

## Kepatuhan terhadap Pedoman Aktivitas Fisik WHO pada Anak Usia Dini : Evaluasi dengan Metode *Machine learning*

Akhmad Faizal Ramdhan <sup>1)</sup>, Adang Suherman <sup>2)</sup>, Jajat <sup>3)\*</sup>, Kuston Sultoni <sup>4)</sup>,  
Imas Damayanti <sup>5)</sup>, Yati Ruhayati <sup>6)</sup>

<sup>1), 2), 3), 4), 5) dan 6)</sup> Universitas Pendidikan Indonesia

E-mail : <sup>1)</sup> [faizal797@upi.edu](mailto:faizal797@upi.edu), <sup>2)</sup> [adangsuherman@upi.edu](mailto:adangsuherman@upi.edu), <sup>3)</sup> [jajat\\_kurdul@upi.edu](mailto:jajat_kurdul@upi.edu),  
<sup>4)</sup> [kuston.sultoni@upi.edu](mailto:kuston.sultoni@upi.edu), <sup>5)</sup> [imas\\_d@upi.edu](mailto:imas_d@upi.edu), <sup>6)</sup> [yatiruhayati@upi.edu](mailto:yatiruhayati@upi.edu)

### ABSTRAK

Studi ini berupaya untuk mengevaluasi dan mengukur tingkat aktivitas fisik anak usia dini sejalan dengan pedoman Organisasi Kesehatan Dunia (WHO), menggunakan teknik klasifikasi *machine learning* pada data yang diperoleh dari kuesioner. Menyadari pentingnya aktivitas fisik di tahun-tahun formatif, penelitian ini bertujuan untuk menilai kepatuhan terhadap ambang batas aktivitas yang direkomendasikan WHO pada anak usia dini. Metodologi ini mengintegrasikan kuesioner komprehensif yang mengungkap beragam aspek pola aktivitas fisik anak usia dini, yang mencakup durasi, intensitas, dan jenis aktivitas yang dilakukan dalam berbagai situasi. Sebanyak 99 orang tua siswa melaporkan aktivitas keseharian anak mereka yang berusia 4 sampai 5 tahun ( $M = 4,59 \pm 0,41$ ). Dengan memanfaatkan model klasifikasi algoritma *machine learning decision tree*, penelitian ini memproses data yang dikumpulkan untuk membedakan pola dan mengklasifikasikan tingkat aktivitas berdasarkan kriteria WHO. Hasilnya menunjukkan, indikator waktu aktivitas, waktu tidur dan waktu bermain menjadi indikator penentu *decision tree* dalam mengklasifikasi kepatuhan anak usia dini terhadap rekomendasi aktivitas fisik WHO. Lebih lanjut, *machine learning decision tree* sangat efektif dalam mengevaluasi dan mengklasifikasikan kepatuhan aktivitas fisik anak usia dini dengan performa akurasi 90%. Efektivitas pendekatan *machine learning decision tree* dalam mengevaluasi dan mengkategorikan tingkat aktivitas fisik anak usia dini secara akurat, menyoroti bidang-bidang potensial untuk intervensi dan strategi yang ditargetkan untuk meningkatkan kepatuhan terhadap aktivitas fisik yang direkomendasikan oleh WHO. Metodologi ini menawarkan instrumen yang menjanjikan bagi para profesional kesehatan, pembuat kebijakan, dan pendidik untuk lebih memahami dan mengatasi perilaku aktivitas fisik anak usia dini, sehingga berkontribusi terhadap promosi gaya hidup sehat sejak usia dini.

**Kata kunci :** *artificial intelligence*; gaya hidup aktif; perilaku sedentari

### ABSTRACT

*This study aimed to evaluate and measure the physical activity levels of young children in line with World Health Organization (WHO) guidelines, using machine learning classification techniques on data obtained from questionnaires. Recognizing the importance of physical activity in the formative years, this study aimed to assess compliance with WHO recommended activity thresholds in early childhood. This methodology integrates a comprehensive questionnaire that reveals various aspects of early childhood physical activity patterns, including duration, intensity and types of activities performed in various situations. A total of 99 parents reported the daily activities of their children aged 4 to 5 years ( $M = 4,59 \pm 0,41$ ). By utilizing a machine learning decision tree algorithm classification model, this research processes the collected data to distinguish patterns and classify activity levels based on WHO criteria. The results shows that indicators of activity time, sleep time and play time are the determining indicators for the decision tree in classifying young children's compliance with*

**Penulis Korespondensi :** Jajat, Universitas Pendidikan Indonesia  
E-mail : [jajat\\_kurdul@upi.edu](mailto:jajat_kurdul@upi.edu)



