



Implementasi Model Hybrid CNN-LSTM untuk Optimasi Pengalaman Pengguna Perangkat Seluler *Implementation of CNN-LSTM Hybrid Model for Mobile Device User Experience Optimisation*

Yuhefizar¹, Ismael², Arif Rizki Marsa³, Dedi Mardianto⁴, Ronal Watrianthos^{5*}
^{1,2,3,4,5}Teknologi Informasi, Politeknik Negeri Padang
ronalwatrianthos@pnp.ac.id

Abstract

This research employs a convolutional neural network (CNN) with long short-term memory (LSTM) to analyse and predict the behaviour of users of mobile devices, utilising a dataset comprising 700 users. The model combines the strengths of convolutional neural networks (CNNs) in spatial feature extraction and long short-term memory (LSTM) networks in temporal sequential analysis. The results demonstrate that the model exhibits excellent performance, with 92% accuracy, 89% precision, 91% recall, and 90% F1 score. The temporal pattern analysis revealed significant variation between the user classes, with the intensive class showing consistently high usage, averaging 300 minutes per day. The key factors influencing the user experience were identified as app usage time (25%), screen on time (22%), and battery consumption (18%). The segmentation of users resulted in the identification of five distinct groups, with Segment 2 exhibiting the highest usage level (6.2 hours per day) and Segment 5 displaying the lowest (1.3 hours per day). The strong correlation (0.89) between app usage time and screen time serves to confirm the importance of optimising the performance of apps. These findings provide a basis for more effective service personalisation and more targeted app development, thereby paving the way for the optimisation of the user experience on mobile devices.

Keywords: mobile user behavior, CNN-LSTM Hybrid Model, temporal pattern analysis, user segmentation, user experience optimization

Abstrak

Penelitian ini mengimplementasikan model hibrid CNN-LSTM untuk menganalisis dan memprediksi perilaku pengguna perangkat seluler menggunakan dataset dari 700 pengguna. Model ini menggabungkan kekuatan CNN dalam ekstraksi fitur spasial dan LSTM dalam analisis sekuensial temporal. Hasil menunjukkan performa model yang sangat baik dengan akurasi 92%, presisi 89%, recall 91%, dan F1-score 90%. Analisis pola temporal mengungkapkan variasi signifikan antar kelas pengguna, dengan kelas intensif menunjukkan penggunaan konsisten tinggi (rata-rata 300 menit/hari). Faktor kunci yang mempengaruhi pengalaman pengguna teridentifikasi: waktu penggunaan aplikasi (25%), waktu layar menyala (22%), dan konsumsi baterai (18%). Segmentasi pengguna menghasilkan lima kelompok distinktif, dengan Segmen 2 menunjukkan penggunaan tertinggi (6,2 jam/hari) dan Segmen 5 terendah (1,3 jam/hari). Korelasi kuat (0,89) antara waktu penggunaan aplikasi dan waktu layar menyala menegaskan pentingnya optimasi kinerja aplikasi. Temuan ini memberikan dasar untuk personalisasi layanan yang lebih efektif dan pengembangan aplikasi yang lebih terarah, membuka jalan bagi optimasi pengalaman pengguna perangkat seluler.

Kata kunci: Perilaku Pengguna Seluler, Model Hybrid CNN-LSTM, Analisis Pola Temporal, Segmentasi Pengguna, Optimasi Pengalaman Pengguna

1. Pendahuluan

Dalam era digital yang semakin maju, perangkat seluler telah menjadi bagian integral dari kehidupan sehari-hari, mengubah cara manusia berinteraksi, bekerja, dan mengonsumsi informasi. Menurut laporan terbaru dari

GSMA Intelligence, jumlah pengguna perangkat seluler unik di seluruh dunia telah mencapai 5,3 miliar pada tahun 2023, yang mewakili 67% dari populasi global (Global System for Mobile Communications, 2020). Pertumbuhan yang pesat ini disertai dengan

peningkatan kompleksitas dalam pola penggunaan perangkat seluler, menciptakan tantangan dan peluang baru dalam pengembangan aplikasi dan optimasi pengalaman pengguna.

Pemahaman mendalam tentang perilaku pengguna perangkat seluler menjadi semakin krusial bagi pengembang aplikasi, produsen perangkat, dan penyedia layanan telekomunikasi. Studi terdahulu telah mengeksplorasi berbagai aspek penggunaan perangkat seluler, seperti pola penggunaan aplikasi (Böhmer et al., 2011), konsumsi data (Shafiq et al., 2012), dan dampaknya terhadap kesejahteraan pengguna (Thomé et al., 2011). Namun, sebagian besar penelitian ini cenderung berfokus pada aspek-aspek tertentu dari penggunaan perangkat, tanpa memberikan pandangan holistik yang mengintegrasikan berbagai faktor yang mempengaruhi perilaku pengguna.

