

Klasifikasi Usia Pengguna Berdasarkan Nilai Guna Perangkat Seluler Menggunakan Metode Support Vector Machine

Muhammad Amaruna Sahona¹, Lastri Widya Astuti², Muhammad Haviz Irfani³

^{1,2,3}Fakultas Ilmu Komputer dan Sains, Program Studi Teknik Informatika, Universitas Indo Global Mandiri, Indonesia

Email: ¹Sahonaal@gmail.com, ²lastriwidya@uigm.ac.id, ³m.haviz@uigm.ac.id

Abstrak—Klasifikasi perangkat seluler adalah proses pengelompokan perangkat seperti smartphone berdasarkan karakteristik dan fitur yang dimilikinya. Penelitian ini mengatasi permasalahan kurangnya pemahaman mengenai karakteristik penggunaan perangkat seluler pada berbagai kelompok usia, yang dapat menyebabkan ketidaksesuaian produk dengan kebutuhan pengguna. Tujuan penelitian ini adalah mengklasifikasikan usia pengguna perangkat seluler berdasarkan manfaat perangkat menggunakan metode support vector machine (SVM). Data yang digunakan adalah data sekunder dari dataset platform kaggle, yang mencakup variabel terkait perilaku pengguna, seperti model perangkat, sistem operasi, durasi penggunaan aplikasi, waktu layar menyala, konsumsi daya baterai, jumlah aplikasi terinstal, penggunaan data, dan jenis kelamin pengguna. Pengolahan data melibatkan pembersihan data, ekstraksi fitur, pelatihan model SVM dengan kernel Linear, RBF, Polynomial, dan Sigmoid, serta penyetelan *Hyperparameter* menggunakan Grid Search. Hasil penelitian menunjukkan bahwa model SVM dengan kernel Linear, Polynomial, dan RBF mencapai akurasi 100%, membuktikan efektivitas metode ini dalam mengklasifikasikan usia pengguna.

Kata Kunci: Klasifikasi, Perangkat Seluler, Usia, Support Vector Machine, Perilaku Pengguna.

Abstract—Mobile device classification is the process of grouping devices such as smartphones based on their characteristics and features. This study addresses the problem of a lack of understanding of the characteristics of mobile device usage across age groups, which can lead to product mismatches with user needs. The purpose of this study is to classify the age of mobile device users based on device benefits using the support vector machine (SVM) method. The data used are secondary data from the Kaggle platform dataset, which includes variables related to user behavior, such as device model, operating system, application usage duration, screen-on time, battery power consumption, number of installed applications, data usage, and user gender. Data processing involves data cleaning, feature extraction, training an SVM model with Linear, RBF, Polynomial, and Sigmoid kernels, and *Hyperparameter* tuning using Grid Search. The results show that the SVM model with Linear, Polynomial, and RBF kernels achieves 100% accuracy, proving the effectiveness of this method in classifying user age.

Keywords: Classification, Mobile Devices, Age, Support Vector Machine, User Behavior.

1. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi pada era digital telah mendorong peningkatan penggunaan perangkat seluler, khususnya smartphone, di berbagai lapisan Masyarakat [1]. Perangkat seluler tidak lagi berfungsi hanya sebagai alat komunikasi, tetapi juga dimanfaatkan untuk mendukung aktivitas pendidikan, pekerjaan, hiburan, serta pengelolaan kegiatan sehari-hari [2]. Tingginya intensitas penggunaan tersebut menjadikan perangkat seluler sebagai bagian penting dalam kehidupan modern [3].

Seiring dengan meningkatnya penggunaan perangkat seluler, pola dan nilai guna pemanfaatannya menunjukkan perbedaan yang signifikan berdasarkan karakteristik usia pengguna [4]. Kelompok remaja cenderung menggunakan perangkat seluler untuk media sosial, hiburan, dan komunikasi dengan teman sebaya, sedangkan kelompok dewasa lebih memanfaatkannya untuk menunjang produktivitas, pekerjaan, dan akses informasi [5]. Sementara itu, kelompok lanjut usia umumnya menggunakan perangkat seluler untuk menjaga hubungan sosial serta memperoleh informasi yang berkaitan dengan kesehatan dan kebutuhan sehari-hari. Perbedaan ini menunjukkan bahwa usia memiliki pengaruh terhadap cara dan tujuan penggunaan perangkat seluler [6].

