

# PREDIKSI PERILAKU AGRESIF ANAK BERBASIS MACHINE LEARNING

Irmawati Ishak Duko<sup>1</sup>, Frangky Tupamahu<sup>2</sup>, Yurni Rahman<sup>3</sup>

<sup>1</sup>Pendidikan Islam Anak Usia Dini, Fakultas Agama Islam, Universitas Muhammadiyah Gorontalo

<sup>2</sup>Informatika, Fakultas Sains dan Ilmu Komputer, Universitas Muhammadiyah Gorontalo

<sup>3</sup>Pendidikan Anak Usia Dini, Fakultas Keguruan dan Ilmu Keolahragaan, Universitas Muhammadiyah Gorontalo

<sup>1</sup>irmaduko@umgo.ac.id, <sup>2</sup>frangkytupamahu@umgo.ac.id, <sup>3</sup>yurnirahman@umgo.ac.id

---

## Abstrak

Perilaku agresif pada anak merupakan masalah serius yang dapat mengganggu perkembangan sosial, emosional, dan akademik. Deteksi dini dan intervensi yang tepat sangat penting untuk mencegah dampak negatif jangka panjang. Penelitian ini bertujuan melakukan prediksi agresif anak berbasis machine learning untuk mendeteksi perilaku agresif pada anak usia sekolah dasar hingga menengah atas. data observasi 200 orang guru di Provinsi Gorontalo, yang dikumpulkan melalui kuesioner online yang mengukur berbagai indikator perilaku agresif seperti fisik, verbal, relasional, dan kerusakan properti, digunakan sebagai dasar pengembangan model. Instrumen penelitian telah divalidasi dengan uji validitas isi oleh praktisi kesehatan mental dan uji reliabilitas menggunakan Cronbach's alpha dengan nilai koefisien 0.7. Tiga metode seleksi fitur, yaitu Korelasi Pearson, Chi-Square, dan Information Gain, diaplikasikan untuk memilih variabel independen yang paling relevan dalam memprediksi perilaku agresif anak. Dari 14 variabel independen yang diukur melalui kuesioner, terdapat 12 fitur terpilih sebagai prediktor. Fitur-fitur ini merepresentasikan indikator perilaku agresif yang diamati oleh para guru pada siswa-siswa mereka, meliputi perubahan emosi, perilaku menyendiri, kesulitan tidur, penurunan prestasi akademik, dan perilaku berisiko. Dua algoritma machine learning, Random Forest dan Support Vector Machine (SVM), diimplementasikan dan dievaluasi kinerjanya menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil menunjukkan bahwa model Random Forest mencapai akurasi 90%, mengungguli SVM (85%). Analisis prediksi yang dikembangkan memiliki potensi untuk diimplementasikan dalam bentuk aplikasi yang dapat digunakan oleh guru dan orang tua untuk melakukan deteksi dini perilaku agresif pada anak, sehingga memungkinkan intervensi yang tepat dan pencegahan dampak negatif jangka panjang.

**Kata kunci:** perilaku agresif, machine learning, deteksi dini, Anak Usia Sekolah, Random Forest.

---

## 1. Pendahuluan

Perilaku agresif pada anak bukanlah sekedar kenakalan biasa. Perilaku ini merupakan masalah yang serius yang dapat menghambat perkembangan anak secara menyeluruh, baik secara sosial, emosional, maupun akademis, seperti yang diungkapkan dalam penelitian (Y. Nurdiantami et al., 2023) dan studi yang dilakukan oleh (Tur-Porcar et al., 2021) bahkan mampu menunjukkan bahwa presentase anak usia sekolah yang menunjukkan perilaku agresif ini cukup tinggi, sehingga menuntut perhatian lebih dari kita semua. Mendeteksi dini dan memberikan intervensi yang tepat menjadi kunci utama untuk mencegah dampak jangka panjang yang merugikan pada anak-anak dengan perilaku seperti ini (Ausrianti et al., 2022). metode konvensional yang selama ini diandalkan, seperti observasi dan penilaian psikologis, seringkali terkendala oleh berbagai keterbatasan (UNESCO, 2019); Franz et al., 2023a) menjadi persoalan tersendiri yang harus dihadapi.

Subjektivitas pengamat, keterbatasan waktu, dan kurangnya tenaga ahli yang terlatih menjadi hambatan yang nyata di lapangan.

Guru, meskipun berada di posisi yang strategis untuk mengamati perilaku anak secara terus-menerus, belum tentu memiliki keahlian yang memadai untuk melakukan interpretasi dan analisis yang akurat. Keterbatasan ini dapat menyebabkan keterlambatan dalam diagnosis dan intervensi, yang justru dapat memperburuk kondisi anak.

Oleh karena itu, dibutuhkan pendekatan yang lebih efisien, objektif, dan terukur, seperti pemanfaatan teknologi *machine learning* (Park et al., 2023). Teknologi ini memungkinkan kita untuk memprediksi perilaku agresif secara lebih akurat dan melakukan intervensi dini yang efektif. Perkembangan teknologi *machine learning* telah membuka cakrawala baru dalam bidang psikologi anak dan pendidikan (K. S. Lee & Ham, 2022).

Beberapa penelitian telah menunjukkan potensinya untuk memprediksi masalah perkembangan pada anak, seperti depresi. Hal ini

telah dilakukan oleh Shumei Lin dkk (2024) berhasil mengembangkan versi singkat dari *Children's Depression Inventory* (CDI) untuk memprediksi risiko depresi pada anak di Cina. CDI singkat dengan lima item dan ambang batas keputusan 4 terbukti efektif dalam memprediksi risiko depresi pada anak-anak. Selanjutnya oleh Guna Sekhar Sajja dkk (2021) meneliti penggunaan algoritma *machine learning* untuk meningkatkan efisiensi sistem deteksi intrusi (IDS) dalam sistem informasi. Hasilnya menunjukkan bahwa algoritma *Support Vector Machine* memiliki akurasi yang lebih baik daripada *Random Forest* dan *Neural Network* dalam mendeteksi intrusi. Kwang-Sig Lee dan Byung-Joo Ham (2022) melakukan tinjauan sistematis terhadap 32 studi tentang penggunaan (K.-S. Lee & Ham, 2022) juga melakukan tinjauan sistematis terhadap 32 studi tentang penggunaan *machine learning* untuk diagnosis dini depresi. Hasilnya menunjukkan bahwa pembelajaran mesin dapat menjadi sistem pendukung keputusan yang efektif dan non-invasif untuk diagnosis dini depresi. Dalam dunia pendidikan, Andriana (2021) melakukan pengkajian literatur tentang model pembelajaran digital berbasis *Deep Learning* untuk memfasilitasi siswa inklusi di sekolah reguler dan membantu guru dalam menyampaikan materi pembelajaran.

