

Analysis of the Assistance Model for LKPM Through the Zoom Application at the DPMPTSP of South Lampung Regency using XGBoost

Firdaus¹, Anuar Sanusi^{2*}

* Department of Master of Technology Management, IIB Darmajaya, Bandar Lampung, Indonesia
dawuzz79@gmail.com¹, anuar.sanusi@darmajaya.ac.id²

Article Info

Article history:

Received 2026-02-06

Revised 2026-02-26

Accepted 2026-04-08

Keyword:

XGBoost,

LKPM,

Zoom,

DPMPTSP,

Public Service Assistance.

ABSTRACT

This study aims to analyze the success of LKPM mentoring through the Zoom application at DPMPTSP South Lampung Regency using the XGBoost model. The research identifies key features influencing the success of mentoring, including session duration, number of questions, and user satisfaction. The success of mentoring in this study is defined operationally by the extent to which participants engage with the mentoring process, as measured by the duration of interaction, frequency of questions asked, and the satisfaction levels reported by the participants regarding the mentoring quality. Additionally, the study applies Optuna hyperparameter optimization to improve model performance. The results show a significant increase in model accuracy, achieving 87.16%, with improvements in Precision, Recall, and F1-Score compared to the basic model. The findings suggest that longer Zoom sessions, greater participant interaction through questions, and higher user satisfaction contribute to more effective mentoring outcomes. These results provide actionable insights for DPMPTSP South Lampung Regency to refine mentoring strategies, improve session interactivity, and enhance public service delivery. This study establishes a foundation for data-driven strategies to improve the LKPM mentoring process. Furthermore, the study highlights the importance of continuous optimization and feature engineering to improve model predictions. By leveraging advanced machine learning techniques like XGBoost and Optuna, the model demonstrated high adaptability and predictive power. The research contributes to improving mentoring systems in public services by applying data science methodologies to real-world government programs.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Transformasi digital dalam layanan publik telah menjadi agenda strategis pemerintah Indonesia untuk meningkatkan efisiensi, transparansi, dan akuntabilitas pelayanan kepada masyarakat. Dalam sektor penanaman modal, penerapan sistem Online Single Submission (OSS) berbasis Risiko (RBA) menjadikan Laporan Kegiatan Penanaman Modal (LKPM) sebagai instrumen utama dalam pengawasan investasi serta kepatuhan pelaku usaha terhadap regulasi yang berlaku [1]. Meski demikian, pelaksanaan pelaporan LKPM di tingkat daerah masih menghadapi berbagai kendala, termasuk ketidaksesuaian kapasitas pelaku usaha, keterbatasan literasi digital, dan kompleksitas teknis dalam pengisian laporan [2].

Sebagai respons terhadap tantangan tersebut, Dinas Penanaman Modal dan Pelayanan Terpadu Satu Pintu (DPMPTSP) Kabupaten Lampung Selatan menerapkan model pendampingan LKPM secara daring melalui aplikasi Zoom. Pendekatan ini bertujuan untuk menyediakan layanan asistensi yang lebih fleksibel dan mudah diakses oleh pelaku usaha, yang sering kali terhalang oleh kendala geografis atau keterbatasan waktu. Namun, dalam praktiknya, efektivitas model pendampingan daring tersebut masih menunjukkan variasi yang signifikan. Hal ini terlihat dari adanya kesalahan pengisian laporan, keterlambatan dalam pelaporan, serta perbedaan tingkat pemahaman pelaku usaha terhadap ketentuan LKPM [3].

Evaluasi layanan publik berbasis digital umumnya dilakukan menggunakan pendekatan deskriptif dan survei

persepsi pengguna, seperti SERVQUAL dan System Usability Scale (SUS), yang berfokus pada pengukuran kepuasan dan kualitas layanan [4], [5]. Pendekatan ini memberikan gambaran umum mengenai persepsi pengguna, namun terbatas dalam mengidentifikasi pola-pola kompleks yang mempengaruhi keberhasilan suatu layanan. Oleh karena itu, pendekatan berbasis data dengan menggunakan algoritma XGBoost diharapkan dapat mengungkap hubungan-hubungan yang lebih mendalam antara berbagai faktor yang mempengaruhi keberhasilan pendampingan LKPM [6].

Dalam konteks ini, XGBoost—sebuah algoritma machine learning berbasis gradient boosting—menawarkan potensi untuk menangani data besar dan kompleks, serta menghasilkan model yang sangat akurat untuk klasifikasi [7]. Algoritma ini memiliki keunggulan dalam menangani dataset dengan banyak fitur, serta mampu memberikan interpretasi yang jelas mengenai faktor-faktor yang paling berpengaruh terhadap keputusan yang diambil oleh model. Berbagai penelitian sebelumnya menunjukkan bahwa XGBoost efektif digunakan dalam aplikasi-aplikasi terkait analisis klasifikasi dan prediksi dalam berbagai bidang, termasuk layanan publik dan pengambilan keputusan berbasis data [8], [9].

