

KLASIFIKASI TINGKAT KECANDUAN SMARTPHONE PADA REMAJA MENGUNAKAN ALGORITMA RANDOM FOREST

Hema Nuramadini¹, Nining Rahaningsih², Irfan Ali³, Ratna Dewi Lestyorini⁴.

Program Studi Teknik Informatika¹
Program Studi Komputerisasi Akuntansi²
Program Studi Rekayasa Perangkat Lunak³
Program Studi Sistem Informasi⁴

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
hemadini15@gmail.com

(*) Corresponding Author : hemadini15@gmail.com
Published : 30 Juni 2026

Abstract—Excessive Smartphone use among teenagers has become increasingly prevalent and may lead to behavioral addiction that affects psychological, social, and academic functioning. This study aims to classify Smartphone addiction levels in adolescents using the Random Forest algorithm based on digital behavior data. The dataset used in this research was sourced from the Teen Phone Addiction Dataset, consisting of 600 entries and 21 features, including daily usage duration, social media activity, gaming time, demographic information, and psychosocial indicators. The research process involved data acquisition, pre-processing (data cleaning, label encoding, normalization, and data balancing using SMOTE), model training, hyperparameter tuning through Grid Search and k-fold cross-validation, and performance evaluation. The Random Forest model achieved strong performance with 89% accuracy, balanced precision and recall scores, and a weighted F1-score of 0.89. The most influential features were Daily Usage Hours, Time on Social Media, and Time on Gaming, indicating that the intensity of daily digital engagement strongly correlates with Smartphone addiction levels. This study contributes to the development of an early detection system for Smartphone addiction using machine learning, offering potential support for educational initiatives, preventive interventions, and policy development related to digital well-being among adolescents.

Keywords: Smartphone addiction; Random Forest; machine learning; classification; adolescents.

Abstrak—Penggunaan Smartphone yang berlebihan di kalangan remaja semakin meningkat dan berpotensi menimbulkan kecanduan yang berdampak pada aspek psikologis, sosial, dan akademik. Penelitian ini bertujuan untuk mengklasifikasikan tingkat kecanduan Smartphone pada remaja menggunakan algoritma Random Forest berdasarkan data perilaku digital. Dataset diperoleh dari Teen Phone Addiction Dataset berisi 600 data dan 21 fitur yang mencakup durasi penggunaan harian, aktivitas media sosial, gim, serta faktor demografis dan psikososial. Tahapan penelitian meliputi acquisition data, pra-pemrosesan (data cleaning, label encoding, normalisasi, dan penyeimbangan data menggunakan SMOTE), pelatihan model, evaluasi hyperparameter menggunakan Grid Search dan k-fold cross validation, serta analisis hasil. Model Random Forest menunjukkan performa terbaik dengan akurasi 89%, precision dan recall yang seimbang, serta weighted F1-score 0,89. Fitur yang paling berpengaruh meliputi Daily Usage Hours, Time on Social Media, dan Time on Gaming, yang menunjukkan bahwa intensitas keterlibatan digital memiliki korelasi kuat dengan tingkat kecanduan Smartphone. Hasil penelitian ini memberikan kontribusi pada pengembangan sistem pendeteksi dini risiko kecanduan Smartphone berbasis machine learning, yang dapat digunakan sebagai dasar dalam upaya edukasi, intervensi preventif, dan pengambilan kebijakan terkait kesehatan digital remaja.

Kata Kunci: kecanduan Smartphone ; Random Forest; machine learning; klasifikasi; remaja.

INTRODUCTION

Kecanduan ponsel pintar di kalangan remaja telah menjadi masalah mendesak di

seluruh dunia, yang berdampak signifikan terhadap kesehatan mental dan aktivitas sehari-hari mereka. Penelitian menunjukkan bahwa penggunaan ponsel pintar yang berlebihan berkaitan dengan berbagai

dampak negatif, termasuk kecemasan dan depresi [1]. Selain itu, studi menunjukkan bahwa peningkatan keterlibatan dengan ponsel pintar berkorelasi dengan meningkatnya tingkat kecanduan, terutama di kalangan [2] remaja yang aktif menggunakan media sosial dan aplikasi gim dalam jangka waktu lama. Lebih lanjut, meskipun penelitian tentang pendekatan pembelajaran mesin untuk mengklasifikasikan dan memprediksi kecanduan ponsel pintar sedang berlangsung, metodologi dan hasil spesifiknya masih terus dikembangkan [3]. Kerangka kerja semacam itu krusial dalam mengembangkan langkah-langkah pencegahan dan intervensi yang menargetkan populasi remaja untuk mengurangi dampak buruk yang terkait dengan kecanduan ponsel pintar.

