariasi, sehingga sulit untuk membuat prediksi risiko obesitas yang akurat hanya dengan metode analisis konvensional (Sweatt, 2024). Oleh karena itu, dibutuhkan pendekatan inovatif yang mampu menangani kompleksitas data dan memberikan wawasan yang lebih mendalam.

Kemajuan teknologi dalam bidang kecerdasan buatan (artificial intelligence, AI) dan pembelajaran mesin (machine learning) telah membuka peluang baru dalam pengelolaan masalah kesehatan (Jiang et al., 2021). Machine learning memungkinkan analisis data besar dan kompleks dengan cara yang lebih efisien dan presisi tinggi (Al-Jarrah, et al., 2015; Zhou et al., 2017). Metode ini dapat digunakan untuk mengidentifikasi pola-pola tersembunyi, memodelkan hubungan kompleks antarvariabel, serta memprediksi risiko kesehatan secara personalisasi (Peng, et al., 2021). Dalam konteks analisis risiko obesitas, implementasi machine learning dapat memberikan pemahaman yang lebih baik mengenai bagaimana aktivitas fisik memengaruhi risiko obesitas (Ferdowsy et al., 2021) serta menghasilkan model prediksi yang dapat digunakan untuk intervensi dini dan pencegahan (Triantafyllidis et al., 2020).

Penelitian ini bertujuan untuk menganalisis risiko obesitas berdasarkan aktivitas fisik dengan menggunakan metode machine learning. Artikel ini akan mengeksplorasi hubungan antara variabel-variabel yang terkait dengan aktivitas fisik, seperti intensitas, durasi, dan frekuensi, serta faktor lain jenis kelamin, dan keterlibatan dalam ekstrakurikuler. Selain itu, penelitian ini juga akan menilai keandalan model machine learning dalam memberikan prediksi risiko obesitas dibandingkan dengan metode konvensional.

METODE PENELITIAN

Metode *cross-sectional study* digunakan dalam penelitian ini untuk mengungkap variabel perilaku aktivitas fisik, perilaku sedentari dan kaitannya dengan resiko obesitas. Penelitian dilaksanakan sejak bulan Februari sampai dengan Agustus 2024 di Universitas Pendidikan Indonesia, Bandung. Target sasaran dan subjek penelitian ini adalah usia remaja yang dalam hal ini mahasiswa Universitas Pendidikan Indonesia dari berbagai jurusan sebanyak 384 orang mahasiswa yang bersedia untuk menjadi volunteer dalam penelitian.

Body Mass Index (BMI), dan kelebihan berat badan atau status obesitas merupakan variable utama pada penelitian ini. BMI dihitung berdasarkan rumus berat badan (Kg) dibagi tinggi badan kuadrat (m²). Adapun klasifikasi tabel BMI Asia Pasifik, dimana berat badan normal $18.5 \leq \text{BMI} < 22,9 \text{ kg/m}^2$, overweight as $23 \leq \text{BMI} < 24,9 \text{ kg/m}^2$, dan obesitas $\text{BMI} \geq 25 \text{ kg/m}^2$ (Lim et.al, 2017) .

Level aktivitas fisik dikelompokkan menjadi lima kategori yaitu: sedentary (intensitas < 100 hitungan/menit), ringan ($100 \leq \text{intensitas} < 760$ hitungan/menit), gaya hidup ($760 \leq \text{intensitas} < 2200$ hitungan/menit), sedang ($2200 \leq \text{intensitas} < 6000$ hitungan/menit), dan tinggi ($\text{intensitas} \geq 6000$ hitungan/menit) (Wanner et.al, 2017).

Pada tahap awal, peneliti melakukan rekrutment terhadap partisipan yang bersedia untuk menjadi volunteer dalam penelitian. Selanjutnya partisipan diminta untuk mengisi biodata/demografi termasuk data BMI dan surat pernyataan persetujuan. Partisipan yang telah menyatakan setuju untuk berpartisipasi lalu diminta untuk menggunakan instrumen accelerometer selama tujuh hari. Penggunaan accelerometer ini bertujuan untuk memperoleh data aktivitas fisik keseharian dari partisipan penelitian.