Penelitian ini bertujuan untuk menganalisis model pendampingan LKPM melalui aplikasi Zoom menggunakan algoritma XGBoost, dengan fokus pada identifikasi faktor-faktor kunci yang mempengaruhi keberhasilan pendampingan. Melalui pendekatan ini, diharapkan dapat dihasilkan aturan keputusan yang bersifat interpretatif, serta memberikan kontribusi bagi pengembangan strategi pendampingan LKPM yang lebih efektif dan berbasis bukti. Penelitian ini juga diharapkan dapat menjadi referensi bagi pengambilan kebijakan di DPMPTSP dalam meningkatkan kualitas layanan publik di Kabupaten Lampung Selatan.

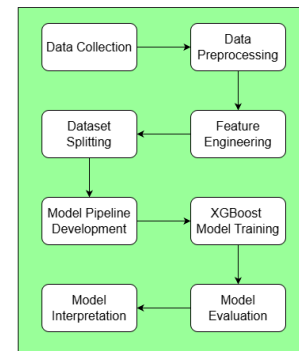
II. METODE

Metode penelitian ini dirancang untuk menjawab tujuan penelitian dengan mengoptimalkan penggunaan aplikasi Zoom dalam model pendampingan LKPM di DPMPTSP Kabupaten Lampung Selatan, menggunakan algoritma XGBoost. Penelitian ini mengadopsi pendekatan eksperimental komparatif dengan dua pipeline yang berbeda: (1) pipeline dasar yang menggunakan fitur standar yang banyak diterapkan dalam literatur sebelumnya, dan (2) pipeline lanjutan yang menggunakan rekayasa fitur hibrida dan optimasi hiperparameter mendalam. Kinerja kedua pipeline ini dievaluasi dan dibandingkan untuk mengukur kontribusi metodologi yang lebih canggih dalam meningkatkan performa model. Dengan pendekatan ini, penelitian ini berfokus pada pengolahan data interaksi peserta Zoom dan laporan LKPM untuk mengidentifikasi faktor-faktor yang mempengaruhi keberhasilan pendampingan LKPM.

A. Pengumpulan Data dan Persiapan

Tahap pertama dari penelitian ini adalah pengumpulan data yang melibatkan dua sumber utama: data interaksi peserta melalui aplikasi Zoom dan data LKPM yang dilaporkan oleh

pelaku usaha. Data interaksi mencakup informasi seperti durasi pertanyaan, jumlah pertanyaan, waktu respons dari DPMPTSP, serta tingkat partisipasi dalam sesi Zoom. Sedangkan data LKPM mencakup jumlah laporan yang diterima, status penyelesaian laporan, serta kategori laporan (investasi besar, menengah, kecil). Proses pengumpulan data dilakukan dengan menggunakan API Zoom dan sistem manajemen LKPM yang terhubung ke DPMPTSP. Data yang terkumpul kemudian digabungkan untuk menghasilkan dataset akhir yang terdiri dari 1.100 data poin yang mencakup atribut-atribut interaksi Zoom dan informasi terkait pelaporan LKPM.



Gambar 1. Research Methodology Flowchart.

Gambar 1 menunjukkan alur metodologi penelitian yang digunakan dalam menganalisis model pendampingan LKPM melalui aplikasi Zoom di DPMPTSP Kabupaten Lampung Selatan. Diagram tersebut menggambarkan tahapan penelitian secara sistematis, mulai dari proses pengumpulan dan persiapan data, rekayasa fitur, pembentukan pipeline model, hingga evaluasi dan interpretasi hasil menggunakan algoritma XGBoost [10-19]. Alur ini dirancang untuk memastikan bahwa setiap tahapan saling terintegrasi dan mendukung tujuan penelitian dalam mengidentifikasi faktor-faktor yang berpengaruh terhadap keberhasilan pendampingan LKPM secara daring.

B. Rekayasa Fitur (Feature Engineering)

Salah satu tantangan signifikan dalam analisis data berbasis machine learning adalah bahwa model-model ini tidak dapat langsung memproses data mentah yang bersifat high-frequency atau data berbasis time-series secara langsung [10]. Untuk itu, data yang dikumpulkan melalui aplikasi Zoom dan sistem LKPM yang melibatkan interaksi dengan pelaku usaha harus dirangkul dan diubah menjadi vektor fitur numerik dengan panjang tetap untuk setiap sesi. Data ini dihitung berdasarkan statistik agregat dari setiap sesi interaksi, yang kemudian digunakan untuk melatih model. Penelitian ini mengimplementasikan dua tingkat rekayasa fitur yang berbeda untuk meningkatkan prediktifitas model.