Namun, sebagian besar penelitian terkait penggunaan smartphone masih berfokus pada aspek deskriptif atau perilaku konsumen, seperti pengaruh harga dan citra merek terhadap keputusan pembelian [7]. Pendekatan tersebut belum mampu memberikan pemahaman yang komprehensif mengenai klasifikasi usia pengguna berdasarkan nilai guna perangkat seluler. Penelitian lain yang mengkaji demografi pengguna smartphone hanya menggambarkan distribusi usia responden tanpa melakukan klasifikasi berbasis pola penggunaan [8].

Beberapa studi telah menerapkan metode clustering, seperti K-Means, untuk mengelompokkan tingkat ketergantungan atau intensitas penggunaan smartphone [9]. Meskipun memberikan informasi yang bermanfaat, metode tersebut bersifat unsupervised sehingga kurang optimal untuk permasalahan klasifikasi usia pengguna yang memiliki label kelas yang jelas [10]. Di sisi lain, perkembangan machine learning membuka peluang penerapan metode supervised learning untuk menghasilkan klasifikasi yang lebih akurat dan objektif [11].

Salah satu metode supervised learning yang banyak digunakan dalam permasalahan klasifikasi adalah Support vector machine (SVM) [12]. Metode SVM dikenal memiliki kemampuan yang baik dalam menangani data berdimensi tinggi serta memisahkan kelas dengan batas nonlinier secara optimal [13]. Meskipun SVM telah banyak diterapkan dalam berbagai bidang klasifikasi, penelitian yang secara khusus mengklasifikasikan usia pengguna perangkat seluler berdasarkan nilai guna penggunaan perangkat masih terbatas [14].

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk melakukan klasifikasi usia pengguna perangkat seluler berdasarkan nilai guna penggunaan perangkat menggunakan metode Support Vector Machine. Penelitian ini diharapkan dapat menghasilkan model klasifikasi yang akurat dan memberikan kontribusi dalam memahami karakteristik penggunaan perangkat seluler pada berbagai kelompok usia. Hasil penelitian ini juga diharapkan dapat menjadi dasar bagi pengembangan layanan dan sistem digital yang lebih adaptif terhadap kebutuhan pengguna lintas usia.

2. METODOLOGI PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif dengan desain klasifikasi menggunakan metode Support vector machine (SVM), yang dipilih karena kemampuannya dalam mengelola data berdimensi tinggi dan fitur non-linier, serta menghasilkan akurasi yang tinggi [15]. Data yang digunakan diperoleh dari platform kaggle, mencakup variabel seperti model perangkat, sistem operasi, durasi penggunaan aplikasi, waktu layar aktif, konsumsi daya, jumlah aplikasi terpasang, penggunaan data, jenis kelamin, usia, dan kelas perilaku pengguna. Tahapan metode penelitian dijelaskan dalam Gambar 1.



Gambar 1. Tahap Metode Penelitian

2.1 Identifikasi Masalah

Terdapat kekurangan pemahaman terkait karakteristik penggunaan perangkat seluler berdasarkan kelompok usia, yang menyebabkan ketidaksesuaian antara produk dan kebutuhan penguin dari berbagai usia. Terdapat kekurangan pemahaman terkait karakteristik penggunaan perangkat seluler berdasarkan kelompok usia, yang menyebabkan ketidaksesuaian antara produk dan kebutuhan penguin dari berbagai usia.

2.2 Studi Literatur

Kajian literatur yang relevan mengenai klasifikasi perangkat seluler, parameter penggunaan perangkat, algoritma SVM (termasuk kernel linear, RBF, polynomial, dan sigmoid), dan penelitian sebelumnya. Adapun variabel yang digunakan, seperti model perangkat, sistem operasi, durasi penggunaan aplikasi, konsumsi daya, dan variabel demografis .

