

Sistem Rekomendasi Warna Kontekstual untuk Desain UI/UX Menggunakan *Random Forest*

Agita Nurfadillah¹, Roni Andarsyah², Rolly Maulana Awangga³

^{1,2,3} Jurusan Teknik Informatika, Fakultas Sekolah Vokasi, Universitas Logistik dan Bisnis Internasional

Jl. Sariosih No.54, Sarijadi, Kec. Sukasari, Kota Bandung, Jawa Barat 40151

Email: agitanurfadillah45@gmail.com, roniandarsyah@ulbi.ac.id, awangga@ulbi.ac.id

ABSTRAK

Pemilihan warna dalam desain antarmuka pengguna (UI/UX) memegang peranan penting dalam menciptakan pengalaman visual yang konsisten dan menarik. Namun, proses pemilihan warna masih sering didasarkan pada intuisi subjektif. Penelitian ini mengembangkan sistem rekomendasi warna kontekstual berdasarkan kategori aplikasi, menggunakan algoritma *Random Forest*. Dataset diperoleh dari Dribbble dan Kaggle, mencakup fitur warna RGB, HSL, serta fitur turunan lainnya. Proses pengembangan sistem mengikuti tahapan ADDIE, dimulai dari analisis hingga evaluasi performa. Eksperimen dilakukan dengan tahapan rekayasa fitur, pemilihan fitur, tuning parameter (*GridSearchCV*), serta penyeimbangan data menggunakan SMOTE. Model terbaik menghasilkan akurasi sebesar 39,2% dan menunjukkan peningkatan pada kategori aplikasi edukatif setelah balancing. Sistem ini diimplementasikan dalam bentuk dashboard interaktif berbasis Streamlit, memungkinkan pengguna memilih kategori aplikasi dan memperoleh rekomendasi warna secara visual. Penelitian ini merupakan kontribusi awal dalam integrasi klasifikasi warna berbasis konteks ke dalam proses desain UI digital, sebagai solusi berbasis data yang dapat mengurangi ketergantungan pada intuisi subjektif.

Kata kunci: Rekomendasi Warna, Desain UI/UX, *Machine Learning*, *Random Forest*, Klasifikasi Warna, *Streamlit*

ABSTRACT

Color selection in user interface (UI/UX) design is vital in creating a consistent and attractive visual experience. However, the color selection process is still often based on subjective intuition. This study uses the Random Forest algorithm to develop a contextual color recommendation system based on application categories. The dataset was obtained from Dribbble and Kaggle, and it included RGB and HSL color features and derived features. The system development process followed the ADDIE framework, from analysis to performance evaluation. Experiments were conducted through feature engineering, feature selection, parameter tuning (GridSearchCV), and data balancing using SMOTE. The best model achieved an accuracy of 39.2% and showed improvement in the educational application category after balancing. The system is implemented as an interactive dashboard based on Streamlit, allowing users to select application categories and receive visual color recommendations. This research is an initial contribution to integrating context-based color classification into the digital UI design process, as a data-driven solution that can reduce reliance on subjective intuition.

Keywords: *Color Recommendation, UI/UX Design, Machine Learning, Random Forest, Color Classification, Streamlit*

Pendahuluan

Warna merupakan salah satu elemen visual yang sangat penting dalam desain antarmuka pengguna (UI) dan pengalaman pengguna (UX). Pemilihan warna yang tepat dapat membentuk persepsi, emosi, bahkan keputusan pengguna dalam menggunakan sebuah aplikasi. Warna juga berfungsi sebagai media komunikasi visual yang mampu menarik perhatian, memperkuat identitas visual, serta meningkatkan kenyamanan penggunaan sistem[1].

Dalam konteks digital, warna tidak hanya memiliki fungsi estetika, tetapi juga berdampak langsung terhadap efektivitas interaksi pengguna. Meskipun demikian, proses pemilihan warna dalam desain UI/UX masih banyak bergantung pada intuisi subjektif. Pendekatan seperti ini berisiko menghasilkan desain yang tidak konsisten dan tidak responsif terhadap karakteristik pengguna maupun konteks aplikasi. Beberapa pengguna mungkin merasa kesulitan mengenali elemen penting dalam antarmuka, atau merasa tidak nyaman dengan kontras warna yang digunakan. Ketidaksesuaian ini dapat menurunkan pengalaman pengguna dan efektivitas sistem secara keseluruhan[2].