Pada tingkat pertama, Fitur Dasar (Standard Features), fitur-fitur dirancang berdasarkan pengetahuan domain dan variabel umum yang banyak digunakan dalam literatur sebelumnya [20]. Fitur-fitur ini dibagi ke dalam tiga kategori utama: (1) Fitur Kecepatan Interaksi, yang mencakup durasi sesi, jumlah pertanyaan, dan tingkat partisipasi peserta selama

sesi Zoom; (2) Fitur Input Pengguna, seperti persentase waktu berbicara penuh dan tingkat partisipasi dalam menggunakan berbagai fitur Zoom; dan (3) Fitur Respons dan Kualitas Layanan, yang mencakup waktu respons dan durasi bantuan yang diberikan oleh DPMPTSP. Fitur dasar ini memberikan gambaran umum yang jelas mengenai interaksi peserta dan kinerja dasar layanan yang diberikan oleh DPMPTSP, serta mendasari pemahaman awal dalam membedakan keberhasilan pendampingan. Tingkat kedua, Fitur Lanjutan (Hybrid Features), dirancang untuk memberikan sinyal prediktif yang lebih kuat dan relevan dengan konteks pendampingan LKPM yang lebih kompleks. Fitur-fitur ini menggabungkan data yang lebih mendalam dan memberikan konteks yang lebih jelas mengenai strategi dan kinerja peserta. Fitur-fitur ini mencakup: (1) Fitur Berdasarkan Waktu, seperti durasi sesi Zoom dan waktu yang dibutuhkan untuk memberikan bantuan, yang menggambarkan seberapa efektif pendampingan yang dilakukan dalam konteks waktu; (2) Fitur Penilaian Layanan, yang mengukur kepuasan peserta dan rating layanan yang diberikan oleh DPMPTSP, serta apakah peserta mengajukan keluhan atau tidak; (3) Fitur Strategi dan Asistensi, yang mencakup jenis bantuan yang diberikan selama sesi Zoom dan apakah bantuan tersebut berhasil atau tidak, serta tingkat kepatuhan peserta terhadap prosedur LKPM; dan (4) Fitur Gaya Pengguna, seperti tingkat partisipasi pengguna dalam berbagai aktivitas di Zoom dan apakah mereka cenderung menggunakan fitur-fitur non-verbal seperti chat atau berbagi layar.

Fitur-fitur lanjutan ini diharapkan dapat memberikan model dengan sinyal yang lebih kuat untuk klasifikasi keberhasilan pendampingan, karena mampu menangkap elemen-elemen yang lebih strategis dan berbasis kinerja dalam sesi pendampingan daring LKPM. Dengan menggunakan kombinasi fitur dasar dan lanjutan ini, model XGBoost dapat lebih efektif dalam mengidentifikasi pola yang membedakan antara keberhasilan dan kegagalan pendampingan LKPM, sekaligus memberikan wawasan tentang faktor-faktor yang mempengaruhi keberhasilan pendampingan [21].

C. Training Model

Penelitian ini menggunakan Extreme Gradient Boosting (XGBoost) untuk menganalisis model pendampingan LKPM melalui aplikasi Zoom di DPMPTSP Kabupaten Lampung Selatan. XGBoost dipilih karena kemampuannya yang sangat baik dalam menangani data tabular yang besar dan kompleks, serta memberikan kinerja terbaik dalam klasifikasi. XGBoost juga memiliki fitur *feature importance* yang memungkinkan peneliti untuk mengidentifikasi fitur-fitur yang paling berpengaruh dalam keberhasilan model pendampingan LKPM [22].

Metodologi berbasis machine learning dengan menggunakan XGBoost sudah sangat sesuai untuk mengidentifikasi pola keberhasilan mentoring dalam konteks ini. XGBoost memiliki kemampuan luar biasa dalam menangani dataset yang besar dan kompleks, serta dapat menangani hubungan non-linear yang mungkin ada antara

fitur-fitur yang digunakan. Keunggulan XGBoost terletak pada kemampuannya untuk mengoptimalkan pembelajaran melalui teknik *gradient boosting*, yang membuatnya lebih efektif dalam mengklasifikasikan hasil berdasarkan pola-pola yang lebih rumit dan tidak terlihat jelas di permukaan. Selain itu, fitur *feature importance* yang dimiliki oleh XGBoost memungkinkan peneliti untuk dengan mudah mengidentifikasi fitur-fitur paling berpengaruh yang berkontribusi terhadap keberhasilan pendampingan, memberikan interpretabilitas yang jelas tanpa perlu membandingkan model dengan algoritma lain.

Penelitian ini mengimplementasikan dua pipeline pelatihan yang berbeda: (1) Pipeline Dasar, yang menggunakan fitur standar berdasarkan pengetahuan domain dan literatur yang ada, seperti durasi sesi, jumlah pertanyaan, tingkat partisipasi peserta, serta data terkait LKPM seperti jumlah laporan dan status penyelesaian. Pembagian data dilakukan dengan menggunakan metode 80/20 split, di mana 80% data digunakan untuk pelatihan dan 20% untuk pengujian, serta menggunakan K-Fold Cross-Validation sebanyak 5 lipatan untuk memilih hiperparameter optimal. (2) Pipeline Lanjutan, yang menggunakan fitur hibrida yang lebih kompleks, yang mencakup data berbasis waktu, kualitas layanan, dan tingkat kepuasan peserta. Untuk optimasi model, framework Optuna digunakan untuk pencarian otomatis untuk menemukan kombinasi hiperparameter terbaik, diikuti dengan 5-fold cross-validation untuk memastikan kestabilan dan generalisasi model. Tujuan dari kedua pipeline ini adalah untuk menghasilkan model yang lebih akurat dalam mengklasifikasikan keberhasilan pendampingan LKPM, dengan mempertimbangkan berbagai faktor yang relevan dalam konteks layanan publik berbasis Zoom [23].