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

*WHO physical activity recommendations. Furthermore, machine learning decision trees are very effective in evaluating and classifying physical activity compliance in early childhood with an accuracy performance of 90%. The effectiveness of the machine learning decision tree approach in accurately evaluating and categorizing early childhood physical activity levels, highlights potential areas for targeted interventions and strategies to increase adherence to WHO recommended physical activity. This methodology offers a promising instrument for health professionals, policy makers, and educators to better understand and address early childhood physical activity behavior, so that contributing to the promotion of healthy lifestyles from an early age.*

**Keywords :** *artificial intelligence; active life style; sedentary behavior*

## **PENDAHULUAN**

Dewasa ini perkembangan teknologi yang semakin canggih dan modern, sudah menjadi bagian yang tidak terpisahkan dari kehidupan manusia baik anak-anak maupun orang dewasa. Berdasarkan hasil kajian Asosiasi Pengguna Jasa Internet Indonesia (APJII) bahwa sebanyak 215.626.156 jiwa dari total populasi penduduk Indonesia yang berjumlah 275.773.901 jiwa atau sekitar 78,19% pada periode 2023 merupakan pengguna aktif smartphone (Yati, 2023). Sementara itu survei Komisi Perlindungan Anak Indonesia terdapat sekitar 71,3% anak usia sekolah yang memiliki gadget, dimana 52% digunakan untuk chatting dengan teman, 52% menonton youtube, 50% mencari informasi, 42% bersosial media dan lainnya. Ketersediaan dan kemudahan teknologi tersebut tentunya memberikan banyak dampak positif, namun demikian juga tidak sedikit memberikan dampak negatif.

Dampak positif kemajuan teknologi antara lain memudahkan anak-anak dalam mengasah kreativitas dan kecerdasan. Beragam aplikasi digital seperti mewarnai, belajar membaca, dan menulis huruf yang tentunya memberikan dampak positif bagi perkembangan otak hanya dengan

memanfaatkan tablet sebagai sarana belajar. Anak-anak menjadi lebih bersemangat untuk belajar karena aplikasi semacam ini biasanya dilengkapi dengan animasi yang menarik, warna yang cerah, serta lagu-lagu yang ceria. Selain itu, kemampuan berimajinasi membantu pola pikir anak dalam mengatur kecepatan bermain, mengolah strategi dalam permainan, dan membantu meningkatkan kemampuan otak kanan anak (Christensen & Knezek, 2002).

Perkembangan teknologi dan informasi juga memberikan dampak terhadap anak-anak. Dengan perkembangan teknologi informasi, anak-anak sekarang ini rasanya jauh lebih “sadar teknologi” dibanding generasi-generasi di belakangnya (Hatch, 2011). Hal tersebut menjadikan anak usia dini memiliki rasa ingin tahu, dan kemaun belajar yang sangat tinggi khususnya pada masa kanak-kanak awal. Anak usia dini memiliki karakteristik dan dunia sendiri yang jauh berbeda dari orang dewasa. Anak selalu aktif, antusias, dinamis, dan memiliki rasa ingin tahu terhadap apa yang dilihat dan didengarnya, seolah-olah tidak pernah berhenti belajar (Kale & Rey, 2017). Tetapi dibalik kelebihan tersebut terdapat dampak buruk yaitu bagi daya

kembang anak yang disebabkan oleh radiasi di dalam gadget yang dapat merusak jaringan syaraf dan otak anak bila anak sering menggunakan gadget (Al Sagr & Al Sagr, 2020). Dampak buruk lainnya bagi daya aktif anak dan kemampuan anak untuk berinteraksi dengan orang lain. Anak menjadi kurang interaktif dan lebih suka sendiri dengan zona nyamannya bersama gadget. Sehingga menimbulkan sikap individualis pada anak dan kurangnya sikap peduli terhadap sesama baik terhadap orang tua teman, maupun orang lain. Selain itu anak lebih mudah terserang penyakit karena kurangnya aktivitas fisik.

Aktivitas fisik pada anak usia dini menjadi faktor penting untuk menunjang tumbuh kembang anak. Karena pada masa ini anak mengalami masa golden age atau masa keemasan. selama 24 jam sehari, anak-anak prasekolah (berusia 3-4 tahun) melakukan setidaknya 180 menit aktivitas fisik, yang mana setidaknya 60 menitnya harus dalam intensitas sedang hingga kuat (MVPA), menghabiskan waktu tidak lebih dari 1 jam di depan layar (misalnya menonton televisi, menggunakan tablet atau smartphone sambil duduk), dan tidur berkualitas selama 10-13 jam per hari (Okely et al., 2021; WHO, 2021). Namun seiring perkembangan zaman dimana teknologi sudah digunakan di berbagai tingkat usia terkhusus anak usia dini, menjadikan anak malas bergerak karena ketergantungan terhadap gadget. Kurangnya aktivitas fisik memiliki dampak negatif pada sistem kesehatan, lingkungan, pembangunan ekonomi, kesejahteraan masyarakat dan kualitas hidup dan dapat mempengaruhi kepercayaan diri, bahkan menimbulkan

konsep diri negatif dalam kegiatan fisik (Mirza, 2017). Sedangkan melakukan aktivitas fisik secara teratur terbukti membantu mencegah dan mengelola penyakit tidak menular seperti penyakit jantung, stroke, diabetes, dan beberapa jenis kanker. Ini juga membantu mencegah hipertensi, menjaga berat badan yang sehat dan dapat meningkatkan kesehatan mental, kualitas hidup dan kesejahteraan (WHO, *Physical Activity*, 2022).