Untuk mengatasi tantangan tersebut, pendekatan berbasis data dan algoritma mulai banyak digunakan dalam mendukung pengambilan keputusan desain. Salah satu pendekatan yang menjanjikan adalah pemanfaatan algoritma machine learning. Dengan mengolah data warna dari berbagai antarmuka aplikasi dan mempelajari pola pemilihan warna yang umum digunakan, sistem dapat membentuk model klasifikasi yang merekomendasikan warna dominan sesuai konteks

penggunaannya. Algoritma seperti Random Forest mampu mengklasifikasikan pola warna berdasarkan fitur RGB, HSL, serta karakteristik visual lainnya dengan tingkat akurasi yang cukup tinggi[3]. Penelitian sebelumnya menunjukkan efektivitas Random Forest dalam merekomendasikan pencahayaan personal berbasis preferensi warna [4], serta performa tinggi dalam klasifikasi fitur warna pada objek multispektral[5].

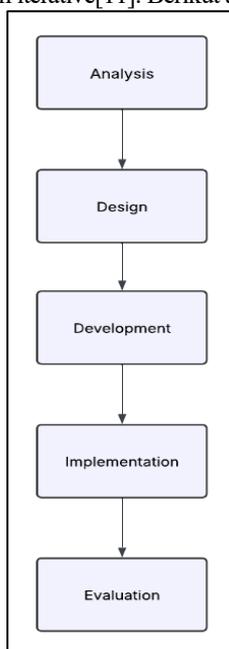
Pendekatan ini menjadi sangat relevan ketika dikaitkan dengan kebutuhan desain kontekstual. Aplikasi edukasi, hiburan, personal, atau produktivitas tentunya membutuhkan kombinasi warna yang berbeda agar sesuai dengan tujuan komunikasi visualnya. Selain itu, sistem rekomendasi warna yang baik juga perlu mempertimbangkan aspek inklusivitas, seperti aksesibilitas bagi pengguna dengan gangguan persepsi warna[6].

Oleh karena itu, integrasi antara analisis fitur warna digital dan konteks aplikasi masih belum diterapkan secara luas dalam sistem desain antarmuka. Pemilihan warna masih sering dilakukan secara manual, tanpa mempertimbangkan data historis atau preferensi pengguna yang beragam. Hal ini menjadi peluang bagi pengembangan sistem rekomendasi warna yang adaptif, cerdas, dan berbasis machine learning[7], [8]. Selain itu, pengukuran fitur warna dari objek visual berbasis sensor juga menjadi bagian penting untuk meningkatkan akurasi prediksi, seperti yang ditunjukkan dalam pemanfaatan imaging sensor dalam klasifikasi visual berkecepatan tinggi[9]. Model berbasis ensemble learning juga menunjukkan kinerja yang dapat dijelaskan secara transparan, mendukung integrasi sistem rekomendasi warna yang akurat dan dapat dipertanggungjawabkan[10].

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi warna kontekstual untuk desain UI/UX dengan menggunakan algoritma Random Forest. Sistem ini dirancang untuk memberikan rekomendasi warna secara otomatis berdasarkan kategori aplikasi yang dipilih pengguna. Dataset yang digunakan terdiri atas data visual dari berbagai platform desain, yang telah direkayasa dan diolah menjadi fitur warna numerik. Hasil model kemudian diintegrasikan ke dalam sebuah dashboard interaktif berbasis Streamlit yang dapat digunakan oleh desainer UI/UX dalam proses perancangan antarmuka digital. Dengan pendekatan ini, diharapkan proses pemilihan warna menjadi lebih objektif, efisien, dan sesuai dengan kebutuhan kontekstual dari masing-masing aplikasi.