Accelerometer Actigraph GT3X dan IPAQ-SF digunakan untuk memperoleh data terkait dengan aktivitas fisik keseharian partisipan penelitian. Akselerometer Actigraph GT3X merekam durasi aktivitas sampel melalui sensor gerakan tubuh. Durasi yang terekam kemudian dianalisis menggunakan algoritma cut poin dalam perangkat lunak ActiLife, yang disesuaikan dengan karakteristik partisipan, yang menjadi subjeknya. Perhitungan selanjutnya menghasilkan luaran, termasuk jumlah langkah, pengeluaran energi, dan MET, yang digunakan untuk mengklasifikasikan aktivitas fisik.

Penelitian ini menggunakan empat algoritma klasifikasi dan regresi logistik tradisional untuk menguji hubungan antara aktivitas fisik dan status berat badan. Empat algoritma klasifikasi tersebut adalah *local k-nearest neighbours (KNN)*, *Classification via Regression (CVR)*, *decision tree*, dan *random forest*. Adapun software yang digunakan untuk analisis data yaitu dengan menggunakan Rapidminer Studio Versi 10.1

HASIL DAN PEMBAHASAN

Hasil

Tabel 1 memuat informasi mengenai karakteristik sampel penelitian, seperti jenis kelamin, dan partisipasi dalam kegiatan ekstrakurikuler atau unit kegiatan mahasiswa, serta status BMI. Penelitian ini melibatkan 280 mahasiswa dari berbagai program studi, dengan 63,54% di antaranya merupakan perempuan. Rentang usia partisipan adalah 17 hingga 23 tahun. Sekitar 30% dari mahasiswa, baik laki-laki maupun perempuan, termasuk dalam kategori kelebihan berat badan (*overweight*) dan obesitas, dengan proporsi perempuan yang lebih tinggi dibandingkan laki-laki. Berdasarkan keterlibatan dalam kegiatan ekstrakurikuler, lebih dari 26% mahasiswa yang tidak mengikuti kegiatan ekstrakurikuler berada dalam kategori overweight dan obesitas. Hal serupa juga ditemukan pada mahasiswa yang aktif dalam kegiatan ekstrakurikuler, baik yang bersifat olahraga maupun non-olahraga, di mana lebih dari 26% termasuk dalam kategori yang sama.

Tabel 1. Karakteristik Partisipan Penelitian

Variabel	Normal 18.5 ≤ BMI < 22,9 kg/m ²		Overweight 23 ≤ BMI < 24,9 kg/m ²		Obesitas B MI ≥ 25 kg/m ²	
	N	Rata-rata (%)	N	Rata-rata (%)	N	Rata-rata (%)
	Gender					
Laki-laki	101	72,14	21	15	18	12,86
Perempuan	179	73,36	29	11,89	36	14,75
Ekstrakurikuler						
Non-Ekskul	175	73,53	26	10,92	37	15,55
Ekskul Non-olahraga	74	71,15	18	17,31	12	11,54
Ekskul Olahraga	31	73,81	6	14,29	5	11,90

Analisis selanjutnya yaitu memprediksi BMI khususnya kelebihan berat badan dan obesitas berdasarkan gender, level aktivitas fisik dan perilaku sedentari. Partisipan di bagi ke dalam dua kelompok, yaitu obesitas dan non-obesitas (termasuk overweight dan obesitas). Tabel 2 menyajikan hasil dari performa klasifikasi *algoritma machine learning* yang dianalisis dengan Rapidminer. Algoritma *Random forest* memiliki akurasi paling tinggi dibandingkan dengan tiga algoritma lainnya dalam memprediksi risiko obesitas, yaitu 71,09%, sementara CVR akurasinya paling rendah yaitu 46,09%. Demikian juga sensitifitas random forets paling tinggi yaitu 37,50%, sementara KNN sensitifitasnya paling rendah yaitu 14,81%. Untuk spesificitas, algoritma *decision tree* persentasenya paling tinggi, yaitu 77,5% sementara yang terendah yaitu KNN dengan 71,29%.