D. Evaluasi Model

Setelah model XGBoost dilatih menggunakan kedua pipeline yang telah dijelaskan sebelumnya, evaluasi model dilakukan untuk mengukur kinerja dan efektivitasnya dalam mengklasifikasikan keberhasilan pendampingan LKPM melalui aplikasi Zoom. Evaluasi model ini bertujuan untuk menilai bagaimana model dapat memprediksi hasil pendampingan dengan akurat, serta untuk mengidentifikasi kekuatan dan kelemahan model dalam mengklasifikasikan data yang belum pernah dilihat sebelumnya [24]. Proses evaluasi ini menggunakan beberapa metrik klasifikasi yang relevan, di antaranya Akurasi, Precision, Recall, dan F1-Score untuk masing-masing kelas (berhasil atau gagal) berdasarkan hasil prediksi model. Akurasi mengukur persentase prediksi yang benar, sementara Precision dan Recall memberikan wawasan lebih dalam tentang kemampuan model untuk mengidentifikasi dengan benar kelas yang relevan, terutama untuk kelas minoritas, seperti keberhasilan pendampingan LKPM. F1-Score digunakan untuk memberikan gambaran keseimbangan antara Precision dan Recall, terutama dalam menghadapi data yang tidak seimbang [10-25].

Selain itu, perlu diperhatikan bahwa distribusi data dalam dataset yang digunakan dapat memengaruhi hasil evaluasi, terutama jika terdapat ketidakseimbangan (*imbalance*) dalam

jumlah kelas yang diprediksi. Misalnya, jika kategori 'berhasil' jauh lebih dominan daripada kategori 'gagal', model mungkin lebih cenderung untuk memprediksi hasil sebagai 'berhasil'. Hal ini dapat mempengaruhi metrik seperti Precision dan Recall, terutama untuk kategori yang lebih jarang, seperti 'gagal'. Oleh karena itu, evaluasi model tidak hanya mengandalkan akurasi, tetapi juga metrik yang lebih sensitif terhadap distribusi data yang tidak seimbang, seperti Precision, Recall, dan F1-Score. Evaluasi ini bertujuan untuk memberikan gambaran yang lebih adil tentang kinerja model dalam mengklasifikasikan kedua kelas dengan benar.

Selain itu, Confusion Matrix digunakan untuk lebih mendalami kesalahan klasifikasi yang terjadi, dengan menganalisis jumlah prediksi yang benar dan salah untuk setiap kelas. Confusion Matrix memberikan gambaran yang jelas mengenai jenis kesalahan yang paling sering dilakukan oleh model, apakah model lebih sering salah mengklasifikasikan hasil keberhasilan atau kegagalan pendampingan. Dengan demikian, evaluasi ini tidak hanya memberikan angka statistik tetapi juga membantu untuk memahami area perbaikan dalam model. Terakhir, Feature Importance juga dianalisis untuk mengidentifikasi faktor-faktor kunci yang paling berpengaruh terhadap hasil prediksi model, memberikan wawasan lebih lanjut mengenai elemen-elemen yang paling penting dalam proses pendampingan LKPM.

E. Analisis Interpretasi

Setelah evaluasi model dilakukan, tahap selanjutnya adalah analisis interpretasi, yang bertujuan untuk memahami hasil yang diperoleh dari model XGBoost dan mengidentifikasi faktor-faktor utama yang memengaruhi keberhasilan pendampingan LKPM melalui aplikasi Zoom di DPMPSTP Kabupaten Lampung Selatan. Salah satu alat utama yang digunakan dalam analisis ini adalah Feature Importance, yang dihasilkan dari model XGBoost. Feature Importance memberikan gambaran tentang fitur-fitur mana yang paling berpengaruh dalam menentukan hasil prediksi [15-19]. Fitur yang memiliki nilai tinggi dalam Feature Importance menunjukkan bahwa fitur tersebut memiliki kontribusi signifikan terhadap keputusan model dalam mengklasifikasikan keberhasilan atau kegagalan pendampingan LKPM.

Analisis ini memungkinkan peneliti untuk mengidentifikasi pola-pola yang mungkin tidak tampak secara jelas pada pandangan pertama, seperti hubungan antara durasi sesi Zoom, tingkat partisipasi peserta, waktu respons, dan jenis bantuan yang diberikan. Misalnya, jika durasi sesi atau jumlah pertanyaan memiliki tingkat feature importance yang tinggi, ini dapat mengindikasikan bahwa interaksi yang lebih panjang dan aktif selama sesi Zoom berkorelasi dengan keberhasilan pendampingan. Selain itu, kepuasan pengguna dan waktu respons dari DPMPSTP juga mungkin menjadi faktor kunci yang mempengaruhi keberhasilan model. Namun, Ketergantungan pada platform Zoom sebagai media komunikasi utama pendampingan LKPM mungkin membatasi generalisasi temuan, karena faktor seperti kualitas

koneksi internet dan keterampilan digital peserta dapat mempengaruhi efektivitas sesi.