2.3 Pengumpulan Data

Data sekunder diperoleh dari dataset kaggle yang mencakup variabel seperti model perangkat, sistem operasi, durasi penggunaan aplikasi, waktu layar menyala, konsumsi daya, jumlah aplikasi terinstal, penggunaan data, usia, jenis kelamin, dan kelas perilaku pengguna. Dataset ini terdiri dari 7000 entri dengan berbagai atribut yang disusun berdasarkan pola penggunaan nyata, yang kemudian dilabeli sesuai kategori usia.

2.4 Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahap awal yang dilakukan sebelum proses pemodelan untuk memastikan data berada dalam kondisi yang layak digunakan. Data yang diperoleh dari proses pengumpulan umumnya masih mengandung ketidakkonsistenan, seperti data duplikat, atribut yang tidak relevan, nilai hilang, serta perbedaan skala antar variabel.

Tahapan pra-pemrosesan data dilakukan untuk memastikan kualitas dan kelayakan data sebelum digunakan pada proses klasifikasi bisa dilihat di Gambar 2.



Gambar 2. Tahapan Pra-Pemrosesan Data

Pada gambar 2 ini, tahapan pra-pemrosesan data meliputi penghapusan data duplikat, penghapusan kolom yang tidak relevan, penanganan nilai hilang, normalisasi data numerik, serta pembagian data menjadi data latih dan data uji.

a. Penghapusan Data Duplikat

Penghapusan data duplikat dilakukan dengan menghilangkan data yang memiliki nilai identik pada seluruh atribut. Data duplikat tidak memberikan informasi tambahan dan dapat memengaruhi distribusi data. Oleh karena itu, proses ini dilakukan untuk menjaga kualitas data dan mencegah bias pada proses pelatihan model.

b. Penghapusan Kolom yang Tidak Relevan

Tahap ini bertujuan untuk menghilangkan atribut yang tidak berkontribusi terhadap proses klasifikasi. Kolom yang tidak relevan, seperti atribut identitas atau atribut yang tidak berkaitan dengan nilai guna penggunaan perangkat seluler, dihapus untuk mengurangi kompleksitas data dan meningkatkan efisiensi pemodelan.

c. Penanganan Nilai Hilang

Penanganan nilai hilang dilakukan untuk mengatasi data yang tidak lengkap pada beberapa atribut. Keberadaan nilai hilang dapat menurunkan kinerja model klasifikasi. Oleh karena itu, data yang mengandung nilai hilang ditangani menggunakan metode yang sesuai agar dataset tetap konsisten dan dapat digunakan pada tahap selanjutnya.

d. Normalisasi Data Numerik

Normalisasi data numerik dilakukan untuk menyamakan rentang nilai antar atribut numerik. Tahap ini penting karena perbedaan skala data dapat memengaruhi hasil klasifikasi. Dengan normalisasi, setiap atribut numerik memiliki pengaruh yang seimbang dalam proses pembentukan model.

e. Pembagian Data

Tahap akhir pra-pemrosesan adalah pembagian data menjadi data latih dan data uji. Data latih digunakan untuk membangun model klasifikasi, sedangkan data uji digunakan untuk mengevaluasi kinerja model. Pembagian ini bertujuan untuk mengukur kemampuan model dalam mengklasifikasikan data yang belum pernah digunakan sebelumnya.

2.5 Penerapan Metode SVM

Model SVM diterapkan dengan berbagai jenis kernel (*linear, RBF, polynomial, sigmoid*) untuk menentukan mana yang memberikan hasil terbaik. *Hyperparameter* pada kernel, disesuaikan menggunakan metode grid search untuk mencapai akurasi maksimal

2.6 Pengujian dan Evaluasi Model

Evaluasi dilakukan berdasarkan akurasi serta metrik seperti confusion matrix, precision, recall, dan F1-score [16].