Penggunaan *Smartphone* secara signifikan mempengaruhi kesehatan mental dan kinerja belajar remaja. Penelitian oleh [4] menunjukkan bahwa data pendidikan multimodal dapat digunakan untuk mendeteksi kesehatan mental siswa, meskipun deteksi yang akurat sulit dicapai karena kompleksitas data yang tidak terstruktur [4]. Selain itu, [5] berfokus pada bagaimana data media sosial dapat digunakan untuk mendeteksi dan memprediksi gangguan mental, termasuk gangguan kecemasan dan depresi, mengingat bahwa pemuda sering menggunakan platform ini untuk interaksi sehari-hari [5]. Dalam studi yang berbeda, [6] menekankan pentingnya model dalam memahami faktor yang mempengaruhi kinerja akademik, meskipun fokus penelitian mereka adalah pada penyandang disabilitas pendengaran [6]. [7] menggambarkan pengembangan sistem pengajaran adaptif yang meningkatkan keterlibatan siswa dengan menciptakan pengalaman belajar yang personal, menunjukkan hubungan antara teknologi pendidikan dan hasil belajar [7]. Secara keseluruhan, hubungan antara kecanduan *Smartphone*, kesehatan mental, dan kinerja belajar merupakan topik penting yang mendapat perhatian dalam penelitian modern [5]; [7].

Algoritma ensemble seperti *Random Forest* (RF) sangat cocok untuk klasifikasi data perilaku karena ketahanannya dan kapasitasnya untuk mengelola kumpulan data berdimensi tinggi, menjadikannya ideal untuk tugas-tugas seperti mengklasifikasikan tingkat kecanduan telepon pintar pada remaja. RF menggunakan beberapa pohon keputusan untuk melakukan prediksi, memanfaatkan metode bagging yang meningkatkan stabilitas model dan mengurangi overfitting [8]; [9]; [10]. Studi terbaru

menunjukkan bahwa RF dapat mencapai akurasi klasifikasi yang tinggi, seperti yang diamati dengan uji klasifikasi beban yang menghasilkan akurasi hingga 93,05% [9]. Selain itu, kemampuan RF untuk menangani hubungan rumit dan non-linier di antara fitur perilaku memungkinkannya untuk secara efektif membedakan antara berbagai tingkat kecanduan ponsel pintar [10]; [11]. Fleksibilitas ini sangat bermanfaat saat menganalisis pola perilaku, karena RF dapat menggabungkan hasil di berbagai subset data, sehingga meningkatkan kinerja prediktif dalam konteks yang melibatkan perilaku manusia yang kompleks [12] [13].

Kecanduan digital adalah bidang studi yang sedang berkembang yang menghubungkan model psikologis dengan data perilaku untuk memahami dan berpotensi mengurangi dampak buruk penggunaan ponsel pintar yang berlebihan di kalangan remaja [14]. mengeksplorasi penerapan fusi data pendidikan multimodal untuk memprediksi hasil kesehatan mental, memanfaatkan teknik pembelajaran mesin seperti *Xgboost* untuk mengklasifikasikan kecanduan internet dan depresi, menunjukkan kapasitas prediktif penilaian psikologis dalam skenario waktu nyata. Sebagai pelengkap, [15] berfokus pada mahasiswa, menggunakan ponsel pintar dan teknologi yang dapat dikenakan untuk memantau pola komunikasi dan hubungannya dengan kesehatan dan kinerja akademik, yang mendukung relevansi data perilaku dalam mengklasifikasikan tingkat kecanduan. Dalam konteks yang lebih luas, [16] melakukan tinjauan sistematis yang menunjukkan bahwa ketergantungan teknologi yang berat, terutama selama pandemi COVID-19, meningkatkan risiko yang terkait dengan kesehatan mental dan kinerja akademik di kalangan remaja. Sementara itu meninjau data penginderaan ponsel pintar untuk mengevaluasi kesejahteraan pada dewasa muda, menekankan bagaimana indikator perilaku dapat berperan sebagai prediktor masalah konsentrasi. Dengan demikian, integrasi model psikologis dengan analitik perilaku melalui berbagai metodologi menghadirkan pendekatan yang bernuansa untuk memahami kecanduan ponsel pintar pada remaja.