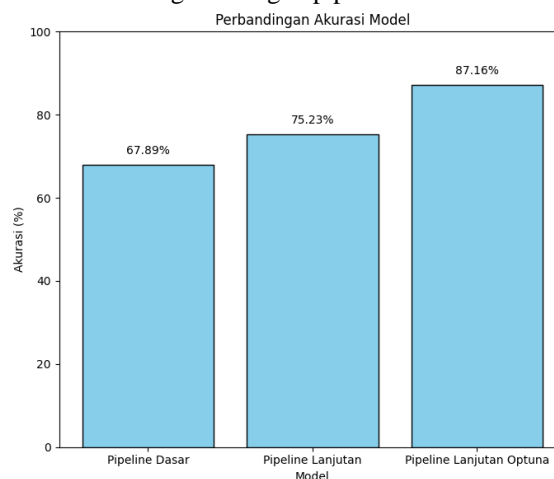
Dengan menganalisis Feature Importance, penelitian ini tidak hanya memberikan pemahaman tentang bagaimana model bekerja, tetapi juga memberikan wawasan yang berguna untuk pengambilan keputusan berbasis data di DPMPSTP. Hasil dari analisis ini dapat digunakan untuk merancang strategi pendampingan yang lebih efektif, meningkatkan kualitas layanan, dan mengoptimalkan alokasi sumber daya berdasarkan faktor-faktor yang terbukti mempengaruhi keberhasilan pendampingan LKPM.

III. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk menganalisis faktor-faktor yang mempengaruhi keberhasilan model pendampingan LKPM melalui aplikasi Zoom di DPMPSTP Kabupaten Lampung Selatan dengan menggunakan algoritma XGBoost. Hasil penelitian menunjukkan bahwa optimasi hiperparameter pada pipeline lanjutan menghasilkan peningkatan yang signifikan dalam akurasi dan F1-Score model, yang menggambarkan kontribusi faktor-faktor seperti durasi sesi Zoom, jumlah pertanyaan, dan tingkat kepuasan pengguna terhadap keberhasilan pendampingan.

A. Hasil Komparasi Akurasi Model

Berdasarkan Gambar 1 menunjukkan bahwa, Pada pipeline dasar, model yang dilatih menggunakan fitur standar menunjukkan hasil akurasinya sebesar 67.89%, yang merupakan hasil terendah di antara ketiga pipeline yang diuji. Selanjutnya, pada pipeline lanjutan, yang menggunakan fitur hibrida dan pengoptimalan hiperparameter, akurasi model meningkat menjadi 75.23%, menunjukkan perbaikan yang signifikan dibandingkan dengan pipeline dasar.




Gambar 2. Komparasi Akurasi Model.

Namun, ketika pengoptimalan hiperparameter diterapkan pada pipeline lanjutan menggunakan framework Optuna, model menunjukkan peningkatan yang sangat signifikan, dengan akurasinya mencapai 87.16%, yang merupakan peningkatan 18.27% dibandingkan dengan pipeline dasar. Peningkatan akurasi ini menunjukkan bahwa optimasi hiperparameter dengan Optuna memberikan kontribusi besar

dalam meningkatkan kinerja model, terutama dalam meningkatkan kemampuan model untuk memprediksi hasil yang lebih akurat.

B. Perbandingan Hasil antara Pipeline Dasar dan Lanjutan

Perbandingan kinerja berdasarkan hasil Confusion Matrix untuk masing-masing pipeline menunjukkan perbedaan yang signifikan dalam True Positives (TP), True Negatives (TN), False Positives (FP), dan False Negatives (FN), yang berpengaruh langsung terhadap akurasi dan kinerja model. Model diuji menggunakan 20% data untuk testing set, yang terdiri dari 220 sampel dari total dataset. Berikut adalah hasil perbandingan model berdasarkan Confusion Matrix.



Gambar 3. Perbandingan Hasil antara Pipeline Dasar dan Lanjutan.

Berdasarkan Gambar 3, kita dapat melihat bahwa Pipeline Dasar, yang memiliki Akurasi 67.89%, menunjukkan distribusi yang lebih seimbang antara True Positives (TP) dan True Negatives (TN), masing-masing sebanyak 75. Meskipun begitu, model ini juga memiliki False Positives (FP) sebanyak 45 dan False Negatives (FN) sebanyak 25, yang menunjukkan bahwa model ini masih kesulitan dalam mengklasifikasikan kategori berhasil dan gagal secara tepat. Hal ini mencerminkan bahwa meskipun model mencapai akurasi yang cukup baik, masih ada banyak kesalahan dalam mengidentifikasi kategori yang sebenarnya harusnya berhasil.