Namun, penelitian yang secara khusus memprediksi perilaku agresif siswa berdasarkan data observasi guru masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem cerdas berbasis *machine learning* yang mampu memprediksi perilaku agresif anak dengan akurasi tinggi menggunakan data observasi guru. Sistem ini akan dikemas dalam bentuk aplikasi yang mudah digunakan oleh guru dan orang tua. Dengan sistem ini, diharapkan orang tua dan guru dapat mengidentifikasi dan melakukan intervensi dini secara lebih efektif.

Kebaruan penelitian ini terletak pada integrasi data observasi guru (Kwartie et al., 2024; Novianti et al., 2024; Whipp et al., 2021) ke dalam model *machine learning* untuk memprediksi perilaku agresif anak. Pendekatan ini memungkinkan pemanfaatan pengetahuan dan pengamatan guru yang berharga, yang sebelumnya terabaikan. Selain itu, penggunaan teknik *machine learning* terkini seperti *deep learning* dan *ensemble methods* diharapkan dapat meningkatkan akurasi prediksi secara signifikan. Penelitian ini memiliki potensi yang besar dalam meningkatkan kesejahteraan anak-anak, khususnya di Indonesia. Dengan mengembangkan sistem prediksi berbasis *machine learning*, diharapkan dapat tercipta alat yang efektif bagi pendidik dan profesional kesehatan mental untuk mengidentifikasi anak-anak yang berisiko lebih awal.

Hal ini memungkinkan intervensi yang lebih tepat waktu dan efektif, yang pada gilirannya dapat meningkatkan hasil perkembangan anak dan

mengurangi beban sosial dan ekonomi terkait masalah perilaku.

Di Indonesia, di mana rasio guru-siswa masih tinggi dan akses ke layanan kesehatan mental terbatas, sistem prediksi otomatis seperti ini dapat menjadi solusi yang efektif dan skalabel untuk mengatasi masalah perilaku agresif pada anak.

Oleh karena itu, penelitian ini tidak hanya berkontribusi pada kemajuan teknologi dalam bidang psikologi anak, tetapi juga berpotensi memberikan dampak praktis yang signifikan dalam meningkatkan kesejahteraan anak-anak di Indonesia.

## 2. Metode

Bagian ini akan menjelaskan tahapan-tahapan yang dilakukan dalam penelitian, meliputi desain penelitian, partisipan, instrumen, teknik pengumpulan data, dan teknik analisis data.

### 2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain cross-sectional (Nurafisa et al., 2022). Pendekatan kuantitatif dipilih karena penelitian ini bertujuan untuk mengukur dan menganalisis hubungan antara variabel-variabel yang diduga memengaruhi perilaku agresif anak. Data kuantitatif memungkinkan untuk melakukan analisis statistik dan menghasilkan kesimpulan yang objektif berdasarkan pola numerik.

Desain cross-sectional (Reni Setiawati & Gunado, 2019) digunakan karena data akan dikumpulkan pada satu waktu tertentu. Desain ini memungkinkan untuk memperoleh gambaran umum mengenai prevalensi dan faktor-faktor yang berhubungan dengan perilaku agresif pada satu titik waktu. Data dikumpulkan melalui kuesioner yang diisi oleh guru-guru di Provinsi Gorontalo.

### 2.2 Partisipan Penelitian

Partisipan dalam penelitian ini adalah 200 guru yang mengajar di tingkat sekolah dasar hingga sekolah menengah atas di Provinsi Gorontalo. Jumlah sampel ini ditentukan berdasarkan pertimbangan keterwakilan populasi guru di Provinsi Gorontalo dan kecukupan data untuk analisis statistik. Teknik pengambilan sampel yang digunakan adalah *purposive sampling*, yaitu pemilihan sampel berdasarkan kriteria tertentu. Kriteria inklusi partisipan adalah sebagai berikut:

- 1) Mengajar di sekolah dasar hingga sekolah menengah atas di Provinsi Gorontalo. Kriteria ini dimaksudkan untuk memastikan bahwa partisipan memiliki pengalaman dalam mengamati dan berinteraksi dengan anak-anak usia sekolah yang merupakan fokus penelitian.
- 2) Memiliki pengalaman mengajar minimal 5 tahun. Pengalaman mengajar dipertimbangkan agar guru memiliki cukup waktu untuk melakukan observasi dan mengenali berbagai pola perilaku siswa, termasuk perilaku agresif. Guru yang lebih

berpengalaman diharapkan memiliki kepekaan yang lebih baik dalam mengidentifikasi indikator perilaku agresif pada anak.

- 3) Bersedia mengisi kuesioner secara online. Kuesioner online dipilih untuk memudahkan pengumpulan data dari guru-guru yang tersebar di berbagai lokasi di Provinsi Gorontalo. Penggunaan kuesioner online juga meningkatkan efisiensi waktu dan biaya dalam pengumpulan data.

### 2.3 Instrument Penelitian

Instrumen yang digunakan dalam penelitian ini adalah kuesioner *online* yang telah divalidasi. Kuesioner ini dikembangkan berdasarkan kajian literatur yang komprehensif mengenai perilaku agresif pada anak dan diskusi dengan ahli di bidang psikologi anak dan pendidikan. Kuesioner ini mengukur berbagai indikator perilaku agresif pada anak, yang dapat dikelompokkan menjadi beberapa kategori seperti yang ditunjukkan pada Tabel 1 berikut ini.

Tabel 1. Kategori Indikator Perilaku Agresi

Kategori	Contoh
<b>Agresi Fisik</b>	<ul style="list-style-type: none"> <li>- Memukul, menendang, menggigit, mencakar, menjambak, mendorong, atau melukai teman sebaya.</li> <li>- Melempar benda dengan tujuan untuk melukai orang lain.</li> <li>- Merusak atau menghancurkan barang milik orang lain.</li> </ul>
<b>Agresi Verbal</b>	<ul style="list-style-type: none"> <li>- Memaki, menghina, mengejek, mengancam, atau mengintimidasi teman sebaya.</li> <li>- Menyebarkan gosip atau fitnah tentang orang lain.</li> <li>- Menggunakan kata-kata kasar atau tidak pantas.</li> </ul>
<b>Agresi Relasional</b>	<ul style="list-style-type: none"> <li>- Menyebarkan gosip atau rumor untuk merusak reputasi seseorang.</li> <li>- Mengabaikan, mengucilkan, atau mengecualikan teman sebaya dari kelompok.</li> <li>- Memanipulasi atau memaksa teman sebaya untuk melakukan sesuatu yang tidak mereka inginkan.</li> </ul>
<b>Perilaku Beresiko</b>	<ul style="list-style-type: none"> <li>- Merusak atau menghancurkan barang milik sekolah, seperti meja, kursi, atau jendela.</li> <li>- Merusak atau menghancurkan barang milik teman sebaya, seperti buku, mainan, atau pakaian.</li> <li>- Mencederet-coret dinding atau fasilitas sekolah.</li> </ul>

Setiap pertanyaan dalam kuesioner menggunakan skala Likert dengan pilihan jawaban mulai dari 1 hingga 5, dengan 1 menunjukkan "Sangat Jarang" dan 5 menunjukkan "Sangat Sering". Skala Likert memungkinkan guru untuk memberikan penilaian kuantitatif terhadap frekuensi kemunculan perilaku agresif pada siswa. Skor dari setiap pertanyaan akan digabungkan untuk menghasilkan skor total yang menunjukkan tingkat perilaku agresif pada anak.