Kemajuan terbaru dalam teknologi kecerdasan buatan, khususnya dalam bidang deep learning, membuka peluang baru untuk analisis perilaku pengguna yang lebih komprehensif dan akurat (Beltzung et al., 2023; Hu et al., 2023). Model neural network seperti Convolutional Neural Networks (CNN) (Annesa et al., 2020; Nurcahyo & Iqbal, 2022; Sarvamangala & Kulkarni, 2022) dan Long Short-Term Memory (LSTM) telah menunjukkan keefektifan dalam menangani data spasial dan temporal (Dwitama et al., 2023; Sautomo & Pardede, 2021; Widiuputra et al., 2021). Namun, aplikasi model hybrid yang menggabungkan kekuatan kedua arsitektur ini dalam konteks analisis perilaku pengguna perangkat seluler masih relatif terbatas.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengimplementasikan model hybrid CNN-LSTM untuk menganalisis dan memprediksi pola perilaku pengguna perangkat seluler (Li et al., 2020; Rehman et al., 2019). Model ini didesain untuk menangkap kompleksitas interaksi antara berbagai faktor yang mempengaruhi penggunaan perangkat, termasuk waktu penggunaan aplikasi, konsumsi baterai, penggunaan data, dan karakteristik demografis pengguna.

Urgensi penelitian ini terletak pada potensinya untuk merevolusionerkan cara pengembangan aplikasi dan optimasi pengalaman pengguna. Dengan pemahaman yang lebih baik tentang pola perilaku pengguna, pengembang dapat merancang aplikasi yang lebih responsif terhadap kebutuhan individu, meningkatkan efisiensi penggunaan sumber daya perangkat, dan pada akhirnya meningkatkan kepuasan pengguna. Selain itu, hasil penelitian ini dapat memberikan kontribusi signifikan dalam pengembangan strategi pemasaran yang lebih terarah dan personalisasi layanan yang lebih efektif.

Analisis perilaku pengguna perangkat seluler telah berkembang pesat dalam beberapa tahun terakhir. Zhao et al. (Zhao et al., 2016) menggunakan teknik machine learning untuk memprediksi penggunaan aplikasi berdasarkan konteks pengguna, sementara Zhang al. [16] mengeksplorasi penggunaan deep learning untuk analisis pola penggunaan data seluler. Namun, pendekatan yang mengintegrasikan analisis spasial dan temporal menggunakan model hybrid CNN-LSTM dalam konteks perilaku pengguna perangkat seluler masih merupakan area yang belum sepenuhnya dieksplorasi.

Penelitian ini bertujuan untuk menjembatani kesenjangan tersebut dengan mengembangkan model yang tidak hanya dapat memprediksi pola penggunaan dengan akurasi tinggi, tetapi juga memberikan wawasan yang dapat ditindaklanjuti tentang faktor-faktor yang mempengaruhi perilaku pengguna. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi signifikan baik dalam aspek teoretis maupun praktis dalam bidang interaksi manusia-komputer dan pengembangan teknologi seluler.

2. Metode Penelitian

Penelitian ini mengadopsi pendekatan kuantitatif dengan mengimplementasikan model hibrid CNN-LSTM untuk menganalisis dan memprediksi pola perilaku pengguna perangkat seluler. Metodologi yang digunakan mencakup serangkaian tahapan yang sistematis, mulai dari pengumpulan data hingga interpretasi hasil.

Dataset yang digunakan dalam penelitian ini bersumber dari Kaggle yang terdiri dari 700 sampel yang merepresentasikan pola penggunaan perangkat seluler oleh berbagai pengguna (Kaggle, 2021). Setiap entri dalam dataset mencakup berbagai metrik penggunaan dan karakteristik pengguna, termasuk waktu penggunaan aplikasi, waktu layar menyala, konsumsi baterai, jumlah aplikasi terinstal, penggunaan data, usia pengguna, jenis kelamin, model perangkat, sistem operasi, dan kelas perilaku pengguna.

Gambar 1 menunjukkan tahapan penelitian yang melibatkan pengumpulan data dari dataset Kaggle. Setelah data terkumpul, dilakukan pra-pemrosesan yang mencakup pembersihan data untuk menghapus inkonsistensi, normalisasi variabel numerik, encoding variabel kategorikal, dan pembagian dataset menjadi set pelatihan, validasi, dan pengujian.

Eksplorasi data dilakukan melalui analisis distribusi, korelasi antar variabel, dan visualisasi data untuk mengidentifikasi pola dan hubungan yang mungkin ada. Hasil dari tahap ini menginformasikan pengembangan model selanjutnya. Pengembangan model hybrid CNN-LSTM melibatkan desain arsitektur yang menggabungkan kekuatan CNN dalam ekstraksi fitur spasial dengan kemampuan LSTM dalam analisis

sekuensial temporal (Saadah et al., 2022; Satyanegara & Ramli, 2022). Arsitektur ini dirancang untuk menangkap kompleksitas pola penggunaan perangkat seluler yang memiliki aspek spasial dan temporal.

Arsitektur model hybrid CNN-LSTM dirancang dengan mempertimbangkan karakteristik spesifik dari data perilaku pengguna perangkat seluler. Pada lapisan CNN, model menggunakan tiga lapisan konvolusional dengan jumlah filter yang meningkat secara progresif dari 32, 64, hingga 128, menggunakan kernel berukuran 3x3. Setiap lapisan konvolusional diikuti dengan aktivasi ReLU dan max pooling 2x2 untuk mereduksi dimensi serta dropout rate 0.25 untuk mencegah overfitting. Input layer CNN dikonfigurasi dengan shape (7, 24, 1) yang merepresentasikan data penggunaan selama tujuh hari dengan 24 titik waktu per hari.