Hasil penelitian sebelumnya yang telah membuktikan bahwa anak usia dini pada zaman ini sedang mengalami krisis aktivitas fisik karena penggunaan teknologi yang menjadi kebiasaan dalam kehidupan sehari-harinya menjadi perhatian dunia terutama para peneliti di bidang ilmu teknologi, kesehatan, dan aktifitas fisik (Biddle et al., 2004). Perhatian dunia tersebut menjadikan penelitian dalam bidang aktifitas fisik sangat menarik untuk dibahas terutama pada anak usia dini untuk keberlangsungan hidup kedepannya. Tidak dapat dipungkiri dengan perkembangan zaman ini teknologi sudah masuk dan menjadi bagian penting dalam kehidupan sehari-hari, begitupun para peneliti khususnya dalam bidang aktivitas fisik saat ini sudah mulai memanfaatkan kecanggihan teknologi dengan kecerdasan buatan (*artificial intelligence*) pada cabang *machine learning* yang digunakan untuk menganalisis prediksi, klasifikasi, kuantifikasi, dan lainnya pada sumber data dan instrument yang berbeda (Horvitz & Mulligan, 2015).

Penggunaan *machine learning* ini membantu para peneliti membuat sistem ataupun algoritma untuk melihat hasil ataupun prediksi sesuai dengan sumber

data dan instrument yang digunakan. Jumlah data dan penggunaan instrument kuesioner akan sangat berpengaruh pada hasil atau prediksinya karena semakin banyak data maka akurasi pada sistem algoritma akan semakin akurat, begitupun dengan penggunaan kuesioner yang berbeda maka hasilnya akan bervariasi (Batta, 2018). Aplikasi *machine learning* dapat membuat pola dan fitur tertentu berdasarkan jumlah data dan tujuan hasilnya. Hal ini membuktikan bahwa penggunaan *machine learning* dapat sangat berguna dalam memprediksi aktivitas fisik pada anak usia dini. Melihat dari penelitian sebelumnya pembahasan mengenai penggunaan *machine learning* ini sudah dilakukan dengan sumber data dan instrument yang berbeda (Lima et al., 2016).

Di Indonesia penelitian mengenai pengklasifikasian aktivitas fisik pada anak usia dini menggunakan *machine learning* lebih mudah dilakukan dengan instrumen kuesioner, selain pendataannya yang dapat dilakukan diberbagai penjuru di Indonesia, pengisian kuesioner pun dapat dilakukan dalam waktu bersamaan dan jumlah data yang didapat kemungkinan lebih banyak dibanding menggunakan instrument lain, namun kelemahan pada instrument ini data yang di masukan belum tentu akurat karena dapat terjadi human error atau kesalahan pada pihak orang tua yang mengisi data tidak sesuai dengan aktivitas anak yang dilakukan pada beberapa hari kebelakang (Lamb & Brodie, 1990). Berdasarkan kelemahan pada penelitian sebelumnya membuat saya lebih tertarik untuk menutupi kelemahan tersebut dan

membuat pembaruan dalam pengklasifikasian aktivitas fisik pada anak usia dini, sehingga pada penelitian ini saya akan menganalisis aktivitas fisik usia dini dengan menggunakan *machine learning* dengan sumber data kuesioner, dengan tujuan memberikan hasil ataupun prediksi yang akurat (Garcia-Chimeno et al., 2017).

## METODE PENELITIAN

Penelitian ini menggunakan metode *machine learning* yang merupakan bagian dari *Artificial Intelligence* (AI). Sebagaimana tujuan penelitian, metode *machine learning* digunakan untuk mengklasifikasi kepatuhan aktivitas fisik pada anak usia dini terhadap pedoman dari WHO.

Data penelitian ini dikumpulkan melalui survei orangtua dengan mengisi kuesioner di Jawa Barat pada tahun 2020 hingga 2021. Partisipan yang terlibat sebanyak 156 orang yang melibatkan orang tua di beberapa Taman Kanak-Kanak (TK) dan Pendidikan Anak Usia Dini (PAUD). Hasil screening terhadap data yang terkumpul, diperoleh 99 jumlah data anak usia dini, yang berumur 4 sampai 5 tahun (rata-rata usia  $4,59 \pm 0,41$ ).