Pengumpulan data akurat tentang kecanduan ponsel pintar di kalangan remaja menghadirkan banyak tantangan. Pertama, variabilitas dalam cara kecanduan didefinisikan dan diukur mempersulit pengumpulan data. Berbagai penelitian menggunakan instrumen psikometri yang berbeda-beda, sehingga menyebabkan inkonsistensi dalam definisi kecanduan ponsel pintar [17]. Selain itu, pengukuran yang dilaporkan sendiri seringkali menimbulkan bias, karena remaja mungkin tidak melaporkan penggunaan ponsel pintar mereka


secara akurat karena bias keinginan sosial atau kurangnya kesadaran diri [18]. Kompleksitas lanskap digital, di mana aplikasi dan jaringan terus berkembang, semakin mempersulit penilaian tingkat kecanduan [19]. Lebih lanjut, pertimbangan etis dalam meneliti anak di bawah umur mengharuskan penanganan persetujuan dan privasi yang cermat, yang dapat membatasi ukuran dan keragaman sampel [20]. Terakhir, disparitas teknologi dapat mengakibatkan akses yang tidak merata terhadap alat ukur yang tepat, sehingga mendistorsi proses pengumpulan data. [21]

Sejumlah studi terbaru telah berusaha mendefinisikan dan mengukur tingkat kecanduan *Smartphone* dengan berbagai metode yang sesuai dengan konteks penggunaannya. Beberapa penelitian menunjukkan bahwa penggunaan kuesioner yang terstandarisasi dapat menghasilkan pengukuran yang valid dan reliabel terhadap tingkat kecanduan *Smartphone*, dengan mempertimbangkan faktor-faktor seperti waktu penggunaan, tingkat ketergantungan, dan dampak emosional. Selain itu, penerapan metode *machine learning*, seperti algoritma *Random Forest*, dapat meningkatkan akurasi identifikasi tingkat kecanduan di kalangan remaja dengan mengelompokkan data fitur yang relevan dari perilaku pengguna *Smartphone*. Pendekatan pengukuran berbasis psikometrik juga dinilai efektif untuk mengkategorikan pengalaman individu terkait kecanduan *Smartphone*, termasuk dalam hal engagement dan pengaruh sosial [22]

masalah penelitian ini dirumuskan sebagai upaya untuk menjawab pertanyaan-pertanyaan penelitian yang telah dikemukakan sebelumnya. Tujuan-tujuan tersebut diarahkan untuk menguji, menganalisis, dan mengevaluasi performa model Klasifikasi Tingkat Kecanduan *Smartphone* pada Remaja Menggunakan Algoritma *Random Forest* serta mengidentifikasi faktor-faktor signifikan yang memengaruhi hasil prediksi. Penjabaran tujuan ini juga membantu dalam membatasi ruang lingkup serta fokus eksperimen secara sistematis

MATERIALS AND METHODS

Desain penelitian dibagi ke dalam 4 (empat) tahapan, yakni 1) Tahap Studi Pendahuluan, 2) Tahap Pencarian Literature, 3) Tahap Pemilihan Metode, 4) Tahap Kesimpulan dan Rekomendasi



Gambar 1. Alur Penelitian

Alur penelitian machine learning yang terstruktur mulai dari pengolahan dataset hingga evaluasi model. Proses dimulai pada bagian dataset, yaitu penggunaan data *teen phone addiction dataset* sebagai sumber utama penelitian. Pada tahap ini juga dilakukan pembagian data menjadi data latih (80%) dan data uji (20%) menggunakan metode *stratified sampling* untuk menjaga proporsi kelas tetap seimbang. Selain itu, dilakukan visualisasi awal seperti melihat *head* data, statistik deskriptif, serta distribusi target (misalnya kategori low dan medium) guna memahami karakteristik data secara umum.

Tahap berikutnya adalah pra-pemrosesan data, yang bertujuan untuk meningkatkan kualitas data sebelum masuk ke tahap pemodelan. Proses ini diawali dengan *data cleaning*, yaitu menghapus kolom yang tidak relevan seperti id, nama, dan lokasi. Kemudian dilakukan penanganan *missing values* dengan menghapus data kosong serta menangani outlier jika ditemukan. Selanjutnya, fitur kategorikal diubah menjadi numerik melalui *label encoding* pada variabel seperti gender, tujuan penggunaan ponsel, dan kontrol orang tua. Untuk mengatasi ketidakseimbangan kelas, dilakukan *balancing data*, kemudian dilanjutkan dengan normalisasi fitur numerik seperti durasi penggunaan harian. Hasil dari tahap ini divisualisasikan kembali untuk memastikan distribusi data sudah lebih baik, termasuk melalui *heatmap* korelasi fitur.