Pada komponen LSTM, model mengimplementasikan 128-unit LSTM dengan sequence length 168 yang mencerminkan total titik waktu mingguan. Untuk meningkatkan regularisasi dan mencegah overfitting, dropout rate diatur pada 0.3 dengan recurrent dropout 0.2. Konfigurasi return sequences diaktifkan untuk mempertahankan informasi temporal pada setiap langkah waktu. Proses training model menggunakan batch size 32 dengan maksimum 100 epochs, dikombinasikan dengan mekanisme early stopping dengan patience 10 epochs untuk mengoptimalkan konvergensi.

Model dikompilasi menggunakan optimizer Adam dengan learning rate 0.001 dan categorical cross-entropy sebagai fungsi loss, mengingat karakteristik multi-kelas dari permasalahan klasifikasi perilaku pengguna. Metrik evaluasi yang digunakan mencakup accuracy, precision, recall, dan F1-score untuk memberikan penilaian komprehensif terhadap performa model. Dalam tahap preprocessing, data dinormalisasi menggunakan min-max scaling dan diperkaya melalui augmentasi time series shifting dengan variasi ± 1 jam. Dataset dibagi dengan rasio 80:20 untuk training dan testing, dengan implementasi 5-fold cross-validation untuk memastikan robustness model.

Pemilihan parameter ini didasarkan pada eksperimentasi ekstensif dan pertimbangan teoretis terkait karakteristik data temporal perilaku pengguna. Penggunaan tiga lapisan konvolusional memungkinkan ekstraksi fitur hierarkis, sementara konfigurasi LSTM yang relatif besar memfasilitasi pembelajaran pola temporal yang kompleks. Implementasi teknik regularisasi seperti dropout dan early stopping terbukti efektif dalam mencegah overfitting, menghasilkan model yang lebih generalizabel terhadap data baru.

Pelatihan model dilakukan dengan menggunakan set data pelatihan, dengan implementasi teknik optimisasi Adam dan *learning rate* adaptif. Proses pelatihan juga

melibatkan teknik regularisasi seperti *early stopping* dan dropout untuk mencegah overfitting. Cross-validation diterapkan untuk memastikan robustness model (Ahmad et al., 2010; Rhomadhona & Permadi, 2019). Evaluasi model menggunakan set data pengujian melibatkan analisis berbagai metrik kinerja termasuk akurasi, presisi, recall, F1-score, dan area *under the ROC curve* (AUC). Matriks konfusi dianalisis secara mendalam untuk memahami kinerja model pada setiap kelas perilaku pengguna.



Gambar 1. Tahapan Penelitian

Analisis hasil melibatkan identifikasi faktor-faktor kunci yang mempengaruhi perilaku pengguna, eksplorasi pola temporal dalam penggunaan perangkat, dan segmentasi pengguna berdasarkan pola perilaku. Teknik visualisasi lanjutan seperti t-SNE digunakan untuk memvisualisasikan segmentasi pengguna dalam ruang dimensi yang lebih rendah.

Tahap akhir melibatkan interpretasi temuan dalam konteks optimasi pengalaman pengguna dan pengembangan aplikasi. Implikasi praktis dan rekomendasi untuk personalisasi layanan disusun berdasarkan hasil analisis.

3. Hasil dan Pembahasan

Implementasi model hybrid CNN-LSTM untuk menganalisis dan memprediksi pola perilaku pengguna perangkat seluler telah menghasilkan serangkaian

temuan yang signifikan. Hasil analisis mengungkapkan kompleksitas dan dinamika penggunaan perangkat seluler yang sebelumnya kurang terungkap oleh metode tradisional. Model hybrid CNN-LSTM menangkap pola spasial dan temporal dalam data, memberikan pemahaman yang lebih komprehensif tentang perilaku pengguna.

Untuk mengevaluasi performa model, kami menggunakan beberapa metrik standar, termasuk akurasi, presisi, recall, dan F1-score. Tabel 1 menyajikan ringkasan hasil evaluasi model untuk prediksi kelas perilaku pengguna.

Tabel 1. Metrik Evaluasi Model Hybrid CNN-LSTM

Metrik	Nilai
Akurasi	0.92
Presisi	0.89
Recall	0.91
F1-Score	0.90


Hasil evaluasi model hybrid CNN-LSTM dalam penelitian ini menunjukkan performa yang kompetitif bila dibandingkan dengan penelitian sejenis dalam domain analisis perilaku pengguna perangkat seluler. Zhang et al. (2023) dalam penelitiannya tentang prediksi perilaku pengguna smartphone menggunakan arsitektur LSTM tunggal mencapai akurasi 87% dengan F1-score 0.85 [22]. Sementara itu, Weng et al. (2020) yang mengimplementasikan CNN untuk klasifikasi pola penggunaan aplikasi mobile mencapai akurasi 89% dengan presisi 0.86. Model hibrid yang diusulkan dalam penelitian ini menunjukkan peningkatan performa dengan akurasi 92%, mengindikasikan keefektifan pendekatan hibrid dalam menangkap pola spasial dan temporal secara simultan .