Nilai total aktivitas fisik dihitung dengan satuan *Metabolic Equivalent of Task* (METs). METs adalah sebuah unit yang digunakan untuk mengukur intensitas aktivitas fisik seseorang yang mengacu pada jumlah energi yang dibutuhkan oleh tubuh saat melakukan suatu aktivitas tertentu. Rumus METs-  

$$\text{menit/minggu} = \text{METs Level (jenis aktivitas)} \times \text{Jumlah Menit Aktivitas} \times \text{Jumlah hari/minggu}$$

**Tabel 1**  
**Kategori METs**

Kategori	METs (Menit/Minggu)
Berat	$\geq 3000$
Sedang	$\geq 600$
Ringan	$< 600$

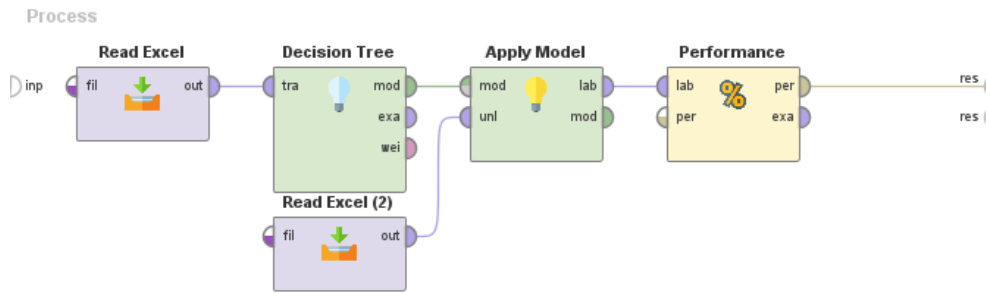
Pada tahap awal dilakukan screening data, penyaringan jawaban responden yang tidak lengkap, tidak relevan, atau tidak sah akan diidentifikasi dan dihapus jika tidak sesuai kriteria. Kemudian melakukan validasi dan verifikasi, pada proses ini dilakukan penyaringan jawaban dari responden yang dapat di verifikasi dengan pertanyaan untuk memastikan keakuratan jawaban dan keabsahan data. Tahapan kedua yaitu kodifikasi, proses modifikasi jawaban responden pada kuesioner, dari data berbentuk kualitatif, seperti jawaban naratif/deskriptif, menjadi data yang dapat diukur secara kuantitatif atau pengkodean seperti variabel yang dapat dihitung atau diukur dalam bentuk angka atau kategori. Selanjutnya menentukan jumlah METs yang sesuai dengan jenis aktivitas dan tingkat intensitas responden dilanjutkan dengan mengkategorikan aktivitas fisik sesuai dengan tingkat intensitas melalui *machine learning*.

*Parent questionnaire physical activity* (PQPA) digunakan untuk memperoleh informasi mengenai aktivitas keseharian pada anak usia dini. PQPA ini dikembangkan oleh tim Sunrise Study Australia, yang bekerjasama dengan beberapa negara termasuk Indonesia khususnya kelompok

bidang keilmuan aktivitas fisik pada program studi ilmu keolahragaan Universitas Pendidikan Indonesia. Orang tua diminta untuk melaporkan aktivitas anak mereka sesuai dengan yang diminta pada kuesioner.

Dalam menentukan klasifikasi memenuhi dan tidaknya aktivitas fisik pada anak usia dini, *WHO guidelines on physical activity and sedentary behaviour* dijadikan rujukan utama. Pada tahap ini, data yang terkumpul dari responden selanjutnya di *screening* dan diberikan label sesuai dengan pedoman dari WHO. Adapun klasifikasi label yang diberikan yaitu memenuhi rekomendasi (*meet guidelines*) dan tidak memenuhi rekomendasi (*not meet guidelines*).

Metode algoritma *machine learning* yang digunakan untuk mengklasifikasi aktivitas fisik anak usia dini dalam penelitian ini yaitu *decision tree*. Sebagaimana penelitian terdahulu yang mengungkapkan bahwa *decision tree* merupakan salah satu algoritma paling baik dalam mengklasifikasi. Adapun *software Rapidminer* digunakan untuk analisis data. Berikut ini adalah gambar tahap proses analisis yang dilakukan pada *software Rapidminer* pada gambar 1.



**Gambar 1**  
Proses Analisis *Decision Tree* dengan *Rapidminer*

Hasil dari screening data, sebanyak 99 data responden dinyatakan dapat dilanjutkan untuk dilakukan pengolahan dan analisis. Selanjutnya data dibagi menjadi 80% data latih yaitu sebanyak 79 data, dan 20% data uji sebanyak 20 data sesuai dengan ketentuan.