Metode Penelitian

Penelitian ini menggunakan pendekatan Research and Development (R&D) dengan model pengembangan ADDIE (Analysis, Design, Development, Implementation, dan Evaluation). Model ADDIE dipilih karena mampu memfasilitasi proses pengembangan sistem secara sistematis dan iterative[11]. Berikut adalah tahapan metode penelitian:



Gambar 1. Alur Metode Penelitian

1. Tahap Analisis

Tahap awal dalam proses penelitian ini adalah analisis, yang menjadi fondasi dari keseluruhan sistem yang akan dikembangkan. Peneliti memulai dengan mengidentifikasi kebutuhan dasar dari sistem rekomendasi warna yang akan dibangun, termasuk memahami perilaku dan preferensi pengguna dalam konteks desain UI/UX. Kajian literatur dilakukan untuk mendapatkan referensi dari penelitian-penelitian terdahulu terkait pemilihan warna, teori persepsi warna, serta penerapan algoritma machine learning dalam desain. Selain itu, dilakukan eksplorasi terhadap jenis-jenis aplikasi (seperti finansial, kesehatan, edukasi, dan lain-lain) untuk memahami pola warna

yang umum digunakan pada masing-masing kategori. Data yang diperoleh, baik dari platform desain (seperti *Dribbble*) maupun dataset terbuka (seperti *Kaggle*), dianalisis lebih lanjut untuk mengekstraksi atribut warna penting seperti RGB, Hue, *Saturation*, dan *Lightness*, yang nantinya digunakan sebagai variabel dalam pelatihan model. Pengetahuan ini turut diperkuat oleh penggunaan data fashion digital dan emosi visual berbasis fitur warna dari gambar objek [12], [13].

2. Tahap Design

Pada tahap ini, perancangan sistem dilakukan dengan menyusun alur data dari masukan pengguna hingga keluaran sistem berupa rekomendasi warna. Desain sistem meliputi skema pemetaan warna ke fitur numerik (RGB, HSL, brightness, kontras), struktur input untuk klasifikasi kategori aplikasi, serta rancangan antarmuka dashboard visual berbasis Streamlit[14]. Palet warna yang akan direkomendasikan diproses melalui model klasifikasi visual dan mempertimbangkan keselarasan warna harmonis sesuai konteks[15].

3. Tahap Development

Tahapan ini mencakup serangkaian aktivitas teknis seperti pembersihan data, penghapusan duplikasi, normalisasi nilai warna, dan pemetaan kategori aplikasi. Data desain UI/UX yang diperoleh dari berbagai platform kemudian diproses untuk memastikan kualitas dan keseragaman fitur warna. Selanjutnya, dilakukan seleksi fitur melalui analisis korelasi dan pengujian gain information untuk memilih fitur yang paling relevan, yaitu RGB, HSL, brightness, dan hue-dominan. Dataset dibagi menggunakan rasio 80% untuk pelatihan dan 20% untuk pengujian dengan teknik stratified split, guna mempertahankan proporsi distribusi antar kategori. Validasi model dilakukan menggunakan teknik k-fold cross validation dengan jumlah lipatan $k = 3$, untuk memastikan performa model lebih stabil dan menghindari overfitting. Model yang digunakan adalah Random Forest, karena kemampuannya dalam menangani data non-linear dan multivariat. Penyetelan parameter dilakukan menggunakan GridSearchCV terhadap parameter jumlah estimators dan kedalaman pohon, untuk mengoptimalkan performa klasifikasi.

4. Tahap Implementation

Tahap implementasi dilakukan setelah model sistem dinyatakan layak dan siap diuji. Prototipe sistem dikembangkan dalam bentuk aplikasi web interaktif menggunakan Streamlit, sebuah framework Python yang memudahkan integrasi antara model machine learning dan antarmuka pengguna. Melalui dashboard ini, pengguna dapat memilih kategori aplikasi seperti edukasi, finansial, atau kesehatan, lalu sistem akan menampilkan rekomendasi palet warna utama dalam bentuk visual, lengkap dengan nilai RGB dan HEX. Tampilan antarmuka dirancang sederhana agar mudah digunakan oleh desainer maupun pengguna umum. Selain itu, prototipe ini juga menyertakan penjelasan singkat mengenai cara kerja sistem untuk mempermudah eksplorasi dan pemanfaatan fitur rekomendasi warna secara praktis.