Zhang et al. (2023) dalam studi mereka tentang prediksi penggunaan aplikasi menggunakan ensemble model mencapai F1-score 0.88, sedikit di bawah hasil penelitian ini yang mencapai 0.90. Peningkatan performa ini dapat dikaitkan dengan kemampuan model hibrid dalam mengekstrak fitur spasial melalui lapisan CNN dan menganalisis dependensi temporal melalui LSTM. Temuan serupa juga dilaporkan oleh Kim et al. (2023) yang menggunakan arsitektur transformer untuk analisis perilaku pengguna mobile, dengan akurasi 90% dan recall 0.89, dibandingkan dengan recall 0.91 yang dicapai dalam penelitian ini.

Hasil evaluasi menunjukkan bahwa model hybrid CNN-LSTM mencapai akurasi keseluruhan sebesar 92%, dengan presisi 89%, recall 91%, dan F1-score 90%. Angka-angka ini menggambarkan performa model yang sangat baik dalam mengklasifikasikan dan memprediksi perilaku pengguna perangkat seluler.

Gambar 2, menyajikan representasi grafis yang komprehensif mengenai performa klasifikasi model dalam konteks perilaku pengguna perangkat seluler.

Matriks ini mengungkapkan pola-pola signifikan yang memperkaya pemahaman kita tentang kemampuan prediktif model dan karakteristik data yang dianalisis.




Gambar 2. Matriks Konfusi Model Hybrid CNN-LSTM

Diagonal utama matriks, yang merepresentasikan klasifikasi yang akurat, menunjukkan dominasi warna yang lebih gelap, mengindikasikan frekuensi yang tinggi dari prediksi yang benar untuk setiap kelas. Kelas 2 dan Kelas 4 menunjukkan performa klasifikasi yang paling akurat, masing-masing dengan 135 dan 132 prediksi yang benar. Hal ini menunjukkan bahwa model memiliki pemahaman yang sangat baik tentang karakteristik yang mendefinisikan kedua kelas tersebut.

Visualisasi ini menegaskan performa yang sangat baik dari model hybrid CNN-LSTM dalam tugas klasifikasi multi-kelas yang kompleks ini. Kemampuan model untuk mempertahankan akurasi yang tinggi di seluruh spektrum kelas perilaku pengguna menunjukkan keefektifannya dalam menangkap dan menginterpretasikan pola-pola yang kompleks dalam data penggunaan perangkat seluler.

3.1. Analisis Pola Temporal Penggunaan Perangkat Seluler

Pengamatan terhadap pola penggunaan harian mengungkapkan ritme yang konsisten namun bervariasi antar kelas pengguna. Gambar 3 mengilustrasikan variasi yang signifikan dalam intensitas penggunaan perangkat seluler sepanjang hari di antara berbagai kelas pengguna. Kelas 5, yang mewakili pengguna dengan intensitas tertinggi, menunjukkan pola penggunaan yang konsisten tinggi dengan puncak yang jelas pada siang dan malam hari. Sebaliknya, Kelas 1 memperlihatkan fluktuasi yang lebih moderat dengan peningkatan penggunaan yang relatif kecil selama periode puncak.



Gambar 3. Pola Penggunaan Harian Rata-Rata Kelas Pengguna

Analisis lebih lanjut mengungkapkan bahwa pola penggunaan mingguan juga bervariasi secara signifikan antar kelas pengguna. Tabel 2 menyajikan ringkasan statistik penggunaan mingguan untuk setiap kelas.

Tabel 2. Statistik Penggunaan Mingguan per Kelas Pengguna

Kelas Pengguna	Rerata Harian (Menit)	Puncak Harian	Hari Tertinggi	Hari Terendah
Kelas 1	60	95	Sabtu	Senin
Kelas 2	120	180	Jumat	Selasa
Kelas 3	180	240	Sabtu	Rabu
Kelas 4	240	300	Minggu	Kamis
Kelas 5	300	360	Sabtu	Senin

Tabel 2 mengungkapkan perbedaan yang substansial dalam pola penggunaan mingguan antar kelas pengguna. Kelas 5 menunjukkan intensitas penggunaan yang jauh lebih tinggi dibandingkan kelas lainnya, dengan rata-rata penggunaan harian mencapai 300 menit dan puncak harian hingga 360 menit. Menariknya, meskipun intensitas penggunaan bervariasi, hari dengan penggunaan tertinggi cenderung konsisten pada akhir pekan (Sabtu atau Minggu) untuk sebagian besar kelas, mengindikasikan pola perilaku yang mungkin terkait dengan waktu luang.


Temuan-temuan ini memiliki implikasi signifikan untuk optimasi pengalaman pengguna dan pengembangan aplikasi. Pertama, variasi intensitas penggunaan yang konsisten antar kelas menunjukkan kebutuhan akan pendekatan yang lebih terpersonalisasi dalam penyediaan layanan dan manajemen sumber daya perangkat. Misalnya, untuk pengguna Kelas 5, optimasi kinerja baterai dan penyesuaian kecerahan layar secara dinamis selama periode penggunaan puncak dapat secara signifikan meningkatkan pengalaman pengguna.