**HASIL DAN PEMBAHASAN**

Sebagaimana ketentuan pada *supervised machine learning* bahwa data yang olah dan dianalisis harus terdiri atas data latih dan data uji. Oleh karena itu tahap awal analisis yaitu membagi data aktivitas fisik anak usia dini menjadi dua bagian, yaitu data latih dan data uji. Adapun jumlah data latih yang

digunakan dalam penelitian ini sebanyak 79 data yaitu data yang telah melalui screening. Adapun jumlah data untuk tes yaitu sebanyak 20 dataset. Data latih dan data tes dapat dilihat sebagaimana pada tabel 1 dan tabel 2, input dari software Rapidminer.

Variabel yang menjadi label yaitu memenuhi rekomendasi aktivitas (*meet guideline*) fisik dari WHO atau tidak. Adapun atribut yang digunakan untuk mengklasifikasi rekomendasi tersebut yaitu gender, tempat tinggal, waktu aktivitas fisik, waktu bermain, waktu duduk, dan waktu tidur anak usia dini yang dilaporkan oleh orang tua melalui kuesioner.

Row No.	ID	Meet Guideli...	Gender	Living Area	PA Time	Play Time	Sitting Time	Sleep Tim
1	ID01001	No	Perempuan	Kota	60	90	300	690
2	ID09001	No	Perempuan	Desa	60	30	30	630
3	ID01002	Yes	Laki-laki	Kota	120	90	240	720
4	ID09002	No	Laki-laki	Desa	0	0	10	600
5	ID01004	Yes	Perempuan	Kota	360	10	0	690
6	ID09003	No	Perempuan	Desa	60	30	20	600
7	ID01005	Yes	Laki-laki	Kota	240	60	240	540
8	ID09004	Yes	Perempuan	Desa	150	75	315	720
9	ID01006	No	Perempuan	Kota	70	20	480	630
10	ID09005	No	Perempuan	Desa	90	60	60	630
11	ID01007	Yes	Perempuan	Kota	120	120	300	720
12	ID09006	Yes	Laki-laki	Desa	255	60	120	600
13	ID01008	Yes	Perempuan	Kota	120	120	240	630

ExampleSet (79 examples, 2 special attributes, 6 regular attributes)

**Gambar 2**  
Tabel Dataset Latih untuk Klasifikasi Aktivitas Fisik Anak Usia Dini

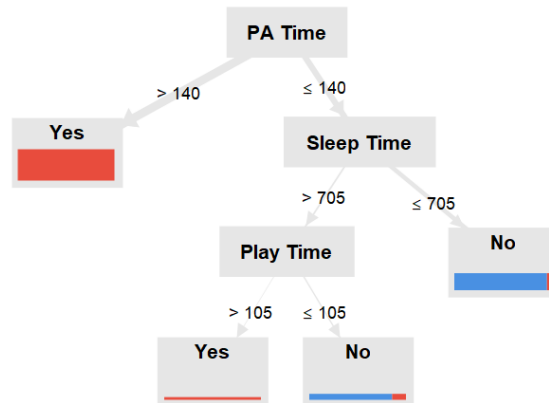
Row No.	ID	Meet Guideli...	Gender	Living Area	PA Time	Play Time	Sitting Time	Sleep Time
1	ID13009	No	Laki-laki	Desa	90	60	240	600
2	ID07002	Yes	Laki-laki	Kota	480	60	120	750
3	ID14001	No	Laki-laki	Desa	90	30	300	600
4	ID07003	Yes	Laki-laki	Kota	270	270	210	720
5	ID14002	No	Laki-laki	Desa	90	30	300	495
6	ID07004	Yes	Perempuan	Kota	480	60	120	750
7	ID14003	No	Laki-laki	Desa	240	60	300	540
8	ID08001	Yes	Laki-laki	Kota	360	120	300	690
9	ID14004	No	Laki-laki	Desa	90	90	180	660
10	ID08002	Yes	Laki-laki	Kota	360	60	300	660
11	ID15002	No	Perempuan	Desa	120	15	180	720
12	ID08003	No	Perempuan	Kota	95	30	230	600
13	ID15003	Yes	Laki-laki	Desa	330	75	330	600

ExampleSet (20 examples, 2 special attributes, 6 regular attributes)

**Gambar 3**  
**Tabel Dataset Tes untuk Klasifikasi Aktivitas Fisik Anak Usia Dini**

Algoritma *machine learning decision tree* menghasilkan pohon keputusan sebagai model dari data latih. Adapun hasil pohon keputusan sebagaimana pada gambar 2, di mana *root* atau akar yang paling atas yaitu waktu aktivitas fisik (PA Time). Berdasarkan pohon keputusan yang dihasilkan maka untuk melihat apakah aktivitas fisik pada anak usia dini memenuhi rekomendasi WHO atau tidak, yang pertama dilihat dari waktu aktivitas fisiknya. Jika waktu aktivitasnya lebih dari 140 menit per-hari maka anak usia dini diklasifikasikan memenuhi rekomendasi aktivitas fisik dan perilaku

sedentari dari WHO. Jika waktu aktivitas fisiknya kurang dari atau sama dengan 140 menit perhari, maka harus dilihat jumlah waktu tidurnya. Jika waktu tidurnya kurang dari 705 menit per-hari maka diklasifikasikan tidak memenuhi rekomendasi WHO, tetapi jika waktu tidurnya lebih dari 705 menit perhari dan waktu bermainnya lebih dari 105 menit perhari maka diklasifikasikan memenuhi rekomendasi dari WHO. Sementara itu jika waktu tidurnya lebih dari 750 menit perhari tetapi waktu bermainnya kurang dari atau sama dengan 105 menit perhari maka diklasifikasikan tidak memenuhi rekomendasi WHO.