5. Tahap Evaluation

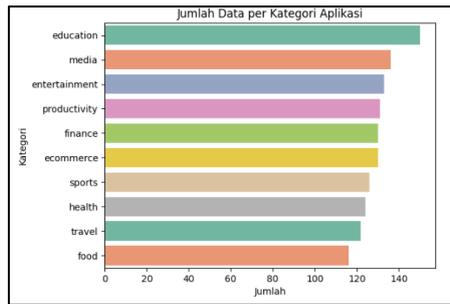
Evaluasi dilakukan menggunakan pendekatan *Proof of Concept* (PoC) untuk menguji fungsionalitas dasar sistem dalam bentuk prototipe. Model Random Forest dievaluasi terhadap data uji menggunakan metrik akurasi, presisi, dan recall guna menilai kemampuan klasifikasi berdasarkan input warna dominan. Selain evaluasi model, pengujian juga dilakukan terhadap dashboard Streamlit untuk memastikan alur kerja sistem berjalan dengan baik, mulai dari pemilihan kategori hingga visualisasi hasil warna. Meskipun belum diuji langsung oleh pengguna, hasil evaluasi awal ini menunjukkan bahwa sistem memiliki potensi untuk dikembangkan lebih lanjut.

Hasil Dan Pembahasan

Hasil dan pembahasan menyajikan hasil dari serangkaian eksperimen yang dilakukan untuk mengembangkan sistem rekomendasi warna berbasis *machine learning*. Pembahasan difokuskan pada analisis dataset warna, evaluasi performa model klasifikasi, serta implementasi sistem rekomendasi dalam bentuk dashboard interaktif. Eksperimen dilakukan secara bertahap, dimulai dari eksplorasi data, preprocessing, rekayasa fitur, pelatihan model, hingga tuning parameter dan penanganan data tidak seimbang. Selain itu, disertakan pula visualisasi untuk membantu memahami karakteristik data warna dari antarmuka UI/UX berbagai kategori aplikasi.

1. Visualisasi Distribusi Kategori Aplikasi

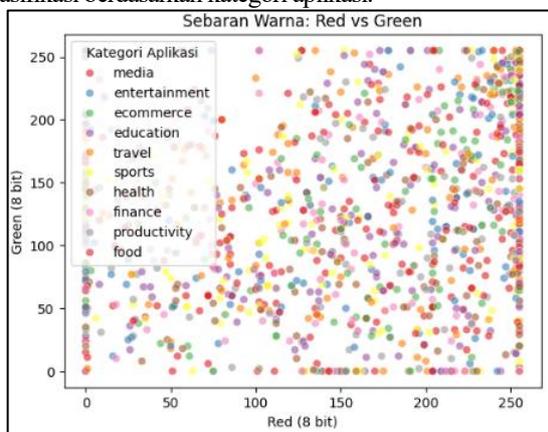
Untuk memahami proporsi data pada setiap kategori, dilakukan visualisasi distribusi jumlah data per kategori aplikasi menggunakan diagram batang horizontal seperti pada Gambar 2. Hasilnya menunjukkan bahwa kategori *education* memiliki jumlah data terbanyak, diikuti oleh kategori seperti *media*, *entertainment*, dan *productivity*. Sementara itu, kategori seperti *food*, *travel*, dan *health* memiliki jumlah data yang relatif lebih rendah.



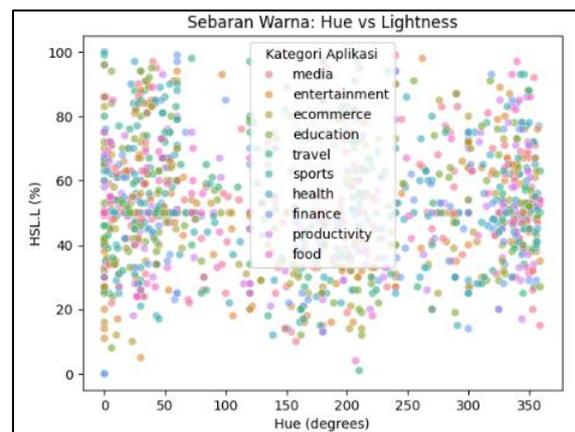
Gambar 2. Visualisasi Distribusi Kategori Aplikasi

2. Scatterplot Red vs Green atau Hue vs Lightness

Untuk memahami persebaran visual warna dalam dataset, dilakukan visualisasi dua dimensi menggunakan scatterplot. Gambar 3 dan 4 memperlihatkan sebaran warna pada ruang Red vs Green (RGB) dan Hue vs Lightness (HSL). Terlihat bahwa sebagian besar kategori aplikasi memiliki area tumpang tindih pada plot RGB, namun distribusi pada ruang Hue-Lightness menunjukkan pola yang sedikit lebih terpisah, khususnya untuk kategori seperti *media* dan *productivity*. Hal ini mengindikasikan bahwa dimensi Hue dan Lightness dapat memberikan sinyal diskriminatif yang lebih baik untuk proses klasifikasi berdasarkan kategori aplikasi.