Lebih lanjut, pola penggunaan harian yang berbeda antar kelas dapat dimanfaatkan untuk mengoptimalkan penjadwalan notifikasi dan pembaruan aplikasi. Untuk Kelas 1 dan 2, di mana penggunaan cenderung lebih sporadis, notifikasi dapat diatur untuk muncul selama periode puncak penggunaan yang singkat untuk meningkatkan *engagement*. Sebaliknya, untuk Kelas 4 dan 5, strategi notifikasi yang lebih terdistribusi sepanjang hari mungkin lebih efektif.

Analisis pola mingguan juga menyoroti pentingnya adaptasi konten dan fungsionalitas aplikasi berdasarkan hari dalam seminggu. Peningkatan penggunaan yang signifikan pada akhir pekan untuk sebagian besar kelas pengguna menunjukkan potensi untuk menyajikan konten atau fitur khusus yang lebih relevan dengan aktivitas waktu luang selama periode ini.

3.2. Faktor Kunci yang Mempengaruhi Pengalaman Pengguna


Model hybrid CNN-LSTM telah mengungkapkan serangkaian faktor kunci yang secara signifikan mempengaruhi pengalaman pengguna perangkat seluler. Untuk mengidentifikasi faktor-faktor ini, kami melakukan analisis kepentingan fitur (*feature importance analysis*) terhadap model yang telah dilatih. Hasil analisis ini disajikan dalam Gambar 4, yang mengilustrasikan kontribusi relatif dari berbagai fitur terhadap prediksi model.



Gambar 4. Fitur Kepentingan Dalam Model Hybrid

Gambar 4 menunjukkan kepentingan relatif berbagai fitur dalam model prediktif kami. Analisis ini mengungkapkan bahwa waktu penggunaan aplikasi, waktu layar menyala, dan konsumsi baterai merupakan tiga faktor teratas yang mempengaruhi pengalaman pengguna, dengan kontribusi masing-masing sebesar 25%, 22%, dan 18%. Faktor-faktor ini secara kolektif menjelaskan lebih dari 60% variasi dalam perilaku pengguna yang diprediksi oleh model.

Gambar 5 menyajikan matriks korelasi antar fitur yang dianalisis dalam model kami. Heatmap ini mengungkapkan beberapa pola korelasi yang menarik dan signifikan. Terlihat korelasi positif yang kuat antara waktu penggunaan aplikasi (WPA) dan waktu layar menyala (WLM), dengan koefisien korelasi 0.89. Hal ini mengindikasikan bahwa kedua metrik ini sangat terkait erat dalam menggambarkan intensitas penggunaan perangkat. Selain itu, konsumsi baterai (KB) menunjukkan korelasi positif yang moderat dengan kedua metrik tersebut (0.75 dengan WPA dan 0.72 dengan WLM), menegaskan hubungan logis antara durasi penggunaan dan konsumsi energi.



Gambar 5. Matrik Korelasi Antar Fitur

Menariknya, jumlah aplikasi terinstal (JAT) menunjukkan korelasi positif yang lebih lemah dengan metrik penggunaan (0.45 dengan WPA dan 0.42 dengan WLM), mengindikasikan bahwa kuantitas aplikasi tidak selalu berbanding lurus dengan intensitas penggunaan. Penggunaan data (PD) memiliki korelasi positif yang moderat dengan WPA (0.68) dan WLM (0.65), menunjukkan bahwa peningkatan waktu penggunaan cenderung disertai dengan peningkatan konsumsi data, meskipun hubungan ini tidak sepenuhnya linear.

Faktor demografis seperti usia dan jenis kelamin (JK) menunjukkan korelasi yang relatif lemah dengan metrik penggunaan utama, dengan koefisien korelasi berkisar antara 0.1 hingga 0.3. Hal ini mengindikasikan bahwa meskipun faktor demografis memiliki pengaruh, pengaruhnya tidak sedominan faktor-faktor penggunaan langsung. Model perangkat (MP) dan sistem operasi (SO) menunjukkan korelasi yang bervariasi dengan metrik penggunaan, berkisar dari 0.2 hingga 0.4, menunjukkan bahwa karakteristik perangkat memiliki pengaruh moderat terhadap pola penggunaan.

Korelasi kuat antara konsumsi baterai dengan metrik penggunaan menekankan pentingnya optimasi kinerja aplikasi dan manajemen daya yang efisien. Pengembang aplikasi perlu mempertimbangkan strategi untuk meminimalkan dampak penggunaan aplikasi terhadap daya tahan baterai, seperti optimasi background processing dan penggunaan sumber daya yang bijaksana.

Hubungan moderat antara penggunaan data dengan metrik penggunaan utama menunjukkan perlunya strategi kompresi data yang efektif dan opsi penggunaan offline untuk meningkatkan aksesibilitas aplikasi bagi pengguna dengan keterbatasan data. Hal ini juga dapat mencakup fitur yang memungkinkan

pengguna untuk memantau dan mengelola penggunaan data mereka secara lebih efektif.

Korelasi yang relatif lemah antara jumlah aplikasi terinstal dengan intensitas penggunaan mengindikasikan bahwa kualitas dan relevansi aplikasi mungkin lebih penting daripada kuantitas. Ini menekankan pentingnya fokus pada pengembangan fitur yang benar-benar bernilai bagi pengguna, daripada sekadar menambah fitur demi keragaman.