**Gambar 4**  
**Pohon Keputusan Klasifikasi Guideline Aktivitas Fisik WHO**

Setelah dihasilkan pohon keputusan, langkah selanjutnya adalah menguji algoritma pohon keputusan tersebut dengan menggunakan data uji. Adapun hasil pengujianya sebagaimana tertera pada tabel 3 output dari Rapidminer diketahui bahwa ada beberapa daya yang

berbeda antara klasifikasi dengan prediksi *decision tree* yang dihasilkan. Sebagai contoh pada kolom baris no.7 label data uji sebenarnya diklasifikasikan No, namun demikian algoritma mengklasifikasikannya Yes.

Row No.	ID	Meet Guideli...	prediction(...)	confidence(...)	confidence(...)	Gender	Living Area	PA Time
1	ID13009	No	No	0.958	0.042	Laki-laki	Desa	90
2	ID07002	Yes	Yes	0	1	Laki-laki	Kota	480
3	ID14001	No	No	0.958	0.042	Laki-laki	Desa	90
4	ID07003	Yes	Yes	0	1	Laki-laki	Kota	270
5	ID14002	No	No	0.958	0.042	Laki-laki	Desa	90
6	ID07004	Yes	Yes	0	1	Perempuan	Kota	480
7	ID14003	No	Yes	0	1	Laki-laki	Desa	240
8	ID08001	Yes	Yes	0	1	Laki-laki	Kota	360
9	ID14004	No	No	0.958	0.042	Laki-laki	Desa	90
10	ID08002	Yes	Yes	0	1	Laki-laki	Kota	360
11	ID15002	No	No	0.857	0.143	Perempuan	Desa	120
12	ID08003	No	No	0.958	0.042	Perempuan	Kota	95
13	ID15003	Yes	Yes	0	1	Laki-laki	Desa	330

ExampleSet (20 examples, 5 special attributes, 6 regular attributes)

**Gambar 5**  
**Tabel Data Hasil Pengujian Algoritma Machine learning Decision Tree**

Langkah selanjutnya untuk mengukur performa atau kemampuan

dari *algoritma decision tree* yang telah dihasilkan, maka dilakukan pengukuran



akurasi. Pengukuran ini dilakukan untuk menguji berapa banyak data yang berhasil diklasifikasikan dengan benar oleh *algoritma machine learning decision tree*. Akurasi ini menjadi

patokan mengenai bagaimana performa dari algoritma *machine learning*. Semakin tinggi akurasi, maka akan semakin banyak data yang diklasifikasikan dengan benar.

accuracy: 90.00%

	true No	true Yes	class precision
pred. No	8	1	88.89%
pred. Yes	1	10	90.91%
class recall	88.89%	90.91%	

**Gambar 6**  
**Tabel Confusion Matrix Hasil Pengujian Performa Akurasi**  
**Decision Tree Machine learning**

Hasil pengujian *performace vector* sebagaimana pada tabel 4 diketahui bahwa dari sembilan data sebenarnya yang diklasifikasikan No, delapan data diklasifikasikan sesuai dan satu data diklasifikasi oleh *machine learning* ke dalam Yes dengan persentase 88,89%. Selanjutnya dari 11 data yang sebenarnya diklasifikasikan Yes, 10 data diklasifikasikan benar dan satu data diklasifikasikan salah yaitu No, dengan akurasi 90,91%. Total akurasi secara keseluruhan dari performa akurasi dari klasifikasi algoritma *decision tree* yaitu 90%. Dilihat dari performa akurasi maka dapat dinyatakan bahwa *machine learning algoritma decisin tree* memiliki akurasi cukup baik dalam mengklasifikasi kesesuaian aktivitas fisik.