Setelah data siap, proses berlanjut ke bagian model arsitektur, di mana digunakan pendekatan *ensemble learning* berbasis random forest. Model ini terdiri dari banyak *decision tree* yang bekerja secara kolektif. Pada tahap ini dilakukan pemilihan hyperparameter penting seperti jumlah pohon ($n_estimators$), kedalaman maksimum (max_depth), jumlah fitur yang digunakan ($max_features$), serta kriteria pemisahan (*criterion*). Struktur random forest juga mencakup teknik *bagging*, voting mayoritas untuk klasifikasi, serta analisis *feature importance* untuk mengetahui fitur yang paling berpengaruh terhadap prediksi.

Tahap selanjutnya adalah eksperimen dan pengujian, di mana model dilatih menggunakan data training dan dioptimasi melalui *hyperparameter tuning* dengan metode *gridsearchcv* serta divalidasi menggunakan *k-fold cross validation*. Hal ini bertujuan untuk mendapatkan kombinasi parameter terbaik dan memastikan model memiliki performa yang stabil serta tidak overfitting.

Tahap terakhir adalah evaluasi model, yang dilakukan menggunakan berbagai metrik seperti akurasi, precision, recall, dan f1-score, serta confusion matrix untuk melihat performa klasifikasi secara lebih detail. Hasil evaluasi ini digunakan untuk menilai efektivitas model dalam memprediksi tingkat kecanduan penggunaan ponsel serta menjadi dasar dalam pengambilan keputusan atau pengembangan model lebih lanjut.

RESULTS AND DISCUSSION

Pelatihan model dilakukan menggunakan algoritma *Random Forest Classifier*, yang membangun kumpulan decision trees untuk meningkatkan akurasi dan stabilitas prediksi. Model dilatih menggunakan data latih yang telah melalui proses *pre-processing*. Selama pelatihan, dilakukan penyesuaian parameter seperti jumlah pohon keputusan ($n_estimators$), kedalaman maksimum pohon ($max_features$), dan jumlah fitur ($max_features$). Pelatihan awal menunjukkan akurasi sebesar 0,85, yang kemudian ditingkatkan melalui proses hyperparameter tuning untuk memperoleh konfigurasi optimal.




Gambar 2 Pelatihan Model

Hasil Evaluasi

Evaluasi parameter dilakukan dengan metode *Grid Search* yang dikombinasikan dengan *k-fold cross validation* ($k=5$). Hasil evaluasi menunjukkan bahwa kombinasi parameter terbaik diperoleh pada:

- $n_estimators = 200$
- $max_features = 10$
- $max_features = 'sqrt'$

Kombinasi ini menghasilkan akurasi rata-rata sebesar 0,89 dan *F1-score* sebesar 0,88. Hasil ini menunjukkan bahwa model telah berada pada titik optimal antara akurasi tinggi dan efisiensi komputasi. Visualisasi hasil tuning menunjukkan tren peningkatan performa hingga batas $n_estimators$ tertentu, setelah itu peningkatan jumlah pohon tidak memberikan keuntungan signifikan.



Gambar 3 Hasil Evaluasi Parameter


Hasil Evaluasi Model

Setelah parameter optimal diperoleh, model diuji menggunakan data uji. Hasil evaluasi performa model disajikan dalam *classification report* dan *confusion matrix*.

- Akurasi keseluruhan: 0,89 (89%)

- B. Precision: 0,90 (kelas tinggi), 0,88 (kelas sedang), 0,00 (kelas rendah)
- C. Recall: 1,00 (kelas tinggi), 0,93 (kelas sedang), 0,00 (kelas rendah)
- D. F1-score: 0,95 (kelas tinggi), 0,90 (kelas sedang), 0,00 (kelas rendah)

Nilai rata-rata tertimbang (*weighted average*) F1-score sebesar 0,89, menandakan performa model yang kuat pada kelas mayoritas. Namun, hasil pada kelas minoritas (rendah) menunjukkan bahwa model masih mengalami *bias* akibat distribusi data yang tidak seimbang meskipun telah diterapkan *SMOTE*.