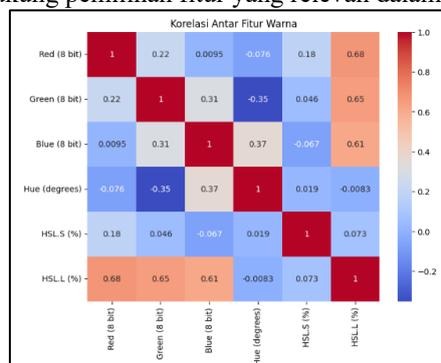
Gambar 3. Scatterplot sebaran warna berdasarkan Red vs Green



Gambar 4. Scatterplot sebaran warna berdasarkan Hue vs Lightness

3. Heatmap Korelasi Antar Fitur Warna

Untuk memahami hubungan antar fitur warna, dilakukan analisis korelasi dan divisualisasikan dalam bentuk heatmap seperti pada Gambar 5. Dari visualisasi tersebut terlihat bahwa fitur Brightness memiliki korelasi cukup kuat dengan nilai Red, Green, dan Blue, karena merupakan hasil rata-rata dari ketiga kanal tersebut. Sebaliknya, nilai Hue menunjukkan korelasi yang rendah terhadap fitur lain, yang menandakan bahwa informasi warna berbasis hue memiliki karakteristik unik dan dapat berperan sebagai fitur pembeda antar kategori aplikasi. Informasi ini penting dalam mendukung pemilihan fitur yang relevan dalam klasifikasi warna.



Gambar 5. Heatmap korelasi antar fitur warna pada dataset

4. Mencoba Lima Kategori

Penelitian dilakukan dengan membagi dataset ke dalam lima kategori aplikasi yaitu bisnis, edukasi, hiburan, lifestyle, dan utilitas. Bertujuan untuk menguji kemampuan model klasifikasi dalam membedakan warna dominan UI/UX berdasarkan 5 kategori aplikasi utama. Pembagian ini dilakukan dengan cara menggabungkan sepuluh

label yang terdiri dari ecommerce, finance, education, health, media, entertainment, travel, food, productivity, sports, ke dalam lima kategori makro.

Tabel 1. Hasil Akurasi Lima Kategori

Kelas	Precision	Recall	F1-Score	Support
Bisnis	0.23	0.19	0.21	52
Edukasi	0.13	0.15	0.14	55
Hiburan	0.29	0.28	0.28	54
Lifestyle	0.18	0.19	0.19	48
Utilitas	0.17	0.18	0.17	51
Accuracy			0.20	260

Berdasarkan dari Tabel.1, dapat disimpulkan bahwa model belum mampu melakukan klasifikasi secara akurat pada tahap awal ini. Model menghasilkan akurasi sebesar 20%, yang mengindikasikan bahwa kemampuan prediksi masih sangat rendah. Nilai precision, recall, dan f1-score di setiap kategori juga menunjukkan performa yang kurang optimal, dengan nilai rata-rata berkisar antara 0.13 hingga 0.29. Secara khusus, kategori *hiburan* menunjukkan performa terbaik (f1-score: 0.28), sedangkan kategori *edukasi* menjadi yang terlemah (f1-score: 0.14), menandakan bahwa model kesulitan mengenali pola warna khas dari aplikasi edukatif. Hasil ini menjadi dasar baseline awal yang akan diperbaiki melalui penyederhanaan kategori dan teknik peningkatan performa model seperti tuning dan balancing data.

5. Mencoba Tiga Kategori

Setelah melakukan penelitian awal dengan lima kategori aplikasi, tahap selanjutnya adalah menguji performa model dengan menyederhanakan kategori menjadi tiga kelompok utama. Tujuan dari pengelompokan ini adalah untuk melihat apakah penyederhanaan label dapat meningkatkan performa klasifikasi warna berdasarkan jenis aplikasi.