Tabel 2. Hasil Analisis Akurasi, Sensitivitas, Spesifisitas

Metode	Local KNN	Decision tree	Random forest	CVR
Accuracy	59,38%	67,97%	71,09%	46,09%
Sensitivity	14,81%	36,67%	37,50%	29,92%
Specificity	71,29%	77,5%	75,89%	76,00%

Dua model algoritma, yaitu *KNN* dan *CVR* memiliki akurasi di bawah rata-rata model lainnya. Sementara itu, *decision tree* dan *random forest* akurasinya di atas rata-rata. Meskipun *random forest* memiliki akurasi paling tinggi diantara tiga algoritma lainnya, tetapi spesifisitasnya masih di bawah *decision tree*. Sementara itu, meskipun *CVR* secara akurasi dan sesitivitasnya rendah, namu spesifisitasnya tidak berbeda jauh dari tiga algoritma lainnya.

Pembahasan

Studi ini mengkaji resiko kelebihan berat badan dan obesitas pada remaja mahasiswa dengan menggunakan data aktivitas fisik yang diukur secara objektif dan teknik machine learning. Hasil penelitian menunjukkan bahwa aktivitas fisik sedang dan tinggi serta perilaku sedentari merupakan faktor kunci utama dalam memprediksi resiko kelebihan berat badan dan obesitas pada remaja mahasiswa. Selain itu, jumlah *metabolic equivalent of task* (MET) dan lamanya perilaku sedentari tercatat memberikan kontribusi paling tinggi dibandingkan dengan variabel lainnya, meskipun hasil penelitian lain pada anak usia dini dengan statistika sederhana menunjukkan tidak adanya korelasi antara METs dengan BMI (Ramdani et al., 2019). Hasil ini menunjukkan bahwa jumlah energi yang dikeluarkan dan durasi aktivitas fisik lebih penting daripada aktivitas fisik dengan intensitas. Aktivitas fisik meningkatkan pengeluaran energi seseorang dan membantu individu menjaga

keseimbangan energi atau bahkan menurunkan berat badan selama konsumsi energi tidak dikompensasi oleh asupan kalori (Strasser, 2013). Lingkungan tempat tinggal secara tidak langsung memberikan dampak terhadap kemungkinan resiko terjadinya kelebihan berat badan dan obesitas (Sallis et al., 2020), meskipun beberapa kajian menunjukkan inkonsistensi hubungan antara lingkungan dengan perilaku aktivitas fisik (Van Cauwenberg et al., 2011). Intensitas aktivitas fisik dan perilaku sedentari memberikan kontribusi lebih besar dibandingkan dengan status tempat tinggal dan keterlibatan dalam ekstrakurikuler dalam memprediksi resiko obesitas.

Penelitian ini juga membandingkan perbedaan performa algoritma *machine learning* dalam memprediksi status BMI, di mana *random forest* memiliki akurasi paling tinggi daripada tiga model lainnya. Namun demikian, performa akurasi *decision tree* sedikit di bawah *random forest*. Selain akurasi, sensitivitas *random forest* juga paling tinggi dari tiga algoritma lainnya, namun tidak halnya dengan spesifisitas. Sensitivitas *random forest* hanya 1% saja di atas *decision tree* analisis resiko obesitas pada remaja. Sementara itu, sensitivitas algoritma *decision tree* hanya 1% di atas CVR, 2% di atas *random forest*, dan 4% lebih di atas KNN.

Penelitian sebelumnya menunjukkan bahwa algoritma random subspace memiliki akurasi tertinggi dibandingkan dengan 10 model lainnya dalam memprediksi status berat badan (Cheng et al., 2021). Penelitian lain melaporkan bahwa algoritma Naïve Bayes mencapai akurasi tertinggi, yaitu 52,38%, dibandingkan tiga model lainnya dalam memprediksi BMI berdasarkan tingkat aktivitas fisik (Saputra et al., 2024). Sementara itu, kajian lain yang memprediksi obesitas pada anak usia dini menemukan bahwa algoritma model ID3 memiliki akurasi sebesar 85% dengan sensitivitas 89%, yang merupakan hasil tertinggi di antara enam model machine learning yang diuji (Dugan et al., 2015). Meskipun hasil dari berbagai penelitian berbeda, secara umum teknik machine learning menunjukkan akurasi prediksi yang lebih baik dibandingkan metode sederhana seperti analisis regresi atau teknik statistika lainnya (Safaei et al., 2021). Perbedaan hasil ini kemungkinan dipengaruhi oleh jumlah dataset dan variabel prediktor yang digunakan.