### 2.4 Teknik Pengumpulan Data

Sebelum digunakan dalam penelitian, kuesioner telah melalui proses validasi sebagai berikut:

1. Uji validitas isi, dilakukan untuk memastikan bahwa pertanyaan-pertanyaan dalam kuesioner relevan dan representatif dalam mengukur indikator perilaku agresif pada anak. Validasi isi dilakukan melalui diskusi mendalam dengan dua orang praktisi kesehatan mental anak yang berpengalaman minimal 10 tahun di bidangnya. Para ahli diminta untuk menilai relevansi, kejelasan, dan kelengkapan item-item dalam kuesioner.
2. Uji reliabilitas, dilakukan untuk menguji konsistensi internal instrumen. Uji reliabilitas menggunakan *Cronbach's alpha* dengan kriteria > 0.70 untuk menunjukkan reliabilitas yang dapat diterima. Perhitungan *Cronbach's alpha* dilakukan pada data *pilot study* yang melibatkan 30 guru dengan karakteristik yang serupa dengan partisipan penelitian.

Kuesioner yang telah melalui uji validitas dan reliabilitas didigitalisasi menggunakan Google Form dan disebarakan kepada guru-guru di Provinsi Gorontalo yang telah mengajar selama lebih dari 5 tahun dan memiliki pengetahuan serta pengalaman spesifik dalam bimbingan konseling di satuan pendidikan dasar, menengah pertama, dan menengah atas. Data demografi guru-guru tersebut diperoleh melalui koordinasi dengan Dinas Pendidikan dan Kebudayaan (DIKBUD) Provinsi Gorontalo, dan proses pengumpulan data telah mendapatkan izin tertulis dari Kesatuan Bangsa dan Politik (KESBANGPOL) Provinsi Gorontalo.

### 2.5 Teknik Analisis Data

Data yang digunakan dalam penelitian ini adalah data primer yang dikumpulkan secara khusus untuk keperluan penelitian ini. Data tersebut berupa observasi guru terhadap perilaku siswa yang diduga menunjukkan perilaku agresif. Adapun contoh data yang dikumpulkan ditunjukkan pada Tabel 2 berikut.

Tabel 2 data-data yang dikumpulkan

Variabel	Nilai
Lama Mengajar (tahun)	8
Anak menjadi lebih pendiam, menarik diri, dan tidak mau berinteraksi dengan orang lain	4
Anak mengalami kesulitan tidur, mimpi buruk, atau gangguan makan	4
Anak menunjukkan penurunan prestasi akademik	4
Anak menunjukkan perilaku berisiko, seperti mencuri, berbohong, atau menggunakan narkoba	1
Anak menunjukkan perilaku menyendiri, seperti menghabiskan waktu di kamar sendirian	4
Anak menunjukkan perubahan berat badan yang signifikan (naik atau turun)	4
Anak menunjukkan masalah makan, seperti nafsu makan yang menurun atau meningkat	4
Anak menunjukkan rasa takut yang berlebihan atau cemas	4
Anak menunjukkan rasa sedih, depresi, atau putus asa	4

Anak menunjukkan kesulitan dalam mengungkapkan emosi	4
Anak menunjukkan perilaku menyakiti diri sendiri	4
Anak menunjukkan kesulitan dalam mengikuti aturan dan norma sosial	2
Anak menunjukkan perilaku agresif atau bullying terhadap teman sebaya	2

Selanjutnya, data dikumpulkan dengan menggunakan kuesioner *online* yang disebarakan kepada guru-guru di Provinsi Gorontalo. Penggunaan kuesioner *online* ini untuk memudahkan proses pengumpulan data karena dapat diakses oleh guru di mana saja dan kapan saja. Selain itu, kuesioner *online* juga memungkinkan pengolahan data secara lebih efisien.

Dataset yang digunakan dalam penelitian ini terdiri dari 200 entri data dengan 15 fitur. Setiap entri mencakup sejumlah atribut yang menggambarkan karakteristik perilaku anak, berdasarkan hasil observasi guru. Dataset ini lengkap, tanpa nilai kosong, dan setiap fitur diukur menggunakan skala Likert dengan rentang 1 (Sangat Jarang) hingga 5 (Sangat Sering), menghasilkan data ordinal. Skala Likert memungkinkan guru untuk memberikan penilaian kuantitatif terhadap frekuensi kemunculan perilaku agresif pada siswa. (Franz et al., 2023b).

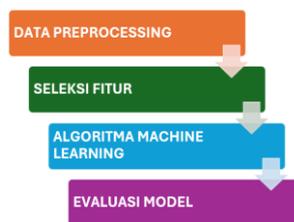
Sebanyak 15 fitur dalam dataset diseleksi untuk mendapatkan subset fitur yang memiliki keterikatan kuat dengan target perilaku agresif dan *bullying*. Proses seleksi fitur menggunakan metode *Korelasi Pearson*, *Chi-Square*, dan *Information Gain*. Subset fitur terpilih kemudian digunakan untuk mengevaluasi model *machine learning*. Selanjutnya, dataset dengan fitur terpilih dibagi menjadi dua bagian yaitu data latih (80%) dan data uji (20%). Pendekatan ini umum digunakan dalam penelitian *machine learning* (Andriansyah & Eka Wulansari Fridayanthie, 2023; Fajri et al., 2022) untuk memastikan bahwa model yang dilatih tidak hanya akurat pada data latih, tetapi juga mampu menggeneralisasi dengan baik pada data baru yang belum pernah dilihat sebelumnya. Proporsi 80-20 (Kadek & Rahim, 2024) dipilih untuk memberikan keseimbangan antara jumlah data yang cukup untuk pelatihan model dan jumlah data yang memadai untuk evaluasi performa model secara independen. Penggunaan data uji yang terpisah memungkinkan identifikasi potensi *overfitting*, yaitu kondisi di mana model terlalu terfokus pada data latih dan gagal untuk menggeneralisasi pada data baru.

Selanjutnya, analisis data dalam penelitian ini dilakukan menggunakan pendekatan *machine learning* untuk membangun model prediktif yang dapat mengidentifikasi perilaku agresif pada anak. Adapun tahapan proses analisis data yang digunakan pada penelitian ini ditunjukkan pada Gambar 1.