Tabel 2. Hasil Akurasi Tiga Kategori

Kelas	Precision	Recall	F1-Score	Support
Edukatif	0.17	0.13	0.15	55
Personal	0.43	0.48	0.45	101
Produktif	0.38	0.39	0.39	104
Accuracy			0.37	260

Dibandingkan dengan eksperimen sebelumnya (lima kategori), terlihat bahwa nilai akurasi meningkat dari 20% menjadi 36,9%, yang menunjukkan bahwa penyederhanaan label membantu model dalam membedakan pola berdasarkan fitur warna. Namun demikian, nilai precision dan recall untuk kategori edukatif masih tergolong rendah. Hal ini kemungkinan disebabkan oleh distribusi data yang tidak seimbang serta kemiripan karakteristik visual antar kategori edukatif dan produktif. Sementara itu, kategori personal menunjukkan performa yang lebih stabil karena jumlah data yang relatif mencukupi dan variasi warna yang lebih khas (misalnya, warna cerah atau kreatif yang sering digunakan pada aplikasi hiburan dan gaya hidup). Penelitian ini menunjukkan bahwa meskipun penyederhanaan label dapat meningkatkan akurasi model, fitur warna saja masih belum sepenuhnya mampu merepresentasikan konteks aplikasi secara andal. Maka dari itu, diperlukan eksperimen lanjutan dengan pendekatan balancing data dan penyetelan parameter untuk meningkatkan performa klasifikasi.

6. Studi Banding Model Lain untuk Validasi Algoritma

Sebagai bentuk validasi terhadap pemilihan algoritma Random Forest, dilakukan studi banding dengan dua model lain yang juga populer dalam klasifikasi data tabular, yaitu Decision Tree Classifier dan Logistic Regression. Evaluasi dilakukan menggunakan dataset yang sama serta konfigurasi fitur serupa dengan eksperimen utama. Tujuannya adalah untuk mengetahui apakah model pembanding mampu menghasilkan performa yang setara atau bahkan lebih baik dibanding Random Forest.

Tabel 3. Hasil Studi Banding dengan Model Lain

Model	Precision	Recall Edukatif	Recall Personal	Recall Produktif
Decision Tree	35,4%	20%	43%	37%
Logistic Regression	36,9%	0%	40%	54%
Random Forest (Tuning)	39,2%	5%	51%	45%

Berdasarkan tabel di atas, terlihat bahwa Random Forest memberikan performa paling seimbang di antara ketiga model, dengan nilai akurasi tertinggi dan distribusi recall antar kelas yang relatif stabil. Meskipun Logistic Regression mendekati dari segi akurasi, model ini gagal mengenali seluruh sampel dari kelas edukatif (recall = 0%). Di sisi lain, Decision Tree memiliki distribusi performa yang sedikit lebih merata, namun masih di bawah Random Forest dari segi f1-score keseluruhan. Dengan demikian, Random Forest dipilih sebagai model utama

karena lebih mampu menangkap variasi fitur warna dan relasi non linear dalam data. Ini juga diperkuat oleh hasil tuning parameter dan pemrosesan fitur tambahan yang mendukung performa model secara keseluruhan.

7. Evaluasi Kinerja Model

Evaluasi performa model dilakukan untuk menilai seberapa baik sistem mampu mengklasifikasikan warna dominan berdasarkan kategori aplikasi. Model terbaik yang diperoleh melalui proses tuning parameter menggunakan GridSearchCV menghasilkan akurasi sebesar 39,2%. Untuk meningkatkan stabilitas klasifikasi dan mengurangi overlap antar label, data aplikasi dikelompokkan ulang menjadi **tiga kategori utama**, yaitu:

1. **Edukasi (edukatif)**, mencakup aplikasi pembelajaran, kursus daring, atau materi edukatif digital.
2. **Personal**, mencakup aplikasi gaya hidup, hiburan, media sosial, dan travel.
3. **Produktif**, mencakup aplikasi bisnis, utilitas kerja, finansial, dan produktivitas sehari-hari.