Penelitian ini memiliki beberapa limitasi, salah satunya adalah bahwa Actigraph GT3X hanya bisa merekam durasi dan intensitas aktivitas yang dilakukan oleh partisipan, tetapi tidak dapat mengetahui aktivitas apa yang dilakukan. Kedua, karena Actigraph GT3X tidak tahan air dan harus dilepas selama aktivitas seperti mandi dan berenang, sehingga aktivitas tersebut tidak dapat terekam. Ketiga, aktivitas sedentari dalam penelitian ini hanya diukur berdasarkan rekaman Actigraph GT3X tanpa verifikasi langsung dari partisipan, terutama untuk aktivitas yang berkaitan dengan *screen time*. Keterbatasan-keterbatasan ini akan menjadi fokus untuk penelitian lebih lanjut. Meskipun demikian, penelitian ini memiliki keunggulan utama, yaitu penerapan *machine learning*, baik supervised maupun unsupervised learning, untuk memprediksi resiko obesitas sekaligus mengidentifikasi kelompok dengan perilaku berisiko tinggi. Pendekatan ini tidak hanya menghasilkan model prediksi yang akurat, tetapi juga memberikan wawasan penting tentang faktor-faktor seperti aktivitas fisik dan durasi aktivitas sedentari yang signifikan dalam memprediksi obesitas. Model yang dikembangkan ini dapat dimanfaatkan untuk mendukung promosi aktivitas fisik dan membantu perancangan kebijakan kampus yang lebih efektif dalam mengurangi prevalensi obesitas di kalangan mahasiswa.

KESIMPULAN

Penelitian ini mengungkapkan bahwa aktivitas fisik, total *Metabolic Equivalent of Task* (MET), dan durasi perilaku sedentari merupakan faktor utama dalam memprediksi resiko obesitas pada mahasiswa. Dalam analisis menggunakan berbagai algoritma machine learning, *random forest* menghasilkan akurasi prediksi terbaik untuk resiko obesitas. Selain

akurasi, *random forest* juga memiliki sensitivitas paling tinggi dalam menganalisis resiko obesitas berdasarkan aktivitas fisik pada remaja. Namun demikian, spesifisitas *random forest* lebih rendah dari *decision tree* dan CVR.

REKOMENDASI

Penelitian lebih lanjut perlu menambah instrumen untuk memperoleh data yang secara kuantitas lebih banyak. Selain itu, catatan harian aktivitas yang dilakukan oleh partisipan diperlukan untuk mengetahui aktivitas fisik keseharian apa saja yang mereka lakukan.

UCAPAN TERIMAKASIH

Ucapan terimakasih disampaikan kepada semua partisipan yang telah bersedia berpartisipasi pada penelitian ini. Selain itu juga kepada pihak Universitas Pendidikan Indonesia, melalui program studi Ilmu Keolahragaan, Fakultas Pendidikan Olahraga dan Kesehatan yang telah membiayai penelitian ini.