Gambar 4 Hasil Evaluasi Model

CONCLUSION

Berdasarkan hasil penelitian dan analisis yang telah dilakukan terhadap klasifikasi tingkat kecanduan ponsel pada remaja menggunakan algoritma *Random Forest*, diperoleh beberapa kesimpulan penting sebagai berikut:

Proses acquisition dan *pre-processing* data berhasil dilakukan secara sistematis menggunakan dataset *Teen Phone Addiction* dari Kaggle yang terdiri dari 600 entri dan 21 fitur. Tahapan pembersihan, pengkodean label, normalisasi, serta penyeimbangan data dengan *SMOTE* terbukti meningkatkan kualitas dataset dan memastikan kesiapannya untuk pelatihan model *machine learning*.

Model *Random Forest* yang dibangun menunjukkan performa klasifikasi yang tinggi dengan nilai akurasi sebesar 0,89 (89%), precision dan recall rata-rata yang seimbang, serta nilai *weighted F1-score* sebesar 0,89. Hal ini menunjukkan bahwa algoritma mampu mengenali pola perilaku pengguna ponsel dengan baik dan memiliki tingkat generalisasi yang kuat terhadap data baru.

Hasil evaluasi parameter melalui *Grid Search* dan *k-fold cross validation* menunjukkan konfigurasi terbaik pada $n_estimators = 200$, $max_features = 10$, dan $max_features = 'sqrt'$. Kombinasi ini memberikan keseimbangan antara performa model dan efisiensi komputasi.

Analisis fitur penting (*feature importance*) mengungkapkan bahwa *variabel Daily Usage Hours*, *Time on Social Media*, dan *Time on Gaming* merupakan faktor paling berpengaruh dalam menentukan tingkat kecanduan ponsel pada remaja. Hal ini memperkuat temuan bahwa durasi penggunaan ponsel dan intensitas aktivitas digital memiliki korelasi langsung terhadap potensi kecanduan.

Meskipun model secara umum memiliki performa yang tinggi, ketidakseimbangan distribusi kelas masih menjadi permasalahan utama, terutama pada kategori rendah yang sulit diprediksi dengan benar. Kondisi ini menandakan perlunya pendekatan tambahan seperti *cost-sensitive learning*, penambahan data, atau penggunaan model ensemble balancing agar performa dapat ditingkatkan secara merata pada semua kelas.

REFERENCE

- [1] A. Almadhor *et al.*, "Multi-Class Adaptive Active Learning for Predicting Student Anxiety," *Ieee Access*, vol. 12, pp. 58097–58105, 2024, doi: 10.1109/access.2024.3391418.
- [2] S. M. M. Hasan, M. P. Uddin, Md. A. Mamun, M. I. Sharif, A. Ulhaq, and G. Krishnamoorthy, "A Machine Learning Framework for Early-Stage Detection of Autism Spectrum Disorders," *Ieee Access*, vol. 11, pp. 15038–15057, 2023, doi: 10.1109/access.2022.3232490.
- [3] S. M. H. Mirsadeghi, H. Bahşi, R. Vaarandi, and W. Inoubli, "Learning From Few Cyber-Attacks: Addressing the Class Imbalance Problem in Machine Learning-Based Intrusion Detection in Software-Defined Networking," *Ieee Access*, vol. 11, pp. 140428–140442, 2023, doi: 10.1109/access.2023.3341755.
- [4] T. Guo, W. Zhao, M. Alrashoud, A. Tolba, S. Firmin, and F. Xia, "Multimodal Educational Data Fusion for Students' Mental Health Detection," *Ieee Access*, vol. 10, pp. 70370–70382, 2022, doi: 10.1109/access.2022.3187502.
- [5] T. A. A. Abdullah *et al.*, "Sig-Lime: A Signal-Based Enhancement of Lime Explanation Technique," *Ieee Access*, vol. 12, pp. 52641–52658, 2024, doi: 10.1109/access.2024.3384277.
- [6] N. R. Raji, R. M. S. Kumar, and C. L. Biji, "Explainable Machine Learning Prediction for the Academic Performance of Deaf Scholars," *Ieee Access*, vol. 12, pp. 23595–