Tabel 4. Evaluasi Kinerja Model

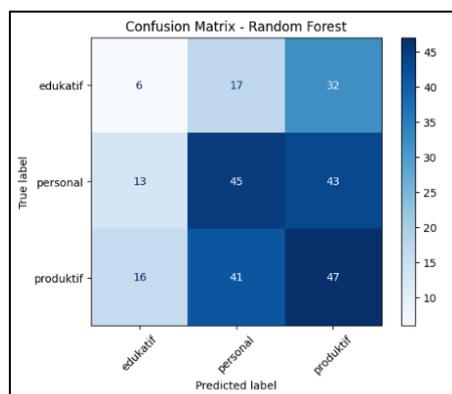
Model	Akurasi	Recall Edukatif	Recall Personal	Recall Produktif
Random Forest (tuning optimal)	39,2%	5%	51%	45%
Random Forest + SMOTE	34,2%	24%	40%	35%

Berdasarkan hasil pengujian, model ini menghasilkan tingkat akurasi sebesar **39,2%** dalam mengklasifikasikan data ke dalam tiga kategori utama aplikasi, yakni edukatif, personal, dan produktif. Di antara ketiga kategori tersebut, kategori personal menunjukkan tingkat keberhasilan klasifikasi yang paling tinggi, sementara kategori **edukatif** menjadi kelas yang paling sulit diprediksi dengan benar. Hal ini diduga karena distribusi warna pada kategori edukatif yang cenderung lebih bervariasi atau menyerupai kategori lain. Hasil tersebut mengindikasikan bahwa pendekatan penyeimbangan data seperti SMOTE memang mampu memperbaiki kinerja model terhadap kelas minoritas (edukatif), tetapi berpotensi menurunkan akurasi keseluruhan. Oleh karena itu, diperlukan pendekatan yang lebih seimbang dalam menangani perbedaan distribusi antar kelas agar performa model tetap stabil di semua kategori.

8. Analisa Kesalahan dan Performan Tiap Kategori

Berdasarkan confusion matrix pada Gambar 6., terlihat bahwa hanya 6 data dari total 55 data edukatif berhasil diklasifikasikan dengan benar. Sebanyak 32 data dari kategori edukatif salah diklasifikasikan sebagai produktif dan 17 lainnya diklasifikasikan sebagai personal. Hal ini menandakan kelemahan model dalam mengenali pola visual yang khas dari aplikasi edukatif.

Sebaliknya, kategori personal berhasil diklasifikasikan dengan benar sebanyak 45 dari total 101 data, meskipun 43 data salah diklasifikasikan ke kategori produktif. Kategori produktif sendiri menunjukkan kinerja terbaik dengan 47 data terklasifikasi dengan benar dari total 104 data. Namun, masih terdapat 41 data produktif yang diklasifikasikan ke personal, menunjukkan adanya tumpang tindih fitur visual antar keduanya.



Gambar 6. Confusion Matrix hasil tuning model Random Forest terhadap tiga kategori aplikasi.

Kesimpulan dari analisis ini adalah bahwa model cenderung lebih kuat dalam mengenali kategori produktif, namun masih mengalami kebingungan dalam membedakan antara personal dan edukatif. Oleh karena itu, strategi tambahan seperti penambahan fitur non-warna, balancing data lanjutan, dan eksplorasi model yang lebih kompleks dapat menjadi opsi pengembangan di masa mendatang.

Simpulan

Penelitian ini berhasil mengembangkan sistem rekomendasi warna kontekstual untuk desain UI/UX berbasis machine learning dengan menggunakan algoritma Random Forest. Sistem dirancang untuk memberikan rekomendasi palet warna sesuai dengan kategori aplikasi, dengan memanfaatkan data visual dari platform Dribbble dan Kaggle yang diproses melalui tahap feature engineering, seleksi fitur, serta penyyetelan parameter.

Hasil eksperimen menunjukkan bahwa model terbaik yang diperoleh mampu mencapai akurasi sebesar 39,2% pada klasifikasi tiga kategori aplikasi: edukatif, personal, dan produktif. Meskipun akurasi tersebut belum optimal, sistem menunjukkan peningkatan performa pada kategori minoritas setelah dilakukan balancing data menggunakan SMOTE. Penggunaan fitur-fitur turunan seperti rasio RGB dan brightness juga berkontribusi dalam meningkatkan kemampuan klasifikasi model. Implementasi sistem dalam bentuk dashboard interaktif berbasis Streamlit menjadi bukti konsep bahwa hasil klasifikasi dapat diterapkan langsung dalam proses desain UI/UX secara praktis dan mudah digunakan. Sistem ini memberikan alternatif berbasis data untuk mendukung keputusan desainer dalam memilih warna yang sesuai konteks aplikasi. Kontribusi utama penelitian ini adalah menunjukkan bahwa pendekatan klasifikasi berbasis fitur warna yang dikombinasikan dengan kategori aplikasi dapat menjadi baseline bagi sistem desain kontekstual yang lebih inklusif, adaptif, dan terotomatisasi.