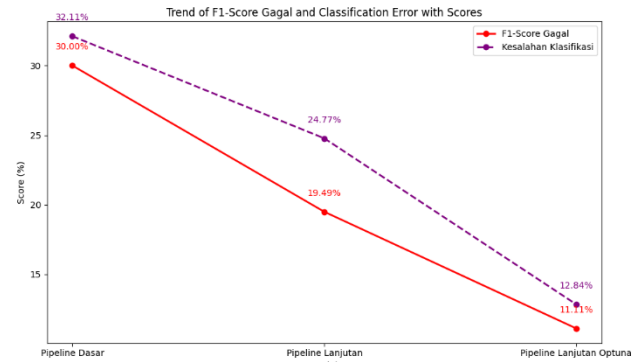
Pipeline Lanjutan, dengan Akurasi 75.23%, menunjukkan peningkatan kinerja yang jelas dibandingkan dengan Pipeline Dasar. True Positives (TP) dan True Negatives (TN) meningkat menjadi 82 dan 83, sementara False Positives (FP) dan False Negatives (FN) menurun menjadi 42 dan 13. Peningkatan ini menunjukkan bahwa Pipeline Lanjutan lebih stabil dalam mengklasifikasikan kedua kategori. Model ini mampu mengidentifikasi berhasil dan gagal dengan lebih akurat, meskipun masih terdapat beberapa kesalahan pada False Positives.

Pipeline Lanjutan dengan Optuna, yang memiliki Akurasi 87.16%, menunjukkan hasil yang paling signifikan di antara ketiga model. True Positives (TP) dan True Negatives (TN) masing-masing mencapai 96, sementara False Positives (FP) dan False Negatives (FN) berjumlah 12 untuk masing-masing. Model ini menunjukkan kemampuan terbaik dalam mengklasifikasikan kedua kategori dengan akurat, mengurangi kesalahan False Negatives dan False Positives secara signifikan. Meskipun ada sedikit False Negatives, yang menunjukkan bahwa model kadang gagal mengidentifikasi beberapa pendampingan yang seharusnya berhasil, hasil ini tetap memperlihatkan akurasi yang tinggi dan pengklasifikasian yang lebih stabil.

Overall, Pipeline Lanjutan dengan Optuna memberikan hasil terbaik dengan akurasinya yang tertinggi dan distribusi yang paling optimal antara True Positives (TP) dan True Negatives (TN). Hal ini menunjukkan bahwa optimasi hiperparameter dengan Optuna memberikan kontribusi besar dalam meningkatkan akurasi dan stabilitas model, serta memperbaiki kemampuan model dalam mengklasifikasikan kategori berhasil dan gagal secara lebih tepat.

C. Analisis Kesalahan Klasifikasi

Analisis Kesalahan berdasarkan perbandingan Gambar 3 akan didapatkan grafik tren F1-Score untuk Gagal dan Kesalahan Klasifikasi untuk masing-masing model, perbedaan dalam kemampuan setiap model untuk mengklasifikasikan kategori gagal (False Negatives) sangat jelas. Kesalahan klasifikasi, yang dihitung sebagai 1 - Akurasi, mengungkapkan seberapa besar kesalahan yang dilakukan oleh model dalam mengklasifikasikan data baik dalam kategori berhasil maupun gagal. Semakin rendah kesalahan klasifikasi, semakin baik model dalam membedakan kedua kategori dengan tepat.



Gambar 4. Trend of F1-Score Gagal and Classification Error with Scores.

Berdasarkan Gambar 4 menunjukkan bahwa pada Pipeline Dasar yang memiliki Akurasi 67.89%, model menunjukkan F1-Score untuk Gagal yang relatif rendah, yaitu 30%, yang menunjukkan bahwa model ini kurang efektif dalam mengidentifikasi kategori gagal dengan benar. Hal ini diperburuk oleh kesalahan klasifikasi yang cukup tinggi, yaitu 32.11%, yang menandakan adanya banyak kesalahan dalam mengklasifikasikan data sebagai berhasil atau gagal. Kesalahan ini kemungkinan disebabkan oleh penggunaan fitur standar, yang belum cukup kuat untuk menangkap pola-pola yang lebih kompleks dalam data.

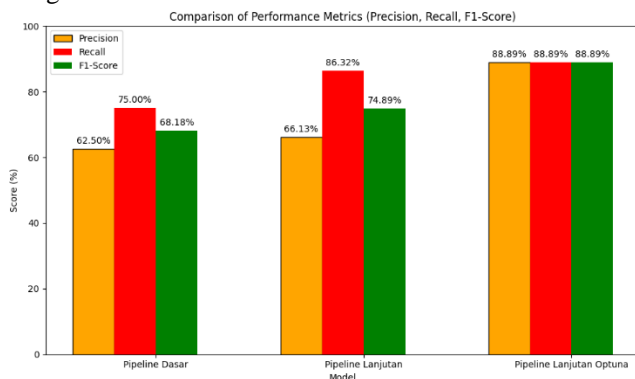
Selanjutnya, Pipeline Lanjutan dengan Akurasi 75.23% menunjukkan peningkatan yang signifikan. Kesalahan klasifikasi menurun menjadi 24.77%, dan F1-Score untuk Gagal juga meningkat, meskipun masih berada di angka 19.49%. Meskipun model ini lebih baik dalam mengidentifikasi kategori berhasil dan gagal dibandingkan Pipeline Dasar, masih ada sejumlah kesalahan pada False Positives, yang menunjukkan bahwa model ini masih terkadang salah mengklasifikasikan kategori gagal sebagai berhasil.