DAFTAR PUSTAKA

- Albuquerque, D., Nóbrega, C., Manco, L., & Padez, C. (2017). The contribution of genetics and environment to obesity. *British medical bulletin*, 123(1), 159-173.
- Al-Jarrah, O. Y., Yoo, P. D., Muhaidat, S., Karagiannidis, G. K., & Taha, K. (2015). Efficient machine learning for big data: A review. *Big Data Research*, 2(3), 87-93.
- Bray, G. A., Frühbeck, G., Ryan, D. H., & Wilding, J. P. (2016). Management of obesity. *The Lancet*, 387(10031), 1947-1956.
- Cheng, X., Lin, S. Y., Liu, J., Liu, S., Zhang, J., Nie, P., ... & Xue, H. (2021). Does physical activity predict obesity—A machine learning and statistical method-based analysis. *International Journal of environmental research and public Health*, 18(8), 3966.
- Chobot, A., Górowska-Kowolik, K., Sokołowska, M., & Jarosz-Chobot, P. (2018). Obesity and diabetes—Not only a simple link between two epidemics. *Diabetes/metabolism research and reviews*, 34(7), e3042.
- Chrostowska, M., Szyndler, A., Hoffmann, M., & Narkiewicz, K. (2013). Impact of obesity on cardiovascular health. *Best practice & research Clinical endocrinology & metabolism*, 27(2), 147-156.
- Dugan, T. M., Mukhopadhyay, S., Carroll, A., & Downs, S. (2015). Machine learning techniques for prediction of early childhood obesity. *Applied clinical informatics*, 6(03), 506-520.
- Egger, G., & Dixon, J. (2014). Beyond obesity and lifestyle: a review of 21st century chronic disease determinants. *BioMed research international*, 2014(1), 731685.
- Ferdowsy, F., Rahi, K. S. A., Jabiullah, M. I., & Habib, M. T. (2021). A machine learning approach for obesity risk prediction. *Current Research in Behavioral Sciences*, 2, 100053.
- Gawlik, K., Zwierzchowska, A., & Celebańska, D. (2018). Impact of physical activity on obesity and lipid profile of adults with intellectual disability. *Journal of Applied Research in Intellectual Disabilities*, 31(2), 308-311.
- Golden, A., & Kessler, C. (2020). Obesity and genetics. *Journal of the American Association of Nurse Practitioners*, 32(7), 493-496..
- Hruby, A., Manson, J. E., Qi, L., Malik, V. S., Rimm, E. B., Sun, Q., ... & Hu, F. B. (2016). Determinants and consequences of obesity. *American journal of public*

- health*, 106(9), 1656-1662.
- Huang, T. T., Drewnowski, A., Kumanyika, S. K., & Glass, T. A. (2009). A systems-oriented multilevel framework for addressing obesity in the 21st century. *Preventing chronic disease*, 6(3).
- Jajat, J. (2020). Dampak Berita Olahraga di Media Massa (Internet) terhadap Sikap Siswa SMA pada Aktivitas Jasmani. *Jurnal Keolahragaan*, 6(1), 44-53.
- Jiang, L., Wu, Z., Xu, X., Zhan, Y., Jin, X., Wang, L., & Qiu, Y. (2021). Opportunities and challenges of artificial intelligence in the medical field: current application, emerging problems, and problem-solving strategies. *Journal of International Medical Research*, 49(3), 03000605211000157.
- 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.
- Koolhaas, C. M., Dhana, K., Schoufour, J. D., Ikram, M. A., Kavousi, M., & Franco, O. H. (2017). Impact of physical activity on the association of overweight and obesity with cardiovascular disease: The Rotterdam Study. *European journal of preventive cardiology*, 24(9), 934-941.
- Krupa-Kotara, K., & Dakowska, D. (2021). Impact of obesity on risk of cancer. *Central European Journal of Public Health*, 29(1), 38-44.
- Morales, M. E., & Berkowitz, S. A. (2016). The relationship between food insecurity, dietary patterns, and obesity. *Current nutrition reports*, 5, 54-60.
- Myers, J., Kokkinos, P., & Nyelin, E. (2019). Physical activity, cardiorespiratory fitness, and the metabolic syndrome. *Nutrients*, 11(7), 1652.
- Nguyen, T., & Lau, D. C. (2012). The obesity epidemic and its impact on hypertension. *Canadian Journal of Cardiology*, 28(3), 326-333.
- Pan, X. F., Wang, L., & Pan, A. (2021). Epidemiology and determinants of obesity in China. *The lancet Diabetes & endocrinology*, 9(6), 373-392.
- Peng, J., Jury, E. C., Dönnies, P., & Ciurtin, C. (2021). Machine learning techniques for personalised medicine approaches in immune-mediated chronic inflammatory diseases: applications and challenges. *Frontiers in pharmacology*, 12, 720694.
- 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), 45-52.
- Rohde, K., Keller, M., la Cour Poulsen, L., Blüher, M., Kovacs, P., & Böttcher, Y. (2019). Genetics and epigenetics in obesity. *Metabolism*, 92, 37-50.
- Rondanelli, M., Klersy, C., Terracol, G., Talluri, J., Maugeri, R., Guido, D., ... & Perna, S. (2016). Whey protein, amino acids, and vitamin D supplementation with physical activity increases fat-free mass and strength, functionality, and quality of life and decreases inflammation in sarcopenic elderly. *The American journal of clinical nutrition*, 103(3), 830-840.
- Safaei, M., Sundararajan, E. A., Driss, M., Boulila, W., & Shapi'i, A. (2021). A systematic literature review on obesity: Understanding the causes & consequences of obesity and reviewing various machine learning approaches used to predict obesity. *Computers in biology and medicine*, 136, 104754.
- Sallis, J. F., Cerin, E., Kerr, J., Adams, M. A., Sugiyama, T., Christiansen, L. B., ... & Owen, N. (2020). Built environment, physical activity, and obesity: findings from the international physical activity and environment network (IPEN) adult study. *Annual review of public health*, 41(1), 119-139.
- Saputra, D. S., Jajat., Damayanti, I., Sultoni, K., Ruhayati, Y., & Rahayu, N. I. (2024). Prediksi BMI Berdasarkan Level Aktivitas Fisik dengan Metode Analisis Machine Learning. *Jurnal Pendidikan Kesehatan Rekreasi*, 10(1), 165-175.