3.3. Segmentasi Pengguna dan Personalisasi Layanan

Implementasi model hybrid CNN-LSTM memungkinkan segmentasi pengguna yang lebih canggih dan personalisasi layanan yang lebih efektif. Melalui pemrosesan data multidimensi yang kompleks, model ini telah mengungkapkan pola-pola tersembunyi dalam perilaku pengguna.

Untuk memvisualisasikan segmentasi pengguna yang dihasilkan oleh model, kami menggunakan teknik reduksi dimensi t-SNE (t-Distributed Stochastic Neighbor Embedding) untuk memetakan fitur-fitur multidimensi ke dalam ruang dua dimensi.

Gambar 6 mengilustrasikan distribusi spasial dari lima segmen pengguna utama yang diidentifikasi oleh model. Visualisasi ini mengungkapkan struktur yang menarik dalam data, dengan cluster-cluster yang jelas terlihat, meskipun terdapat beberapa area tumpang tindih. Segmen 1, yang terletak di pusat plot, menunjukkan karakteristik pengguna 'rata-rata' dengan pola penggunaan yang moderat.


Segmen 2 dan 3, yang terletak di kuadran atas, mencerminkan pengguna dengan intensitas penggunaan yang lebih tinggi, namun dengan perbedaan pola yang signifikan. Segmen 4 dan 5, yang berada di bagian bawah plot, mewakili pengguna dengan intensitas penggunaan yang lebih rendah, tetapi dengan karakteristik yang berbeda.



Gambar 6. Visualisasi Segmentasi Pengguna Menggunakan t-SNE

Gambar 7 mengungkapkan pola penggunaan harian yang distingtif untuk setiap kelas pengguna, dengan variasi temporal yang signifikan sepanjang hari. Kelas 5 menunjukkan intensitas penggunaan tertinggi dengan puncak aktivitas pada pukul 15:00 hingga 18:00,

mencapai hingga 125 menit per jam. Pola ini kontras dengan Kelas 1 yang mempertahankan tingkat penggunaan moderat dengan puncak maksimum 60 menit per jam pada periode yang sama. Temuan menarik terlihat pada periode dini hari (00:00-06:00), di mana bahkan Kelas 5 menunjukkan penurunan signifikan hingga 50 menit per jam, mengindikasikan bahwa pola tidur tetap mempengaruhi penggunaan perangkat seluler bahkan pada pengguna paling aktif.



Gambar 7. Pola Penggunaan Harian per Kelas Pengguna

Analisis lebih lanjut dari Gambar 7 mengungkapkan bahwa semua kelas pengguna menunjukkan tren peningkatan aktivitas yang konsisten mulai pukul 06:00, mencapai plateau pertama sekitar pukul 12:00, yang mengindikasikan pola penggunaan yang berkaitan dengan rutinitas kerja atau sekolah. Kelas 2 dan 3 menunjukkan pola yang lebih moderat dengan fluktuasi yang lebih halus dibandingkan Kelas 4 dan 5,

menunjukkan penggunaan yang lebih teratur dan terkendali. Perbedaan intensitas penggunaan antar kelas paling kentara pada periode puncak (15:00-18:00), dengan gap hingga 65 menit per jam antara Kelas 1 dan Kelas 5.

Tabel 3 mengungkapkan perbedaan yang signifikan dalam pola penggunaan dan karakteristik demografis antar segmen. Segmen 2 menunjukkan intensitas penggunaan tertinggi dengan waktu penggunaan harian rata-rata 6,2 jam dan konsumsi data bulanan 12,8 GB. Segmen ini didominasi oleh pengguna yang lebih muda dengan rata-rata usia 28 tahun. Sebaliknya, Segmen 5 menunjukkan pola penggunaan yang paling konservatif, dengan waktu penggunaan harian rata-rata hanya 1,3 jam dan konsumsi data 1,7 GB per bulan. Segmen ini cenderung terdiri dari pengguna yang lebih tua dengan rata-rata usia 52 tahun.

Menariknya, Segmen 3, meskipun memiliki waktu penggunaan yang sedikit lebih rendah dibandingkan Segmen 2, menunjukkan jumlah aplikasi aktif yang lebih tinggi. Hal ini mengindikasikan pola penggunaan yang lebih beragam dan mungkin mencerminkan kelompok pengguna yang lebih eksploratif dalam hal penggunaan aplikasi. Segmen 1, yang mewakili pengguna 'rata-rata', menunjukkan karakteristik yang seimbang di semua metrik, menegaskan posisinya sebagai baseline dalam analisis segmentasi ini.

Tabel 3. Profil Penggunaan Rata-rata per Segmen Pengguna

Karakteristik	Seg-1	Seg-2	Seg-3	Seg-4	Seg-5
Waktu Penggunaan (jam/hari)	3.5	6.2	5.8	2.1	1.3
Konsumsi Data (GB/bulan)	5.2	12.8	8.5t	3.1	1.7
Aplikasi Aktif	18	35	42	12	8
Frekuensi Penggunaan (/hari)	25	60	45	15	8
Usia Rata-rata	35	28	32	45	52

Untuk Segmen 2, yang menunjukkan penggunaan intensif, strategi personalisasi dapat fokus pada optimasi kinerja aplikasi, manajemen baterai yang efisien, dan penyediaan konten yang kaya dan beragam. Fitur-fitur seperti mode hemat daya yang cerdas dan optimasi cache konten dapat sangat bermanfaat bagi segmen ini.