Dalam Pipeline Lanjutan dengan Optuna, yang memiliki Akurasi 87.16%, menunjukkan hasil terbaik. Kesalahan klasifikasi sangat menurun menjadi hanya 12.84%, dengan F1-Score untuk Gagal yang lebih rendah, yaitu 11.11%. Meskipun ada sedikit kesalahan dalam mengklasifikasikan pendampingan yang berhasil sebagai gagal, model ini mampu mengidentifikasi kedua kategori dengan sangat baik. Hasil ini menunjukkan bahwa optimasi hiperparameter menggunakan Optuna berperan penting dalam meningkatkan kemampuan model untuk membedakan antara kategori berhasil dan gagal dengan lebih tepat.

Optimasi hiperparameter dengan Optuna telah terbukti efektif dalam mengurangi kesalahan klasifikasi dan meningkatkan akurasi model. Meskipun masih ada beberapa kesalahan pada False Negatives, terutama di Pipeline Lanjutan dengan Optuna, kesalahan ini sangat rendah dibandingkan dengan Pipeline Dasar dan Pipeline Lanjutan.

D. Perbandingan Score Performansi Precision, Recall, dan F1-Score

Analisis perbandingan hasil performa *Precision*, *Recall*, dan *F1-Score* untuk masing-masing pipeline, terdapat perbedaan signifikan dalam kinerja antara Pipeline Dasar, Pipeline Lanjutan, dan Pipeline Lanjutan dengan Optuna dalam mengklasifikasikan kategori berhasil dan gagal Adalah sebagai berikut.



Gambar 5. Hasil Perbandingan Score *Precision*, *Recall*, dan *F1-Score*

Gambar 5 menunjukkan dalam Pipeline Dasar, Precision yang tercatat sebesar 62.5% dan Recall 75% menunjukkan bahwa model ini mengalami kesulitan dalam mengidentifikasi kategori gagal dengan benar, karena False Positives masih cukup tinggi. Meskipun demikian, model ini berhasil mengidentifikasi pendampingan yang berhasil dengan cukup baik, yang tercermin pada Recall yang tinggi. F1-Score yang didapat sebesar 68.18% menggambarkan keseimbangan antara Precision dan Recall, namun masih terdapat potensi perbaikan.

Pipeline Lanjutan menunjukkan peningkatan yang jelas, dengan Precision yang mencapai 66.13% dan Recall yang lebih tinggi, yaitu 86.32%. Hal ini menunjukkan bahwa model lebih efektif dalam mengklasifikasikan kategori berhasil dan gagal, serta mengurangi kesalahan False Positives. Peningkatan Recall ini juga menandakan model lebih baik dalam mengidentifikasi pendampingan yang berhasil. F1-


Score yang mencapai 74.89% menunjukkan bahwa model ini memiliki keseimbangan yang lebih baik antara keduanya dibandingkan dengan Pipeline Dasar.

Adapun Pipeline Lanjutan dengan Optuna menghasilkan performa tertinggi di antara ketiga model, dengan Precision, Recall, dan F1-Score yang semuanya mencapai 88.89%. Hasil ini menunjukkan bahwa optimasi hiperparameter yang dilakukan dengan Optuna memberikan kontribusi besar terhadap peningkatan kinerja model, menjadikannya sangat efisien dalam mengklasifikasikan kedua kategori berhasil dan gagal dengan sangat sedikit kesalahan. Peningkatan yang signifikan pada kedua metrik (*Precision* dan *Recall*) mencerminkan kemajuan yang pesat dalam kualitas prediksi.

Terlihat bahwa, Pipeline Lanjutan dengan Optuna memberikan hasil terbaik di semua metrik, dan optimasi hiperparameter telah terbukti meningkatkan kinerja model dalam klasifikasi. Sementara itu, Pipeline Lanjutan juga mengalami peningkatan yang signifikan dibandingkan Pipeline Dasar, meskipun masih ada beberapa area yang dapat diperbaiki, terutama dalam Precision.

E. Analisis Feature Importance

Hasil analisis Feature Importance menggunakan XGBoost mengungkapkan bahwa beberapa fitur memiliki pengaruh besar dalam menentukan keberhasilan model pendampingan LKPM. Durasi sesi Zoom, jumlah pertanyaan, dan kepuasan pengguna adalah fitur-fitur utama yang memengaruhi prediksi keberhasilan. Durasi sesi Zoom memiliki pengaruh terbesar dengan skor 0.28, menunjukkan bahwa semakin lama waktu yang diberikan untuk pendampingan via Zoom, semakin besar kemungkinan keberhasilan yang diprediksi oleh model. Hal ini mengindikasikan bahwa interaksi yang lebih panjang memberikan kesempatan bagi pendamping untuk memberikan informasi yang lebih mendalam, meningkatkan pemahaman peserta, dan pada akhirnya meningkatkan keberhasilan pendampingan. Hasil Feature Importance ditunjukkan dalam Gambar 6 sebagai berikut.