1) Data Preprocessing

Pada tahapan ini, bertujuan untuk mempersiapkan data mentah dan memastikan atribut-atribut relevan sebelum dilakukan analisis dan pemodelan. Data

preprocessing mengikuti prosedur standar *data processing* dengan menangani *missing values* meskipun dalam dataset yang digunakan tidak ditemukan. Jika ditemukan dalam dataset terdapat *missing values*, maka metode imputasi median akan digunakan untuk mengisi nilai yang hilang (Rizvi et al., 2023). Selanjutnya melakukan transformasi data numerik (lama mengajar guru) akan distandarisasi menggunakan *StandardScaler* dari *Scikit-learn*. Standarisasi dilakukan dengan mengubah data sehingga memiliki rata-rata (*mean*) 0 dan standar deviasi 1. Tujuannya adalah untuk menyeragamkan skala data sebelum dimasukkan ke dalam model *machine learning* (de Amorim et al., 2022). Data kategorikal (jenis kelamin, tingkat pendidikan, jenjang sekolah) akan diubah menjadi bentuk numerik menggunakan *one-hot encoding*. Hal ini memungkinkan variabel kategorikal untuk diproses oleh algoritma *machine learning*.



Gambar 1. Proporsi Kategori Indikator Perilaku Agresif.

Dataset yang digunakan dalam penelitian ini terdiri dari 200 sampel, diperoleh melalui observasi guru terhadap perilaku anak. Variabel target, "Anak menunjukkan perilaku agresif atau bullying terhadap teman sebaya", menunjukkan distribusi kelas yang tidak seimbang, seperti ditunjukkan pada Tabel 3. Kelas 1 mendominasi dataset (148 sampel), mencerminkan anak-anak dengan tingkat agresi ringan. Kelas 2, 3, 4, dan 5 memiliki jumlah sampel yang lebih sedikit, dengan kelas 3 sebagai yang paling jarang (6 sampel). Ketidakseimbangan ini dapat memengaruhi kinerja algoritma prediksi, terutama yang sensitif terhadap kelas mayoritas.

Tabel 3 Distribusi Kelas Target

Kelas	Jumlah sampel	Kategori
1	148	Mayoritas
2	22	Minoritas
4	14	Minoritas
5	10	Minoritas
3	6	Minoritas

2) Seleksi Fitur

Seleksi fitur merupakan tahapan penting dalam pengembangan model *machine learning*. Tujuannya adalah untuk memilih fitur-fitur yang paling relevan dan informatif dalam memprediksi variabel target, dalam hal ini perilaku agresif anak yang dapat memengaruhi perilaku agresif dan bullying. Dengan mengurangi jumlah fitur yang digunakan, diharapkan dapat meningkatkan akurasi model, mengurangi kompleksitas model, mempercepat waktu pelatihan, dan meningkatkan interpretabilitas model.

Dalam penelitian ini, digunakan tiga metode *filter method* untuk melakukan seleksi fitur, yaitu *Korelasi Pearson* untuk mengukur hubungan linier antara variabel numerik. Kemudian *Chi-Square* untuk mengukur hubungan antara variabel kategoris terhadap target berdasarkan skor *chi-square*, dan terakhir adalah *Information Gain* untuk mengetahui tingkatan pengaruh fitur yang menjadi atribut terhadap target. Ketiga metode ini dipilih karena relatif sederhana, mudah diimplementasikan, dan efektif dalam mengurangi jumlah fitur tanpa mengurangi akurasi model secara signifikan (Bellotti et al., 2014).

**1. Korelasi Pearson**

Korelasi Pearson mengukur hubungan linear antara dua variabel. Dalam konteks seleksi fitur, Korelasi Pearson seperti ditunjukkan pada persamaan 1, digunakan untuk mengukur kekuatan dan arah hubungan antara setiap fitur dengan variabel target. Nilai koefisien korelasi Pearson berkisar antara -1 hingga +1.

$$r = \frac{n(\sum xy) - (\sum x)\sum y}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \tag{1}$$

Untuk:

- (n) = jumlah pasangan data.
- (x) dan (y) adalah nilai dari dua variabel.

Fitur-fitur dengan nilai korelasi absolut yang tinggi (mendekati +1 atau -1) dianggap lebih relevan karena memiliki hubungan yang kuat dengan variabel target. Dalam penelitian ini, fitur-fitur dengan nilai korelasi Pearson absolut tertinggi dipilih sebagai fitur yang relevan.

**2. Chi-Square**

Chi-Square ( $\chi^2$ ) digunakan untuk menguji independensi antara dua variabel kategorikal. Dalam konteks seleksi fitur, Chi-Square dengan perhitungan seperti ditunjukkan pada persamaan 2, digunakan untuk mengukur hubungan (asosiasi) antara setiap fitur kategorikal dengan variabel target. Nilai Chi-Square yang tinggi menunjukkan adanya hubungan yang signifikan antara fitur tersebut dengan variabel target.

$$\chi^2 = \sum \frac{(O_i - E_i)^2}{E_i} \tag{2}$$

Untuk:

- ( $O_1$ ) = adalah nilai yang diamati.
- ( $E_1$ ) = adalah nilai yang diharapkan.

Chi-Square menghitung perbedaan antara frekuensi observasi/diamati dan frekuensi harapan jika kedua variabel independen. Semakin besar perbedaannya, semakin tinggi nilai *Chi-Square* dan semakin kuat hubungan antara kedua variabel. Fitur-fitur dengan nilai *Chi-Square* tertinggi dipilih sebagai fitur yang relevan.

**3. Information Gain**

Information Gain mengukur seberapa banyak informasi yang diperoleh dari suatu fitur untuk memprediksi variabel target. Information Gain dihitung

berdasarkan *entropy*, yaitu ukuran ketidakpastian dalam suatu variabel. Semakin tinggi Information Gain suatu fitur, semakin besar pengurangan ketidakpastian dalam variabel target ketika fitur tersebut diketahui.