- Schmitz, K. H., Neuhouser, M. L., Agurs-Collins, T., Zanetti, K. A., Cadmus-Bertram, L., Dean, L. T., & Drake, B. F. (2013). Impact of obesity on cancer survivorship and the potential relevance of race and ethnicity. *Journal of the National Cancer Institute, 105*(18), 1344-1354.
- Seravalle, G., & Grassi, G. (2024). Obesity and hypertension. *Obesity: Clinical, Surgical and Practical Guide, 65-79*.
- Sominsky, L., & Spencer, S. J. (2014). Eating behavior and stress: a pathway to obesity. *Frontiers in psychology, 5*, 434.
- Specchia, M. L., Veneziano, M. A., Cadeddu, C., Ferriero, A. M., Mancuso, A., Ianuale, C., ... & Ricciardi, W. (2015). Economic impact of adult obesity on health systems: a systematic review. *The European Journal of Public Health, 25*(2), 255-262.
- Spieker, E. A., & Pyzocha, N. (2016). Economic impact of obesity. *Primary Care: Clinics in Office Practice, 43*(1), 83-95.
- Strasser, B. (2013). Physical activity in obesity and metabolic syndrome. *Annals of the New York Academy of Sciences, 1281*(1), 141-159.
- Sullivan, P. W., Ghushchyan, V. H., & Ben-Joseph, R. (2008). The impact of obesity on diabetes, hyperlipidemia and hypertension in the United States. *Quality of Life Research, 17*, 1063-1071.
- Sweatt, K., Garvey, W. T., & Martins, C. (2024). Strengths and Limitations of BMI in the Diagnosis of Obesity: What is the Path Forward?. *Current Obesity Reports, 13*(3), 584-595.
- 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.
- Triantafyllidis, A., Polychronidou, E., Alexiadis, A., Rocha, C. L., Oliveira, D. N., da Silva, A. S., ... & Tzovaras, D. (2020). Computerized decision support and machine learning applications for the prevention and treatment of childhood obesity: A systematic review of the literature. *Artificial Intelligence in Medicine, 104*, 101844.
- Van Cauwenberg, J., De Bourdeaudhuij, I., De Meester, F., Van Dyck, D., Salmon, J., Clarys, P., & Deforche, B. (2011). Relationship between the physical environment and physical activity in older adults: a systematic review. *Health & place, 17*(2), 458-469.
- 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.
- 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.
- Yang, L., Cao, C., Kantor, E. D., Nguyen, L. H., Zheng, X., Park, Y., ... & Cao, Y. (2019). Trends in sedentary behavior among the US population, 2001-2016. *Jama, 321*(16), 1587-1597.
- Zalesin, K. C., Franklin, B. A., Miller, W. M., Peterson, E. D., & McCullough, P. A. (2008). Impact of obesity on cardiovascular disease. *Endocrinology and metabolism clinics of North America, 37*(3), 663-684.
- Zhou, L., Pan, S., Wang, J., & Vasilakos, A. V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing, 237*, 350-361.