Tujuan penelitian ini untuk mengklasifikasi aktivitas fisik pada anak usia dini berbasis data kuesioner dengan menggunakan metode *machine learning algoritma decision tree*. Klasifikasi yang dimaksud yaitu kesesuaian aktivitas fisik

dalam memenuhi guideline dari WHO. Hasil pengujian menunjukkan bahwa algoritma *machine learning decision tree* dapat mengklasifikasi kesesuaian aktivitas fisik sesuai dengan pedoman dari WHO. *Decision tree* memiliki akurasi yang cukup baik dalam mengklasifikasi aktivitas fisik pada anak usia dini, berbasis data kuesioner dengan performa akurasi 90%. Hasil penelitian ini sejalan dengan penelitian terdahulu di mana algoritma *machine learning decision tree* berguna untuk memprediksi klasifikasi aktif dan tidak aktif usia remaja dengan akurasi antara 70% sampai 81% (Aznar et al., 2018).

Pada penelitian lain, algoritma *decision tree* juga digunakan untuk mengklasifikasi postur dan aktivitas fisik melalui analisis aktivitas duduk, berdiri, berjalan, bersepeda dan menaiki tangga di mana performa akurasi *machine learning decision tree* mencapai hampir 90% (Zhang et al., 2013). Sementara itu penelitian lain yang mengklasifikasi aktivitas fisik keseharian manusia seperti

duduk, berdiri, berjalan, dan berdiri dengan menggunakan algoritma *machine learning decision tree* dan *naïve bayes* menunjukkan performa akurasi 89,5% sampai 99,9% (Maswadi, 2021). Artinya bahwa kemampuan *machine learning* dalam mengklasifikasi aktivitas fisik dapat diandalkan meskipun memiliki performa akurasi yang berbeda-beda.

Variabel atau atribut untuk menganalisis kesesuaian klasifikasi aktivitas fisik dan perilaku sedentari WHO yaitu gender, tempat tinggal, waktu aktivitas fisik, waktu bermain, waktu duduk, dan waktu tidur anak usia dini. Hasil analisis sebagaimana ditunjukkan pada pohon keputusan yang dihasilkan waktu aktivitas fisik, waktu tidur dan waktu bermain anak usia dini menjadi faktor penentu *decision tree* dalam mengklasifikasi kesesuaian dengan rekomendasi dari WHO. Sebagaimana rekomendasi dari WHO untuk anak usia 3 sampai 4 tahun, untuk aktivitas fisik termasuk bermain di luar rumah setidaknya 180 menit per-hari (60 menit diantaranya aktivitas vigorous), aktivitas sedentary screen time tidak lebih dari 60 menit per-hari, dan waktu tidur antara 10-13 jam per-hari (World Health Organization, 2021). Dalam hal ini, waktu duduk atau *screen time activity* tidak menjadi salah satu indikator yang muncul pada pohon keputusan. Analisis lebih mendalam terkait hal ini diperlukan untuk kajian berikutnya. Namun demikian setidaknya penelitian ini membuktikan bahwa algoritma *machine learning decision tree* dapat mengklasifikasi kesesuaian aktivitas fisik dan perilaku sedentari anak usia dini sesuai dengan rekomendasi dari WHO.

Penelitian lebih lanjut diperlukan untuk kajian yang sama dengan mempertimbangkan metode atau algoritma lainnya pada *machine learning*. Sebagaimana beberapa hasil penelitian lainnya yang menemukan bahwa *Support Vector Machines* (Alsareii, 2022; Sheng, 2020; Mesanza et al., 2020), *K-Nearest Neighbour* dan *Artificial Neural Networks* (Mesanza et al., 2020) yang merupakan bagian dari algoritma *machine learning* memiliki performa akurasi yang baik dalam mengklasifikasi aktivitas fisik. Pengujian dengan menggunakan algoritma lainnya diharapkan dapat menemukan yang paling cocok dalam mengklasifikasi aktivitas fisik sesuai rekomendasi WHO pada anak usia dini, berbasis data kuesioner. Selain penggunaan model algoritma, jumlah dataset yang digunakan juga menjadi pertimbangan untuk penelitian lebih lanjut. Jumlah dataset dapat menjadi salah satu yang juga mempengaruhi performa tingkat akurasi suatu model algoritma yang digunakan.

## SIMPULAN DAN SARAN

Metode *machine learning* algoritma *decision tree* berguna untuk mengklasifikasi kesesuaian aktivitas fisik anak usia dini sebagaimana direkomendasikan WHO dengan performa akurasi 90%. Variabel atribut utama yang dihasilkan oleh pohon keputusan untuk mengklasifikasi kesesuaian rekomendasi aktivitas fisik WHO yaitu waktu aktivitas fisik, waktu tidur dan waktu bermain anak usia dini yang dilaporkan oleh orang tua melalui kuesioner. Hasil ini memberikan bukti bahwa metode *machine learning* memiliki kemampuan untuk

mengklasifikasi aktivitas fisik dari berbagai sumber data dan instrumen yang berbeda-beda, sepanjang data tersebut sesuai dengan kebutuhan penelitian.