Information Gain dengan formula ditunjukkan pada persamaan 3, sering digunakan dalam *decision tree* untuk memilih fitur yang paling informatif pada setiap pembagian node. Dalam penelitian ini, fitur-fitur dengan nilai Information Gain tertinggi dipilih sebagai fitur yang relevan.

$$IG(A) = H(S) - \sum \left( \frac{|S_v|}{|S|} \right) H(S_v) \tag{3}$$

Di mana:

- (H(S)) adalah entropi dari dataset asli (S)
- ( $S_v$ ) adalah subset dari (S) setelah pemisahan berdasarkan atribut (A)
- ( $|S_v|$ ) adalah jumlah elemen dalam subset ( $S_v$ )
- ( $|S|$ ) adalah jumlah elemen dalam dataset asli (S)

**3) Pemodelan dengan Algoritma Machine Learning**

Dalam penelitian ini fitur yang telah diseleksi menggunakan tiga metode seleksi fitur pada Tabel 2, dimodelkan menggunakan dua algoritma machine learning yang berbeda, yaitu *Random Forest* dengan hyperparameter tuning di tunjukan pada Tabel 4 dan *Support Vector Machine (SVM)* hyperparameter tuning di tunjukan pada Tabel 5. Penggunaan *Support Vector Machine (SVM)* dan *Random Forest* dalam penelitian ini didasarkan pada pertimbangan kemampuan kedua algoritma (Budiman et al., 2021) tersebut dalam menangani data kompleks, menghasilkan prediksi yang akurat, dan memberikan informasi yang bermanfaat untuk memahami faktor-faktor yang berkontribusi terhadap perilaku agresif pada anak. kemudian untuk *Random Forest* merupakan contoh dari pendekatan *ensemble learning*, yaitu menggabungkan beberapa model untuk meningkatkan performa prediksi (Harahap & Muslim, 2020).

Dengan membandingkan *Random Forest* dengan SVM (yang bukan merupakan algoritma *ensemble*), kita dapat mengetahui apakah pendekatan *ensemble learning* memberikan keuntungan dalam kasus ini.

Table 4 Fitur Seleksi

No	Fitur	Deskripsi
1	Kesulitan dalam mengikuti aturan dan norma sosial	Fitur ini memiliki hubungan yang signifikan dengan variabel target dalam semua metode seleksi fitur
2	Perilaku menyakiti diri sendiri	Atribut ini mencerminkan tingkat risiko anak terhadap perilaku destruktif
3	Perilaku berisiko, seperti mencuri atau berbohong	Menggambarkan perilaku berbahaya yang relevan dengan potensi agresi
4	Rasa sedih, depresi, atau putus asa	Fitur ini menunjukkan kondisi emosional anak yang dapat memengaruhi perilaku agresif.
5	Kesulitan tidur, mimpi buruk, atau gangguan makan.	Indikator stres atau ketidakstabilan yang signifikan dalam perilaku anak.

Dengan membandingkan performa kedua algoritma, diharapkan dapat diperoleh model yang optimal untuk

memprediksi perilaku agresif anak dan membantu dalam upaya deteksi dini.

Tabel 5 *Hyperparameter* Random Forest

Hyperparameter	Keterangan
<i>n_estimators</i>	Jumlah <i>decision tree</i> dalam <i>forest</i>
<i>max_depth</i>	Kedalaman maksimum setiap <i>decision tree</i> .
<i>max_features</i>	Jumlah fitur yang dipertimbangkan di setiap <i>node</i> .
<i>min_samples_split</i>	Jumlah minimum sampel yang diperlukan untuk membagi <i>node</i> .
<i>min_samples_leaf</i>	Jumlah minimum sampel di setiap <i>leaf node</i>

Tabel 6 *Hyperparameter* Support Vector Machine

Hyperparameter	Keterangan
<i>C</i>	Mengontrol trade-off antara <i>margin</i> (jarak antara hyperplane dan titik data terdekat) dan kesalahan klasifikasi.
<i>Kernel</i> (fungsi kernel)	'linear' ; 'rbf' ; 'poly' ; 'sigmoid'
<i>gamma</i> (Koefisien Kernel)	Menentukan seberapa jauh pengaruh satu titik data terhadap yang lain.

#### 4) Evaluasi Model

Dengan menggunakan fitur hasil seleksi menggunakan Korelasi Pearson, Chi-Square, dan Information Gain yang telah disajikan pada Tabel 2 untuk evaluasi model *SVM* dan *Random Forest* menggunakan matrik pengukuran. Dalam penelitian ini, beberapa metrik pengukuran digunakan, seperti ditunjukkan pada persamaan 4, 5, 6 dan 7. Metrik pengukuran yang digunakan pertama adalah akurasi untuk mengukur proporsi prediksi yang benar terhadap total data yang diuji. Metrik ke dua mengukur seberapa banyak prediksi positif yang benar dibandingkan total prediksi positif secara presisi. Metrik ke tiga *recall* atau sensitivitas untuk mengukur seberapa banyak kasus positif yang benar-benar terdeteksi dari semua kasus positif sebenarnya.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \tag{4}$$

$$Presisi = \frac{TP}{TP+FP} \tag{5}$$

$$Recall = \frac{TP}{TP+FN} \tag{6}$$

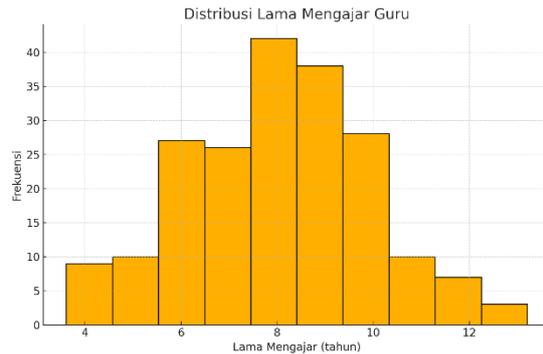
Dimana untuk TP adalah *True Positive* (prediksi positif benar). Untuk TN adalah *True Negative* (prediksi negatif benar). Kemudian untuk FP adalah *False Positive* (prediksi positif salah) dan terakhir adalah FN adalah *False Negative* (prediksi negatif salah). Pengukuran terakhir adalah melakukan pengukuran rata-rata harmonis antara Presisi dan Recall. Digunakan ketika terdapat ketidakseimbangan kelas dalam dataset menggunakan *F1-Score*.

$$F1 - score = 2x \frac{Presisi \times Recall}{Presisi+Recall} \tag{7}$$

### 3. Hasil dan Pembahasan

#### 3.1 Hasil Pengumpulan Data

Sebanyak 200 guru dari berbagai jenjang pendidikan (SD/MI, SMP/MTs, SMA/MA/SMK) di Provinsi Gorontalo berpartisipasi dalam penelitian ini. Data demografi guru menunjukkan bahwa mayoritas partisipan adalah perempuan (70%), memiliki tingkat pendidikan sarjana (85%), dan memiliki pengalaman mengajar antara 6 hingga 10 tahun.



Gambar 2. Histogram Lama Mengajar Guru

#### 3.2 Hasil Seleksi Fitur

Dalam penelitian ini, hasil seleksi fitur menggunakan tiga metode seleksi yaitu *filter method* (*Korelasi Pearson*, *Chi-Square*, dan *Information Gain*) diuraikan secara lengkap sebagai berikut.