Daftar Pustaka

- [1] X. Li, Y. Li, and M. H. Jae, "Neural network's selection of color in UI design of social software," *Neural Comput Appl*, vol. 33, no. 3, pp. 1017–1027, Feb. 2021, doi: 10.1007/s00521-020-05422-4.
- [2] N. A. Karim *et al.*, "Using interface preferences as evidence of user identity: A feasibility study," *International Journal of Data and Network Science*, vol. 8, no. 1, pp. 537–548, Dec. 2024, doi: 10.5267/j.ijdns.2023.9.003.
- [3] R. Prasath and T. Kumanan, "Enhanced artificial bee colony approach for the enhancement and classification of underwater images," *International Journal of Computers and Applications*, vol. 44, no. 5, pp. 433–443, 2022, doi: 10.1080/1206212X.2020.1784591.
- [4] W. Sha, K. Hu, and S. Weng, "Statistic and Network Features of RGB and Hyperspectral Imaging for Determination of Black Root Mold Infection in Apples," *Foods*, vol. 12, no. 8, Apr. 2023, doi: 10.3390/foods12081608.
- [5] A. Zarindast and J. Wood, "A Data-Driven Personalized Lighting Recommender System," *Front Big Data*, vol. 4, Oct. 2021, doi: 10.3389/fdata.2021.706117.
- [6] R. Bonacin, J. C. dos Reis, and R. J. de Araujo, "An ontology-based framework for improving color vision deficiency accessibility," *Univers Access Inf Soc*, vol. 21, no. 3, pp. 691–716, Aug. 2022, doi: 10.1007/s10209-021-00791-6.
- [7] P. Park, H. Oh, and H. Kim, "Dual-color space network with global priors for photo retouching," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-47186-6.
- [8] P. M. Cuenca-Jiménez, J. Fernandez-Conde, and J. M. Cañas-Plaza, "FilterNet: Self-Supervised Learning for High-Resolution Photo Enhancement," *IEEE Access*, vol. 10, pp. 2669–2685, 2022, doi: 10.1109/ACCESS.2021.3139778.
- [9] N. I. Papandrianos, A. Feleki, S. Moustakidis, E. I. Papageorgiou, I. D. Apostolopoulos, and D. J. Apostolopoulos, "An Explainable Classification Method of SPECT Myocardial Perfusion Images in Nuclear Cardiology Using Deep Learning and Grad-CAM," *Applied Sciences (Switzerland)*, vol. 12, no. 15, Aug. 2022, doi: 10.3390/app12157592.
- [10] A. Elangovan *et al.*, "Imaging Sensor-Based High-Throughput Measurement of Biomass Using Machine Learning Models in Rice," *Agriculture (Switzerland)*, vol. 13, no. 4, Apr. 2023, doi: 10.3390/agriculture13040852.
- [11] C. Liu and J. Zhuang, "A Probabilistic Multi-Topic Model learned from Aesthetic Quality Communities for Dress Colors Recommendation," *IEEE Access*, 2025, doi: 10.1109/ACCESS.2025.3559670.
- [12] L. Zhao, M. Li, and P. Sun, "Neo-Fashion: A Data-Driven Fashion Trend Forecasting System Using Catwalk Analysis," *Clothing and Textiles Research Journal*, vol. 42, no. 1, pp. 19–34, Jan. 2024, doi: 10.1177/0887302X211004299.
- [13] A. Manzoor *et al.*, "Inferring emotion tags from object images using convolutional neural network," *Applied Sciences (Switzerland)*, vol. 10, no. 15, Aug. 2020, doi: 10.3390/APP10155333.
- [14] J. Seo, A. Choi, and M. Sung, "Recommendation of indoor luminous environment for occupants using big data analysis based on machine learning," *Build Environ*, vol. 198, Jul. 2021, doi: 10.1016/j.buildenv.2021.107835.
- [15] L. Museros, I. Sanz, Z. Falomir, and L. Gonzalez-Abril, "Creating, Interpreting and Rating Harmonic Colour Palettes Using a Cognitively Inspired Model," *Cognit Comput*, vol. 12, no. 2, pp. 442–459, Mar. 2020, doi: 10.1007/s12559-018-9589-2.