3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengumpulan Data

Data yang digunakan dalam penelitian ini bersumber dari Kaggle, berupa dataset pengguna perangkat seluler yang mencakup sejumlah atribut terkait nilai guna penggunaan perangkat serta informasi kelas usia pengguna. Dataset yang diperoleh masih dalam bentuk data mentah sehingga memerlukan proses pra-pemrosesan sebelum digunakan pada tahap pemodelan. Ringkasan hasil pengambilan data disajikan pada Tabel 1.

Tabel 1. Hasil Pengambilan Data

Keterangan	Nilai
Sumber data	Dataset sekunder (Kaggle)
Jumlah data awal	701
Jumlah atribut awal	10
Jumlah kelas usia	3 kelas
Format data	Numerik & kategorikal

3.2 Hasil Pra-Pemrosesan Data

Pra-pemrosesan data dilakukan untuk meningkatkan kualitas dataset sebelum digunakan pada proses klasifikasi. Tahapan yang dilakukan meliputi penghapusan data duplikat, penghapusan kolom yang tidak relevan, penanganan nilai hilang, serta normalisasi data numerik. Proses ini bertujuan untuk memastikan data berada dalam kondisi yang konsisten dan siap digunakan dalam pelatihan model. Ringkasan hasil pengambilan data disajikan pada Tabel 2.

Tabel 2. Hasil Pra-Pemrosesan Data

Tahapan Pra-Pemrosesan	Hasil
Penghapusan data duplikat	Data duplikat dihapus
Penghapusan kolom tidak relevan	Kolom identitas dihapus
Penanganan nilai hilang	Data tidak lengkap ditangani
Normalisasi data numerik	Seluruh fitur ternormalisasi
Total data akhir	701 data

3.3 Hasil Pembagian Data


Setelah tahap pra-pemrosesan selesai, dataset dibagi menjadi data latih dan data uji. Data latih digunakan untuk membangun model klasifikasi menggunakan metode SVM, sedangkan data uji digunakan untuk mengevaluasi kinerja model yang dihasilkan. Ringkasan hasil pengambilan data disajikan pada Tabel 3.

Tabel 3. Hasil Pembagian Data

Jenis Data	Jumlah	Persentase
Data latih	560	80%
Data uji	141	20%
Total	701	100%

3.4 Hasil Data Korelasi Antar Atribut

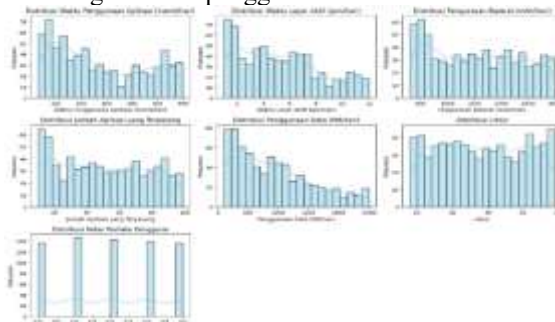
Hasil analisis korelasi pada Gambar 3 menunjukkan adanya hubungan yang signifikan antara atribut seperti durasi penggunaan aplikasi, waktu layar aktif, konsumsi daya, dan jumlah aplikasi yang terpasang. Durasi penggunaan aplikasi memiliki korelasi tinggi dengan atribut lainnya, seperti waktu layar aktif, konsumsi baterai, dan jumlah aplikasi yang terpasang. Temuan ini mengindikasikan bahwa semakin lama waktu penggunaan aplikasi, semakin besar pula penggunaan daya dan data. Sebaliknya, usia pengguna menunjukkan korelasi yang sangat rendah dengan atribut lainnya, yang berarti usia tidak mempengaruhi pola penggunaan perangkat. Di sisi lain, kelas perilaku pengguna memiliki hubungan yang sangat kuat dengan atribut-atribut lainnya, menunjukkan bahwa perilaku pengguna sangat memengaruhi cara mereka menggunakan perangkat.