##### 1. Korelasi Pearson

Metode *Korelasi Pearson* mengukur hubungan linear antara variabel numerik dengan target. Nilai korelasi berkisar antara -1 hingga 1, di mana nilai positif menunjukkan hubungan langsung, sedangkan nilai negatif menunjukkan hubungan terbalik. Dari analisis ini ditemukan bahwa:

- Fitur "*Anak menunjukkan kesulitan dalam mengikuti aturan dan norma sosial*" memiliki korelasi tertinggi (0.689) dengan variabel target.
- Fitur "*Anak menunjukkan perilaku menyakiti diri sendiri*" (0.660) dan "*Anak menunjukkan perilaku berisiko, seperti mencuri, berbohong, atau menggunakan narkoba*" (0.610) juga menunjukkan hubungan yang kuat dengan target.
- Fitur "*Anak menunjukkan rasa sedih, depresi, atau putus asa*" (0.504) dan "*Anak menunjukkan perubahan berat badan yang signifikan*" (0.405), memiliki korelasi moderat.

##### 2. Chi-Square

*Chi-Square* digunakan untuk mengukur hubungan antar variabel kategoris dengan target. Hasil dari Chi-Square menunjukkan fitur-fitur berikut memiliki nilai signifikan terhadap target:

- "*Anak menunjukkan perilaku menyakiti diri sendiri*" memiliki skor Chi-Square tertinggi

(68.58), menunjukkan pengaruh signifikan terhadap target.

- "Anak menunjukkan perilaku berisiko" (52.81) dan "Anak menunjukkan kesulitan dalam mengikuti aturan dan norma sosial" (52.04) juga termasuk fitur yang sangat relevan.
- Fitur dengan skor menengah, seperti "Anak menunjukkan rasa sedih, depresi, atau putus asa" (39.46) dan "Anak mengalami kesulitan tidur" (19.92), tetap memberikan kontribusi pada prediksi.

3. Information Gain

Metode *Information Gain* mengukur pengurangan ketidakpastian (*entropy*) dari variabel target ketika menggunakan fitur tertentu. Hasilnya menunjukkan fitur-fitur yang paling informatif adalah:

- "Anak menunjukkan kesulitan dalam mengikuti aturan dan norma sosial" memiliki Information Gain tertinggi (0.452).
- Fitur-fitur lain yang signifikan termasuk "Anak menunjukkan rasa sedih, depresi, atau putus asa" (0.232) dan "Anak menunjukkan perilaku menyakiti diri sendiri" (0.173).
- Fitur seperti "Anak menunjukkan masalah makan" (0.171) dan "Anak menunjukkan perilaku berisiko" (0.161) juga memberikan kontribusi penting.

Dari hasil seleksi fitur menggunakan tiga metode seleksi fitur menunjukkan hasil yang konsisten dengan data nilai ditunjukkan pada Tabel 7.

Tabel 7. Data Hasil Seleksi Fitur

Fitur	Korelasi Pearson	Chi-Square	Information Gain
Anak menunjukkan kesulitan dalam mengikuti aturan dan norma sosial	0.689	68.58	0.452
Anak menunjukkan perilaku menyakiti diri sendiri	0.660	52.81	0.173
Anak menunjukkan perilaku berisiko	0.610	52.04	0.161
Anak menunjukkan rasa sedih, depresi, atau putus asa.	0.504	39.46	0.232
Anak mengalami kesulitan tidur, mimpi buruk, atau gangguan makan	0.371	19.92	0.112

Fitur-fitur yang terpilih melalui tiga metode statistik, yaitu Korelasi Pearson, Chi-Square, dan Information Gain, merepresentasikan aspek psikologis dan perilaku anak yang paling relevan dalam memprediksi perilaku agresif. Fitur-fitur ini, yang meliputi yang ditunjukkan pada Tabel 3, kemudian digunakan sebagai variabel independen (prediktor) dalam model prediksi *machine learning* menggunakan algoritma *SVM* dan *Random Forest*. Variabel dependen (target) dalam model ini adalah

"Anak menunjukkan perilaku agresif atau bullying terhadap teman sebaya".

3.3 Hasil Pemodelan dan Evaluasi

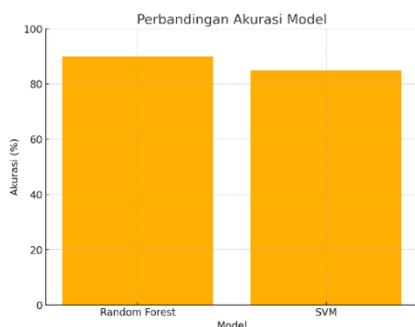
Setelah seleksi fitur telah dilakukan, dua algoritma *machine learning* yaitu *Random Forest* dan *Support Vector Machine* (*SVM*) digunakan untuk membangun model prediksi perilaku agresif anak. *Hyperparameter tuning* dilakukan untuk mengoptimalkan parameter model ditunjukkan pada Tabel 8 berikut.

Tabel 8 Hyperparameter Tuning Optimalisasi Model SVM dan Random Forest

Model	Hyperparameter	Deskripsi	Nilai	Penjelasan
Support Vector Machine	C	Parameter penalti	1.0	Mengontrol trade-off antara kesalahan klasifikasi dan margin. Fungsi kernel yang digunakan untuk
	kernel	Fungsi kernel	<i>rbf</i>	memetakan data ke ruang dimensi yang lebih tinggi. Menentukan seberapa jauh pengaruh satu titik data terhadap yang lain. 'scale' secara otomatis menghitung gamma berdasarkan data.
	gamma	Koefisien kernel untuk 'rbf', 'poly', dan 'sigmoid'	<i>scale</i>	Nilai default yang umum digunakan. Membatasi kedalaman pohon dapat mencegah overfitting. Akar kuadrat dari jumlah fitur ( $\sqrt{5} \approx 2.24$ ) dibulatkan ke bawah.
Random Forest	n_estimators	Jumlah pohon keputusan	100	Nilai default yang umum digunakan. Dapat ditingkatkan untuk mengurangi overfitting.
	max_depth	Kedalaman maksimum setiap pohon	5	Nilai default yang umum digunakan. Dapat ditingkatkan untuk mengurangi overfitting.
	max_features	Jumlah fitur yang dipertimbangkan di setiap node	2	Nilai default yang umum digunakan. Dapat ditingkatkan untuk mengurangi overfitting.
	min_samplesplit	Jumlah minimum sampel untuk membagi node	2	Nilai default yang umum digunakan. Dapat ditingkatkan untuk mengurangi overfitting.
	min_samplesleaf	Jumlah minimum sampel di setiap leaf node	1	Nilai default yang umum digunakan. Dapat ditingkatkan untuk mengurangi overfitting.