#### DAFTAR PUSTAKA

- Al Sagr, N. A., & Al Sagr, A. N. (2020). The effect of electronics on the growth and development of young children: A Narrative Review. *Journal of Health Informatics in Developing Countries*, 14(1), 1–13. <https://jhdc.org/index.php/jhidc/article/view/250>
- 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), 1103. <https://doi.org/10.3390/life12081103>
- Aznar, S., Queralt, A., García-Massó, X., Villarrasa-Sapiña, I., & Molina-García, J. (2018). Multifactorial combinations predicting active vs inactive stages of change for physical activity in adolescents considering built environment and psychosocial factors: a classification tree approach. *Health & Place*, 53, 150-154. <https://doi.org/10.1016/j.healthplace.2018.08.001>
- Batta, M. (2018). *Machine learning Algorithms - A Review*. *International Journal of Science and Research (IJSR)*, 18(8), 381–386. <https://doi.org/10.21275/ART20203995>
- Biddle, S. J. H., Gorely, T., & Stensel, D. J. (2004). Health-enhancing physical activity and sedentary behaviour in children and adolescents. *Journal of Sports Sciences*, 22(8), 679–701. <https://doi.org/10.1080/02640410410001712412>
- Christensen, R., & Knezek, G. (2002). Assessing the Impact of Technology in Education. *Computers in the Schools*, 18(2), 5–25. <https://doi.org/10.1300/J025v18n02>
- Garcia-Chimeno, Y., Garcia-Zapirain, B., Gomez-Beldarrain, M., Fernandez-Ruanova, B., & Garcia-Monco, J. C. (2017). Automatic migraine classification via feature selection committee and *machine learning* techniques over imaging and questionnaire data. *BMC Medical Informatics and Decision Making*, 17(1), 1–10. <https://doi.org/10.1186/s12911-017-0434-4>
- Hatch, K. E. (2011). Determining the Effects of Technology on Children" Senior Honors Projects. *The University of Rhode Island*.
- Horvitz, E., & Mulligan, D. (2015). *Machine learning: Trends, perspectives, and prospects*. *Science*, 349(6245), 253–255. <https://doi.org/10.1126/science.aaa8415>
- Kale, D. C., & Rey, M. Del. (2017). The Effectiveness of Transfer Learning. *Iclr2018*, 5(May), 1–4.
- Lamb, K. L., & Brodie, D. A. (1990). The Assessment of Physical Activity by Leisure-Time Physical Activity Questionnaires. *Sports Medicine*, 10(3), 159–180. <https://doi.org/10.2165/00007256-199010030-00003>
- Lima, A. N., Philot, E. A., Trossini, G.

- H. G., Scott, L. P. B., Maltarollo, V. G., & Honorio, K. M. (2016). Use of *machine learning* approaches for novel drug discovery. *Expert Opinion on Drug Discovery*, 11(3), 225–239.  
<https://doi.org/10.1517/17460441.2016.1146250>
- 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.  
<https://doi.org/10.1007/s11042-020-10447-x>
- Mesanza, A. B., Lucas, S., Zubizarreta, A., Cabanes, I., Portillo, E., & Rodriguez-Larrad, A. (2020). A *machine learning* approach to perform physical activity classification using a sensorized crutch tip. *IEEE Access*, 8, 210023-210034.  
<https://doi.org/10.1109/ACCESS.2020.3039885>
- Mirza, R. (2017). Memaksimalkan Dukungan Keluarga Guna Meningkatkan Kualitas Hidup Pasien Diabetes Mellitus. *Jurnal JUMANTIK*, 2(2), 12–30.  
<http://dx.doi.org/10.30829/jumantik.v2i2.1122>
- Okely, A. D., Kariippanon, K. E., Guan, H., Taylor, E. K., Suesse, T., Cross, P. L., & Draper, C. E. (2021). Global effect of COVID-19 pandemic on physical activity, sedentary behaviour and sleep among 3-to 5-year-old children: a longitudinal study of 14 countries. *BMC Public Health*, 21, 1-15.  
<https://doi.org/10.1186/s12889-021-10852-3>
- 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.  
<https://doi.org/10.1016/j.measurement.2020.107480>
- WHO, *Physical Activity*. (2022). WHO. <https://www.who.int/news-room/fact-sheets/detail/physical-activity>
- World Health Organization. (2021). *Standards for healthy eating, physical activity, sedentary behaviour and sleep in early childhood education and care settings: a toolkit*. Geneva: World Health Organization; 2021. Licence: CC BY-NC-SA 3.0 IGO
- Yati, R. (2023). *Survei APJII Pengguna Internet di Indonesia*. Bisnis.Com. <https://teknologi.bisnis.com/read/20230308/101/1635219/survei-apjii-pengguna-internet-di-indonesia-tembus-215-juta-orang>
- Zhang, T., Fulk, G. D., Tang, W., & Sazonov, E. S. (2013). Using decision trees to measure activities in people with stroke. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 6337-6340). IEEE.  
<https://doi.org/10.1109/EMBC.2013.6611003>