Gambar 3. Hasil Data Korelasi Antar Atribut

3.5 Hasil Distribusi Data Semua Atribut

Distribusi data pada gambar 3 menunjukkan bahwa sebagian besar pengguna menghabiskan waktu antara 200 hingga 500 menit per hari menggunakan aplikasi, dengan waktu layar aktif rata-rata 3 hingga 6 jam per hari. Penggunaan daya bervariasi antara 1000 hingga 1500 mAh per hari, dengan mayoritas pengguna mengonsumsi sekitar 1200 hingga 1500 mAh. Mayoritas pengguna juga memasang antara 20 hingga 100 aplikasi di perangkat mereka. Dalam hal penggunaan data, sebagian besar pengguna menghabiskan antara 500 hingga 1000 MB per hari. Data ini menunjukkan pola penggunaan yang konsisten di antara sebagian besar pengguna.



Gambar 4. Hasil Distribusi Data Semua Atribut

3.6 Atribut Hasil Model SVM dengan Menggunakan Kernel

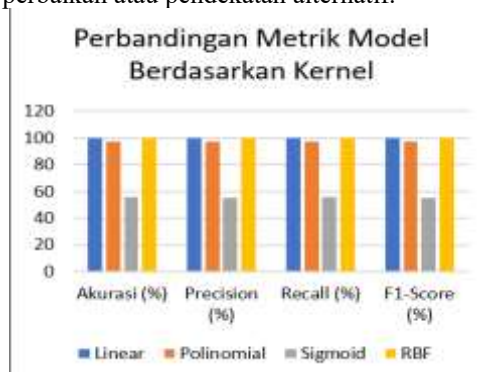
Tabel 4 menyajikan hasil yang diperoleh dari setiap kernel, mencakup accuracy, precision, recall, dan F1-score. perbandingan itu penting untuk menilai untuk menilai kinerja model dan membantu dalam pemilihan kernel yang paling tepat untuk data yang dianalisis. kinerja model dan membantu dalam pemilihan kernel yang paling tepat untuk data yang dianalisis, untuk hasil codingnya berada di lampiran.

Tabel 4. Hasil Model SVM dengan Menggunakan Kernel

Kernel	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
Linear	100	100	100	100
Polynomial	97	97	97	97
Sigmoid	55	55	56	55
RBF	100	100	100	100

Hasil yang ditampilkan pada Tabel 4 menunjukkan penerapan metode support vector machine (SVM) dengan berbagai kernel untuk menilai kinerja model berdasarkan metrik akurasi, precision, recall, dan F1-score. Kernel Linear dan RBF menunjukkan kinerja sangat baik dengan akurasi 100% dan hasil sempurna pada semua metrik, mengindikasikan kemampuan model dalam memisahkan data secara akurat tanpa kesalahan. Kernel Polinomial menunjukkan sedikit penurunan dengan akurasi 97,14% dan Precision serta Recall masing-masing 97%, meskipun masih menunjukkan kinerja baik, ada potensi untuk perbaikan. Di sisi lain, kernel Sigmoid memiliki kinerja yang jauh

lebih rendah, dengan akurasi 55,71% serta Precision dan Recall sekitar 0,55, yang menunjukkan banyak kesalahan dalam klasifikasi dan membutuhkan perbaikan atau pendekatan alternatif.



Gambar 5. Grafik Hasil Model SVM Menggunakan Kernel

Grafik pada Gambar 4 menggambarkan perbandingan kinerja empat kernel yang digunakan dalam penelitian ini. Kernel Linear dan RBF menunjukkan hasil terbaik di semua metrik, diikuti oleh kernel Polynomial, sementara kernel Sigmoid menunjukkan kinerja yang lebih rendah, terutama dalam akurasi dan precision. Hal ini mengindikasikan bahwa pemilihan kernel yang tepat sangat mempengaruhi kinerja model SVM, dengan kernel Linear dan RBF sebagai pilihan terbaik dalam penelitian ini.