Hasil evaluasi Evaluasi model menunjukkan bahwa Random Forest memiliki kinerja yang lebih unggul dibandingkan SVM dalam memprediksi perilaku agresif pada anak. Hal ini dapat dikaitkan

dengan beberapa faktor, antara lain: (1) fleksibilitas Random Forest dalam menangkap hubungan non-linear antar fitur, yang terbukti dari tingginya Information Gain pada fitur "Kesulitan dalam mengikuti aturan" (0.452) dan "Rasa sedih/depresi" (0.232); (2) kemampuan Random Forest dalam menangani ketidakseimbangan kelas melalui *bootstrap sampling* dan *voting* mayoritas, sehingga meningkatkan *recall* pada kelas minoritas; (3) *robustness* Random Forest terhadap *noise* dan outlier karena penggunaan banyak pohon independen; dan (4) generalisasi yang lebih baik pada data baru melalui mekanisme *randomisasi fitur* dan *voting ensemble*. SVM, di sisi lain, memiliki keterbatasan dalam menangani data non-linear dan ketidakseimbangan kelas, serta lebih sensitif terhadap outlier. Tanpa *hyperparameter tuning* yang tepat, SVM rentan terhadap *underfitting* atau *overfitting*, terutama pada dataset kecil.



Gambar 3. Perbandingan Akurasi Model

Diagram batang pada Gambar 3, menunjukkan perbandingan akurasi model antara Random Forest dan SVM. Berdasarkan hasil evaluasi, akurasi Random Forest adalah 90%, sedangkan akurasi SVM adalah 85%.

Tabel 9. Hasil Metrik Evaluasi Model

Model	Akurasi	Presi	Recall	F1-Score
Random Forest	90%	88%	90%	89%
SVM	85%	82%	85%	83%

Nampak jelas bahwa hasil evaluasi model pada Tabel 9, meskipun SVM mampu memberikan hasil akurasi yang baik, terdapat kelemahan dalam minoritas, ini ditunjukkan dari hasil presisi dan *recall* yang lebih rendah dibandingkan algoritma *Random Forest* yang unggul disemua metrik evaluasi model.

### 3.4 Pembahasan

Model *machine learning* yang dikembangkan dalam penelitian ini menunjukkan potensi yang baik dalam memprediksi perilaku agresif anak berdasarkan data observasi guru. Model *Random Forest* terbukti lebih superior dibandingkan SVM dalam mengklasifikasikan perilaku agresif pada anak. Hal ini mengindikasikan bahwa *Random Forest*, dengan kemampuannya untuk menggabungkan keputusan dari banyak pohon keputusan, lebih

mampu menangkap pola kompleks dalam data observasi guru dan menghasilkan prediksi yang lebih akurat.

Fitur-fitur yang terpilih oleh metode seleksi fitur juga memberikan informasi penting mengenai faktor-faktor yang berhubungan dengan perilaku agresif anak. 5 fitur yang terpilih menunjukkan bahwa perilaku agresif pada anak seringkali berkaitan dengan perubahan emosi dan perilaku lainnya, seperti menarik diri, kesulitan tidur, penurunan prestasi akademik, dan perilaku berisiko. Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa perilaku agresif merupakan salah satu manifestasi dari kesulitan emosional dan sosial pada anak. Penelitian ini memiliki kebaruan dalam hal penggunaan data observasi guru yang dikumpulkan melalui kuesioner yang telah divalidasi dan penggunaan metode seleksi fitur untuk meningkatkan akurasi model.

Selain itu, model Random Forest yang menghasilkan akurasi 90% mengindikasikan bahwa observasi guru, ketika diproses dengan algoritma *machine learning* yang tepat, dapat menjadi prediktor yang kuat untuk perilaku agresif pada anak.

Hal ini mendukung gagasan bahwa guru memiliki peran penting dalam identifikasi dini masalah perilaku siswa, karena mereka berinteraksi langsung dengan siswa dan memiliki kesempatan untuk mengamati perubahan perilaku siswa secara konsisten. Hasil penelitian ini juga menunjukkan potensi penerapan teknologi *machine learning* dalam bidang pendidikan di Indonesia. Dengan mengembangkan sistem prediksi yang mudah diakses dan diimplementasikan, diharapkan dapat membantu guru-guru di Indonesia, terutama di daerah-daerah dengan akses terbatas ke tenaga ahli kesehatan mental, untuk melakukan deteksi dini perilaku agresif pada anak

Model prediksi perilaku agresif anak ini diharapkan dapat membantu guru dan orang tua dalam mengidentifikasi anak-anak yang berisiko mengalami perilaku agresif. Dengan adanya prediksi agresif anak berbasis *machine learning* ini, dapat dikembangkan suatu sistem untuk membantu guru dalam melakukan skrining awal untuk mengidentifikasi siswa-siswa yang memerlukan perhatian dan intervensi lebih lanjut.

Identifikasi dini memungkinkan untuk dilakukannya intervensi yang tepat, seperti konseling, terapi perilaku, atau program pendukung lainnya, guna mencegah dampak negatif jangka panjang dari perilaku agresif.

## 4. Kesimpulan dan Saran

### 4.1 Kesimpulan

Penelitian ini menunjukkan bahwa indikator perilaku agresif pada anak yang paling penting adalah kesulitan dalam mematuhi aturan dan norma sosial,

perilaku melukai diri sendiri, dan tindakan berisiko. Hasil evaluasi menunjukkan bahwa model Random Forest secara konsisten mengungguli SVM dalam memprediksi perilaku agresif, dengan akurasi mencapai 90%, presisi 88%, recall 90%, dan F1-score 89%, dibandingkan dengan akurasi 85%, presisi 82%, recall 85%, dan F1-score 83% untuk SVM. Oleh karena itu, penggunaan model Random Forest direkomendasikan untuk prediksi perilaku agresif pada anak. Penelitian ini menyoroti potensi pemanfaatan teknologi machine learning dalam bidang pendidikan, khususnya untuk membantu guru dalam mengidentifikasi dini siswa yang berisiko menunjukkan perilaku agresif.

#### 4.2 Saran

Beberapa saran yang dapat diajukan berdasarkan hasil penelitian ini yaitu Pengembangan Sistem: Model *machine learning* yang telah dikembangkan dapat diintegrasikan ke dalam sistem aplikasi yang mudah digunakan oleh guru dan orang tua, misalnya dalam bentuk aplikasi *mobile* atau *website*.

Akurasi model dan generalisasi model dapat ditingkatkan dengan menambahkan data dari sumber lain, seperti data wawancara dengan orang tua, data psikometri siswa, atau data observasi dari guru-guru di wilayah lain. Penting untuk melakukan evaluasi dan monitoring secara berkala terhadap sistem yang dikembangkan untuk memastikan efektivitas dan keberlanjutannya dalam membantu identifikasi dini perilaku agresif anak. selanjutnya, diperlukan kerjasama lintas disiplin antara pakar teknologi, pakar pendidikan, dan pakar psikologi untuk mengembangkan sistem yang lebih komprehensif dan sesuai dengan kebutuhan di lapangan.

Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi yang signifikan dalam upaya pencegahan dan penanganan perilaku agresif pada anak melalui penerapan teknologi *machine learning*.

#### Daftar Pustaka

- Kadek Aditya Ananta Wisnu Wardana, & Rahim, A. M. A. (2024). Analisis Perbandingan Algoritma Xgboost Dan Algoritma Random Forest Untuk Klasifikasi Data Kesehatan Mental. <https://www.kaggle.com/datasets/bhavikjikadara/Mental-Health-Dataset>
- Andriansyah, D.-, & Eka Wulansari Fridayanthie. (2023). Optimization Of Support Vector Machine and Xgboost Methods Using Feature Selection to Improve Classification Performance. *Journal Of Informatics and Telecommunication Engineering*, 6(2), 484–493. <https://doi.org/10.31289/jite.v6i2.8373>
- Ausrianti, R., Putri Andayani, R., Mercubaktijaya, Stik., & Diii Keperawatan, P. (2022). Hubungan Kekerasan Emosional Dengan Perilaku Agresif Pada Anak Usia Sekolah. <http://jurnal.mercubaktijaya.ac.id/index.php/mercusuar>
- Bellotti, T., Nouretdinov, I., Yang, M., & Gammerman, A. (2014). Feature Selection. Conformal Prediction for Reliable Machine Learning: Theory, Adaptations and Applications, 115–130. <https://doi.org/10.1016/B978-0-12-398537-8.00006-7>
- Budiman, S., Sunyoto, A., & Nasiri, A. (2021). Analisa Performa Penggunaan Feature Selection untuk Mendeteksi Intrusion Detection Systems Dengan Algoritma Random Forest Classifier. <http://sistemasi.ftik.unisi.ac.id>
- De Amorim, L. B. V., Cavalcanti, G. D. C., & Cruz, R. M. O. (2022). The Choice of Scaling Technique Matters for Classification Performance. <https://doi.org/10.1016/j.asoc.2022.109924>
- Fajri, F. N., Tholib, A., & Yuliana, W. (2022). Penerapan Machine Learning Untuk Penentuan Mata Kuliah Pilihan Pada Program Studi Informatika. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(3), 485–496–485 – 496. <https://doi.org/10.28932/jutisi.v8i3.3990>
- Franz, D. J., Richter, T., Lenhard, W., Marx, · Peter, Stein, · Roland, & Ratz, C. (2023a). The Influence of Diagnostic Labels on The Evaluation of Students: A Multilevel Meta-Analysis. 35, 17. <https://doi.org/10.1007/S10648-023-09716-6>
- Franz, D. J., Richter, T., Lenhard, W., Marx, P., Stein, R., & Ratz, C. (2023b). The Influence of Diagnostic Labels On The Evaluation Of Students: A Multilevel Meta-Analysis. *Educational Psychology Review*, 35(1), 1–41. <https://doi.org/10.1007/S10648-023-09716-6/figures/4>
- Harahap, R. N., & Muslim, K. (2020). Peningkatan Akurasi Pada Prediksi Kepribadian MbtI Pengguna Twitter Menggunakan Augmentasi Data. <https://doi.org/10.25126/jtiik.202073622>
- Kwartie, R., Fitriani, Y., & Nuroniah, P. (2024). Peran Guru Dalam Mereduksi Perilaku Agresif Anak Di Sekolah. *Murhum : Jurnal Pendidikan Anak Usia Dini*, 5(1), 791–805. <https://doi.org/10.37985/murhum.v5i1.664>
- Lee, K. S., & Ham, B. J. (2022). Machine Learning on Early Diagnosis of Depression. *Psychiatry Investigation*, 19(8), 597–605. <https://doi.org/10.30773/pi.2022.0075>
- Lee, K.-S., & Ham, B. (2022). Machine Learning on Early Diagnosis of Depression. *Psychiatry Investigation*, 19, 597–605. <https://doi.org/10.30773/pi.2022.0075>
- Novianti, S., Ahmad Tohar, A., Khairi, Z., Studi Magister Psikologi, P., Islam Negeri Sultan Syarif Kasim Riau, U., Pekanbaru, K., & Riau,

- P. (2024). Peran Pendidik Dalam Mencegah Dan Mengatasi Bullying Pada Anak Usia Dini. 2(2).
- Nurafisa, M. D., Lestari, R. F., & Utami, A. (2022). Hubungan Persepsi Pola Asuh Orang Tua Terhadap Perilaku Agresif Pada Remaja. *Jurnal Keperawatan Hang Tuah (Hang Tuah Nursing Journal)*, 2(1), 39–48. <https://doi.org/10.25311/Jkh.Vol2.Iss1.537>
- Park, C., Rouzi, M. D., Atique, M. M. U., Finco, M. G., Mishra, R. K., Barba-Villalobos, G., Crossman, E., Amushie, C., Nguyen, J., Calarge, C., & Najafi, B. (2023). Machine Learning-Based Aggression Detection in Children with Adhd Using Sensor-Based Physical Activity Monitoring. *Sensors*, 23(10). <https://doi.org/10.3390/S23104949>
- Reni Setiawati, O., & Gunado, A. (2019). Perilaku Agresif Pada Siswa Smp Yang Bermain Game Online. In *Maret* (Vol. 1, Issue 1).
- Rizvi, S. T. H., Latif, M. Y., Amin, M. S., Telmoudi, A. J., & Shah, N. A. (2023). Analysis of Machine Learning Based Imputation of Missing Data. *Cybernetics And Systems*. <https://doi.org/10.1080/01969722.2023.2247257>
- Tur-Porcar, A. M., Llorca-Mestre, A., & Mestre-Escrivá, V. (2021). Aggressiveness, Instability and Social-Emotional Education in An Inclusive Environment. *Comunicar*, 29(66), 46–55. <https://doi.org/10.3916/C66-2021-04>
- Unesco. (2019). Behind The Numbers: Ending School Violence and Bullying. <https://unesdoc.unesco.org/ark:/48223/pf0000366486>
- Whipp, A. M., Vuoksimaa, E., Bolhuis, K., De Zeeuw, E. L., Korhonen, T., Mauri, M., Pulkkinen, L., Rimpfeld, K., Rose, R. J., Van Beijsterveldt, C. E. M., Bartels, M., Plomin, R., Tiemeier, H., Kaprio, J., & Boomsma, D. I. (2021). Teacher-Rated Aggression and Co-Occurring Behaviors and Emotional Problems Among Schoolchildren In Four Population-Based European Cohorts. *Plos One*, 16(4 April). <https://doi.org/10.1371/journal.pone.0238667>
- Y. Nurdiantami, H. P., Febriyanti, C. N., Chandra, R. Zahra, & A. B. Emirat. (2023). *Faktor-Faktor Yang Mempengaruhi Tidak Terturnya Perkembangan Sosial-Emosional Pada Anak*.