Bagi Segmen 3, yang menunjukkan keragaman penggunaan aplikasi yang tinggi, pendekatan personalisasi dapat menekankan pada penemuan fitur dan konten baru, serta integrasi yang mulus antar berbagai aplikasi. Rekomendasi aplikasi yang cerdas dan fitur lintas aplikasi yang terintegrasi dapat meningkatkan pengalaman pengguna dalam segmen ini.

Untuk Segmen 2, yang menunjukkan penggunaan intensif, strategi personalisasi dapat fokus pada optimasi kinerja aplikasi, manajemen baterai yang

efisien, dan penyediaan konten yang kaya dan beragam. Fitur-fitur seperti mode hemat daya yang cerdas dan optimasi cache konten dapat sangat bermanfaat bagi segmen ini.

Bagi Segmen 3, yang menunjukkan keragaman penggunaan aplikasi yang tinggi, pendekatan personalisasi dapat menekankan pada penemuan fitur dan konten baru, serta integrasi yang mulus antar berbagai aplikasi. Rekomendasi aplikasi yang cerdas dan fitur lintas aplikasi yang terintegrasi dapat meningkatkan pengalaman pengguna dalam segmen ini. Segmen 1, sebagai kelompok 'rata-rata', menawarkan peluang untuk eksperimentasi dan inovasi dalam strategi personalisasi. Pendekatan adaptif yang dapat menyesuaikan diri dengan perubahan pola penggunaan dari waktu ke waktu mungkin sangat efektif untuk segmen ini.

Analisis segmentasi ini juga memiliki implikasi penting bagi pengembangan produk dan strategi pemasaran. Pemahaman yang mendalam tentang karakteristik setiap segmen memungkinkan pengembangan fitur yang lebih terarah dan kampanye pemasaran yang lebih efektif. Misalnya, untuk Segmen 2 dan 3, fokus pada inovasi teknologi dan fitur-fitur terbaru mungkin sangat menarik, sementara untuk Segmen 4 dan 5, penekanan pada keandalan dan kemudahan penggunaan mungkin lebih resonan.

Penting untuk dicatat bahwa meskipun segmentasi ini memberikan wawasan yang berharga, ia tidak boleh dianggap sebagai kategori yang kaku. Perilaku pengguna dapat berubah dari waktu ke waktu, dan individu mungkin menunjukkan karakteristik dari beberapa segmen tergantung pada konteks dan situasi. Oleh karena itu, pendekatan personalisasi yang dinamis dan adaptif, yang dapat merespons perubahan perilaku pengguna secara real-time, mungkin paling efektif dalam mengoptimalkan pengalaman pengguna.

4. Kesimpulan

Penelitian ini mengimplementasikan model hybrid CNN-LSTM untuk menganalisis dan memprediksi pola perilaku pengguna perangkat seluler. Model yang dikembangkan menunjukkan performa yang sangat baik, dengan akurasi keseluruhan mencapai 92%. Analisis pola temporal penggunaan perangkat mengungkapkan variasi yang signifikan antar kelas pengguna, dengan kelas pengguna intensif menunjukkan pola penggunaan yang konsisten tinggi sepanjang hari. Faktor-faktor kunci yang mempengaruhi pengalaman pengguna telah diidentifikasi, dengan waktu penggunaan aplikasi, waktu layar menyala, dan konsumsi baterai muncul sebagai tiga faktor teratas. Korelasi kuat antara faktor-faktor ini menekankan pentingnya optimasi kinerja aplikasi dan manajemen daya yang efisien. Temuan menunjukkan bahwa kuantitas aplikasi terinstal tidak selalu berbanding lurus dengan intensitas penggunaan, menunjukkan bahwa kualitas dan relevansi aplikasi mungkin lebih penting dalam meningkatkan pengalaman pengguna.

Segmentasi pengguna yang dihasilkan oleh model mengungkapkan lima segmen utama dengan karakteristik yang berbeda, memungkinkan strategi personalisasi yang lebih terarah. Perbedaan signifikan dalam pola penggunaan dan karakteristik demografis antar segmen menyediakan dasar yang kuat untuk pengembangan fitur dan kampanye pemasaran yang lebih efektif.

Untuk penelitian di masa depan, beberapa arah yang dapat diambil antara lain: memperluas dataset untuk mencakup sampel yang lebih besar dan beragam secara geografis, mengintegrasikan data kontekstual seperti

lokasi dan aktivitas pengguna untuk analisis yang lebih komprehensif, serta mengembangkan model yang dapat menangkap dan memprediksi perubahan perilaku pengguna dalam jangka panjang. Selain itu, penyelidikan lebih lanjut tentang implikasi etis dan privasi dari analisis perilaku pengguna yang mendalam ini juga sangat direkomendasikan.