3.7 Hasil Model SVM dengan Menggunakan Hyperparameter

Bagian ini membahas hasil evaluasi model klasifikasi yang diuji dengan berbagai tipe kernel dalam support vector machine menggunakan Hyperparameter. Evaluasi dilakukan untuk menilai kinerja setiap kernel dalam klasifikasi data, serta untuk memberikan wawasan mengenai efektivitas dan efisiensi model berdasarkan metrik yang diperoleh

Tabel 5. Hasil Model SVM dengan Menggunakan Hyperparameter

Kernel	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
Linear	100	100	100	100
Polinomial	100	100	100	100
Sigmoid	61	42	61	48
RBF	100	100	100	100

Tabel 5 memperlihatkan perbandingan kinerja empat kernel dalam model SVM: Linear, Polynomial, Sigmoid, dan RBF. Kernel Linear, Polynomial, dan RBF mencatatkan skor 100% pada semua metrik, sementara kernel Sigmoid memiliki performa lebih rendah, dengan akurasi 61%, precision 42%, recall 61%, dan F1-score 48%. Hasil ini menunjukkan bahwa pemilihan kernel mempengaruhi kinerja model secara signifikan, dengan Linear, Polynomial, dan RBF lebih unggul, sementara Sigmoid kurang efektif meskipun akurasi cukup baik. Pemilihan kernel harus disesuaikan dengan jenis data yang digunakan.



Gambar 6. Hasil Model SVM dengan Menggunakan Hyperparameter

Gambar 6 menunjukkan perbandingan metrik model SVM dengan empat kernel: Linear, Polynomial, Sigmoid, dan RBF, yang meliputi akurasi, precision, recall, dan F1-score. Secara keseluruhan, kernel Linear, Polynomial, dan RBF memberikan kinerja yang lebih baik dan konsisten pada sebagian besar metrik dibandingkan dengan kernel Sigmoid. Kernel Linear, RBF, dan Polynomial lebih cocok untuk data linier atau hampir linier, sementara kernel

Sigmoid, meskipun memiliki akurasi lebih rendah, lebih unggul dalam menghasilkan recall yang lebih tinggi, menandakan bahwa model ini lebih sensitif dalam mendeteksi kelas positif meskipun precision-nya lebih rendah.

4. KESIMPULAN

Dari hasil penelitian ini, dapat disimpulkan bahwa metode Support Vector Machine (SVM) sangat efektif untuk mengklasifikasikan usia pengguna perangkat seluler dengan akurasi mencapai 100% setelah dilakukan optimalisasi hyperparameter. Kernel Linear, Polynomial, dan RBF menunjukkan performa terbaik dalam membedakan kelas usia pengguna, sedangkan kernel Sigmoid menghasilkan performa yang lebih rendah. Proses penyetulan hyperparameter menggunakan grid search terbukti penting dalam meningkatkan akurasi dan kestabilan model. Faktor seperti model perangkat, sistem operasi, durasi penggunaan aplikasi, waktu layar menyala, konsumsi daya baterai, jumlah aplikasi terinstal, penggunaan data, dan jenis kelamin pengguna. Secara keseluruhan, SVM terbukti sebagai metode yang dapat diandalkan untuk klasifikasi usia berdasarkan pola perilaku penggunaan perangkat seluler, serta memberikan wawasan penting untuk pengembangan produk yang lebih relevan.