- 23612, 2024, doi: 10.1109/access.2024.3363634.
- [7] J. Liang *et al.*, "Student Modeling and Analysis in Adaptive Instructional Systems," *Ieee Access*, vol. 10, pp. 59359–59372, 2022, doi: 10.1109/access.2022.3178744.
- [8] A. Raza *et al.*, "Preventing Road Accidents Through Early Detection of Driver Behavior Using Smartphone Motion Sensor Data: An Ensemble Feature Engineering Approach," *Ieee Access*, vol. 11, pp. 138457–138471, 2023, doi: 10.1109/access.2023.3340304.
- [9] B.-S. Lin *et al.*, "Fall Detection System With Artificial Intelligence-Based Edge Computing," *Ieee Access*, vol. 10, pp. 4328–4339, 2022, doi: 10.1109/access.2021.3140164.
- [10] D. Rangelov, M. Boerger, N. Tcholtchev, P. Lämmel, and M. Hauswirth, "Design and Development of a Short-Term Photovoltaic Power Output Forecasting Method Based on Random Forest, Deep Neural Network and LSTM Using Readily Available Weather Features," *Ieee Access*, vol. 11, pp. 41578–41595, 2023, doi: 10.1109/access.2023.3270714.
- [11] I. Ahmed, M. Alkahtani, Q. S. Khalid, and F. M. Alqahtani, "Improved Commodity Supply Chain Performance Through AI and Computer Vision Techniques," *Ieee Access*, vol. 12, pp. 24116–24132, 2024, doi: 10.1109/access.2024.3361756.
- [12] A. Raza *et al.*, "Preventing Road Accidents Through Early Detection of Driver Behavior Using Smartphone Motion Sensor Data: An Ensemble Feature Engineering Approach," *Ieee Access*, vol. 11, pp. 138457–138471, 2023, doi: 10.1109/access.2023.3340304.
- [13] H. S. Mputu, A. Abdel-Mawgood, A. Shimada, and M. S. Sayed, "Tomato Quality Classification Based on Transfer Learning Feature Extraction and Machine Learning Algorithm Classifiers," *Ieee Access*, vol. 12, pp. 8283–8295, 2024, doi: 10.1109/access.2024.3352745.
- [14] T. Guo, W. Zhao, M. Alrashoud, A. Tolba, S. Firmin, and F. Xia, "Multimodal Educational Data Fusion for Students' Mental Health Detection," *Ieee Access*, vol. 10, pp. 70370–70382, 2022, doi: 10.1109/access.2022.3187502.
- [15] S. Vhaduri, S. V. Dibbo, and Y. Kim, "Deriving College Students' Phone Call Patterns to Improve Student Life," *IEEE Access*, vol. 9, pp. 96453–96465, 2021, doi: 10.1109/ACCESS.2021.3093493.
- [16] A. A. Norman *et al.*, "Technology Dependency and Impact During COVID-19: A Systematic Literature Review and Open Challenges," *Ieee Access*, vol. 11, pp. 40741–40760, 2023, doi: 10.1109/access.2023.3250770.
- [17] A. Obeid, R. Ibrahim, and A. Fadhil, "Extended Model of Expectation Confirmation Model to Examine Users' Continuous Intention Toward the Utilization of E-Learning Platforms," *Ieee Access*, vol. 12, pp. 40752–40764, 2024, doi: 10.1109/access.2024.3373190.
- [18] H. Han, Z. Feng, W. Du, S. Guo, P. Wang, and T. Xu, "Remote Sensing Image Classification Based on Multi-Spectral Cross-Sensor Super-Resolution Combined With Texture Features: A Case Study in the Liaohé Planting Area," *Ieee Access*, vol. 12, pp. 16830–16843, 2024, doi: 10.1109/access.2024.3358812.
- [19] K. Katsarou, G. Yu, and F. Beierle, "WhatsApp: LSTM-Based Next-App Prediction With App Usage Sequences," *Ieee Access*, vol. 10, pp. 18233–18247, 2022, doi: 10.1109/access.2022.3150874.
- [20] B. Fu, Q. Shang, T. Sun, and S. Jia, "A Distracted Driving Detection Model Based on Driving Performance," *Ieee Access*, vol. 11, pp. 26624–26636, 2023, doi: 10.1109/access.2023.3257238.
- [21] Y. Zhang, Y. He, H. Zhang, J. Li, Y. Li, and J. Liu, "Classification Method of Voltage Sag Sources Based on Sequential Trajectory Feature Learning Algorithm," *Ieee Access*, vol. 10, pp. 38502–38510, 2022, doi: 10.1109/access.2022.3164675.
- [22] T. Xie, Q. Shang, and Y. Yu, "Automated Traffic Incident Detection: Coping With Imbalanced and Small Datasets," *Ieee Access*, vol. 10, pp. 35521–35540, 2022, doi: 10.1109/access.2022.3161835.