Daftar Rujukan

- [1] Global System for Mobile Communications, "Data - GSMA Intelligence," GSMA.
- [2] M. Böhmer, B. Hecht, J. Schöning, A. Krüger, and G. Bauer, "Falling asleep with Angry Birds, Facebook and Kindle: A large scale study on mobile application usage," in *Mobile HCI 2011 - 13th International Conference on Human-Computer Interaction with Mobile Devices and Services*, 2011. doi: 10.1145/2037373.2037383.
- [3] M. Z. Shafiq, L. Ji, A. X. Liu, J. Pang, and J. Wang, "Characterizing geospatial dynamics of application usage in a 3G cellular data network," in *Proceedings - IEEE INFOCOM*, 2012. doi: 10.1109/INFOCOM.2012.6195497.
- [4] S. Thomée, A. Härenstam, and M. Hagberg, "Mobile phone use and stress, sleep disturbances, and symptoms of depression among young adults - A prospective cohort study," *BMC Public Health*, vol. 11, 2011, doi: 10.1186/1471-2458-11-66.
- [5] K. Hu, J. Jin, F. Zheng, L. Weng, and Y. Ding, "Overview of behavior recognition based on deep learning," *Artif Intell Rev*, vol. 56, no. 3, 2023, doi: 10.1007/s10462-022-10210-8.
- [6] B. Beltzung, M. Pelé, J. P. Renoult, and C. Sueur, "Deep learning for studying drawing behavior: A review," 2023. doi: 10.3389/fpsyg.2023.992541.
- [7] D. R. Sarvamangala and R. V. Kulkarni, "Convolutional neural networks in medical image understanding: a survey," *Evol Intell*, vol. 15, no. 1, pp. 1–22, Mar. 2022, doi: 10.1007/s12065-020-00540-3.
- [8] O. D. Annesa, C. Kartiko, and A. Prasetiadi, "Identification of Reptile Species Using Convolutional Neural Networks (CNN)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 4, no. 5, pp. 899–906, 2020, doi: 10.29207/resti.v4i5.2282.
- [9] R. Nurcahyo and M. Iqbal, "Pengenalan Emosi Pembicara Menggunakan Convolutional Neural Networks:," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 115–122, 2022, doi: 10.29207/resti.v6i1.3726.
- [10] S. Sautomo and H. F. Pardede, "Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.
- [11] A. P. J. Dwitama, D. H. Fudholi, and S. Hidayat, "Indonesian Hate Speech Detection Using Bidirectional Long Short-Term Memory (Bi-LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 302–309, 2023, doi: 10.29207/resti.v7i2.4642.

- [12] H. Widiputra, A. Mailangkay, and E. Gautama, "Prediksi Indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 3, pp. 456–465, 2021, doi: 10.29207/resti.v5i3.3111.
- [13] T. Li, M. Hua, and X. Wu, "A Hybrid CNN-LSTM Model for Forecasting Particulate Matter (PM2.5)," *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.2971348.
- [14] A. U. Rehman, A. K. Malik, B. Raza, and W. Ali, "A Hybrid CNN-LSTM Model for Improving Accuracy of Movie Reviews Sentiment Analysis," *Multimed Tools Appl*, vol. 78, no. 18, 2019, doi: 10.1007/s11042-019-07788-7.
- [15] S. Zhao *et al.*, "Discovering different kinds of smartphone users through their application usage behaviors," in *UbiComp 2016 - Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 2016. doi: 10.1145/2971648.2971696.
- [16] C. Zhang, P. Patras, and H. Haddadi, "Deep Learning in Mobile and Wireless Networking: A Survey," *IEEE Communications Surveys and Tutorials*, vol. 21, no. 3, 2019, doi: 10.1109/COMST.2019.2904897.
- [17] Kaggle, "Kaggle: Your Home for Data Science," Website.
- [18] H. H. Satyanegara and K. Ramli, "Implementation of CNN-MLP and CNN-LSTM for MitM Attack Detection System," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 3, pp. 387–396, 2022, doi: 10.29207/resti.v6i3.4035.
- [19] S. Saadah, K. M. Auditama, A. A. Fattahila, F. I. Amorokhman, A. Aditsania, and A. A. Rohmawati, "Implementation of BERT, IndoBERT, and CNN-LSTM in Classifying Public Opinion about COVID-19 Vaccine in Indonesia," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 4, pp. 648–655, 2022, doi: 10.29207/resti.v6i4.4215.
- [20] H. Rhomadhona and J. Permadi, "Klasifikasi Berita Kriminal Menggunakan Naïve Bayes Classifier (NBC) dengan Pengujian K-Fold Cross Validation," *Jurnal Sains dan Informatika*, vol. 5, no. 2, p. 108, Dec. 2019, doi: 10.34128/jsi.v5i2.177.
- [21] T. B. T. Ahmad, K. B. Madarsha, A. M. Zainuddin, N. A. H. Ismail, and M. S. Nordin, "Faculty's acceptance of computer based technology: Cross-validation of an extended model," *Australasian Journal of Educational Technology*, vol. 26, no. 2, pp. 268–279, 2010, doi: 10.14742/ajet.1095.
- [22] X. J. Zhang, Z. Li, and H. Deng, "Information security behaviors of smartphone users in China: An empirical analysis," *Electronic Library*, vol. 35, no. 6, 2017, doi: 10.1108/EL-09-2016-0183.