REFERENCES

- [1] E. Yuda, G. Hestin, O. Vito, and F. Pengetahuan, "PENGETAHUAN LITERASI DIGITAL TERHADAP DIGITAL SURVEILLANCE MEWUJUDKAN SUMBER DAYA MANUSIA UNGGUL PADA ERA INTERNET OF THINGS," *J. Leverage, Engag. Empower. Community*, vol. 3, no. 1, pp. 71–80, 2021.
- [2] A. Zakaria *et al.*, "Pelatihan Penggunaan Fitur Kesehatan Digital Untuk Mencegah Kecanduan Gadget Pada Anak-Anak," *J. Community Engagem. Empower.*, vol. 01, no. 01, pp. 2986–2930, 2023, doi: 10.58706/dedikasi.
- [3] U. Djuanda and K. Bogor, "Analisis Pengaruh Penggunaan Gadget Pada Perkembangan Psikososial Pada Anak," vol. 3, pp. 7689–7704, 2024.
- [4] Yuyuk, Waridah, and Kartini, "UPAYA ORANG TUA DALAM MENGATASI PENGGUNAAN GADGET PADA ANAK USIA DINI," 2023.
- [5] B. Galih, H. Wicaksana, A. Dinda, and S. E. Zuliestiana, "PENGARUH CITRA MEREK DAN HARGA PRODUK TERHADAP KEPUTUSAN PEMBELIAN SMARTPHONE IPHONE DI INDONESIA BRAND IMAGE AND PRODUCT PRICE; ITS IMPACT FOR SMARTPHONE IPHONE PURCHASING DECISION IN INDONESIA Oleh," vol. 20, 2019.
- [6] K. Nupus, "Analisis Evaluasi Merek Smartphone Samsung Galaxy Series A," *Student Res. J.*, vol. 2, no. 1, pp. 481–490, 2024, doi: 10.55606/srjyappi.v2i1.1040.
- [7] M. Syafiih, M. Khairi, M. Furqan, and B. Yusman, "Pendampingan Literasi Digital untuk Mengurangi Risiko Kejahatan Siber Membentuk Masyarakat yang Lebih Aman," vol. 2, no. 4, pp. 1027–1036, 2024, [Online]. Available: <https://journal.insankreasimedia.ac.id/index.php/JILPI>
- [8] N. U. Khan, W. Wan, R. Riaz, S. Jiang, and X. Wang, "Prediction and Classification of User Activities Using Machine Learning Models from Location-Based Social Network Data," *Appl. Sci.*, vol. 13, no. 6, Mar. 2023, doi: 10.3390/app13063517.
- [9] B. Al Kurniati¹ and U. Solikhah², "Karakteristik Penggunaan Smartphone (Gadget) Pada Balita Usia 1-5 Tahun Di Desa Dukuhmaja Kecamatan Songgom Kabupaten Brebes," 2020. [Online]. Available: <http://journal.um-surabaya.ac.id/index.php/JKM>
- [10] Y. Anggriani, "PEMANFAATAN GADGET DALAM MENINGKATKAN MINAT BACA ANAK DI KELUARGA," 2020.
- [11] A. Sanmorino, R. Gustriansyah, and J. Alie, "DDoS Attacks Detection Method Using Feature Importance and Support Vector Machine," *JUITA J. Inform.*, vol. 10, no. 2, p. 167, 2022, doi: 10.30595/juita.v10i2.14939.
- [12] M. A. T. Siregar and G. Gasim, "Identifikasi Cacat Pada Kayu Menggunakan Fitur Gcm Dengan Metode Svm," *J. Algoritm.*, vol. 3, no. 1, pp. 22–32, 2022, doi: 10.35957/algoritme.v3i1.2970.
- [13] P. Pooja Saigal, "SUPPORT-VECTOR MACHINES EVOLUTION AND APPLICATIONS," 2021.
- [14] N. A. S. Kanaka, R. Heriansyah, and S. Puspasari, "Perbandingan Algoritma Decision Tree dan Support Vector Machine Dalam Pemilihan Calon Mahasiswa Penerima KIP-K," *TIN Terap. Inform. Nusant.*, vol. 4, no. 9, pp. 613–619, 2024, doi: 10.47065/tin.v4i9.4902.
- [15] M. Khoiriah and R. Kurniawan, "Penerapan Algoritma Support Vector Machine Untuk Mendeteksi Autisme," *J. Comput. Syst. Informatics*, vol. 5, no. 4, pp. 786–795, 2024, doi: 10.47065/josyc.v5i4.5692.
- [16] Z. Haoxing and C. System, "penggunaan metrik seperti precision, recall, dan F1-score".