Gambar 6. Hasil *Feature Importance*

Selanjutnya, dalam Gambar 6 juga menunjukkan jumlah pertanyaan yang diajukan oleh peserta memiliki skor 0.20 dan juga berperan penting dalam menentukan hasil pendampingan. Interaksi aktif, seperti banyaknya pertanyaan yang diajukan, menunjukkan bahwa peserta terlibat secara aktif dalam sesi tersebut, yang berkontribusi pada hasil yang lebih baik. Durasi sesi dan jumlah pertanyaan saling mendukung dalam meningkatkan keberhasilan pendampingan. Kepuasan pengguna, dengan skor 0.18, juga mempengaruhi keberhasilan pendampingan, meskipun pengaruhnya sedikit lebih rendah dibandingkan dengan durasi dan jumlah pertanyaan. Kepuasan yang tinggi dari peserta

menjadi indikator bahwa pendampingan tersebut berjalan dengan efektif dan memenuhi harapan peserta. Namun, faktor eksternal yang tidak tercakup dalam model juga bisa mempengaruhi kepuasan ini, seperti kondisi sosial-ekonomi peserta yang mungkin mempengaruhi persepsi mereka terhadap kualitas layanan, terutama jika mereka merasa terbebani oleh waktu yang diperlukan untuk berpartisipasi dalam sesi pendampingan.

Waktu respons, dengan skor 0.15, meskipun memiliki pengaruh lebih moderat, tetap berperan penting dalam memastikan kelancaran sesi pendampingan. Respons yang cepat dari pendamping menciptakan suasana yang lebih efisien dan membantu peserta merasa lebih dihargai, sehingga meningkatkan efektivitas pendampingan. Jumlah laporan LKPM, meskipun memiliki skor terendah yaitu 0.12, tetap memberi kontribusi pada model. Meskipun pengaruhnya lebih kecil, data terkait laporan LKPM bisa menjadi indikator tambahan yang menggambarkan sejauh mana peserta terlibat dalam proses administrasi yang penting untuk keberhasilan pendampingan.

Hasil analisis ini memberikan wawasan yang berguna bagi DPMPSTP untuk meningkatkan interaksi selama sesi Zoom. Dengan memperpanjang durasi sesi dan mendorong lebih banyak pertanyaan dari peserta, mereka dapat meningkatkan efektivitas pendampingan. Selain itu, menjaga tingkat kepuasan peserta dan memperbaiki waktu respons juga merupakan langkah-langkah penting untuk meningkatkan kualitas layanan pendampingan LKPM.

F. Pembahasan

Hasil penelitian ini menunjukkan bahwa model XGBoost yang diterapkan untuk menganalisis keberhasilan pendampingan LKPM melalui aplikasi Zoom di DPMPSTP Kabupaten Lampung Selatan memberikan hasil yang signifikan. Model ini mampu memprediksi keberhasilan pendampingan dengan baik, dengan memperhitungkan beberapa fitur penting yang berpengaruh, seperti durasi sesi Zoom, jumlah pertanyaan, dan kepuasan pengguna. Berdasarkan hasil *Feature Importance*, ditemukan bahwa durasi sesi Zoom (0.28), jumlah pertanyaan (0.20), dan kepuasan pengguna (0.18) adalah faktor yang paling berpengaruh dalam memprediksi keberhasilan pendampingan LKPM.

Durasi sesi Zoom menjadi faktor paling dominan, yang menunjukkan bahwa semakin lama durasi sesi pendampingan, semakin besar kemungkinan keberhasilan yang diprediksi oleh model. Hal ini memberikan wawasan bahwa interaksi yang lebih panjang memungkinkan pendamping untuk memberikan penjelasan lebih mendalam kepada peserta, sehingga meningkatkan pemahaman dan efektivitas pendampingan. Selain itu, jumlah pertanyaan yang diajukan oleh peserta selama sesi juga menunjukkan pengaruh besar terhadap keberhasilan pendampingan, yang menunjukkan pentingnya interaksi aktif selama sesi Zoom. Kepuasan pengguna, meskipun sedikit lebih rendah dibandingkan dengan dua fitur lainnya, juga memiliki

kontribusi yang signifikan terhadap prediksi keberhasilan pendampingan.

Penerapan optimasi hiperparameter dengan Optuna pada Pipeline Lanjutan menunjukkan peningkatan yang signifikan dalam akurasi model, dengan Akurasi 87.16% yang lebih tinggi dibandingkan dengan Pipeline Dasar dan Pipeline Lanjutan. Selain Akurasi, metrik Precision, Recall, dan F1-Score juga menunjukkan kinerja yang lebih baik pada Pipeline Lanjutan dengan Optuna, membuktikan bahwa optimasi hiperparameter memberikan dampak yang besar terhadap peningkatan kualitas prediksi. Hasil ini penting bagi DPMPSTP, yang dapat memanfaatkan fitur-fitur penting ini untuk meningkatkan efektivitas pendampingan LKPM dengan memperpanjang durasi sesi Zoom, meningkatkan interaksi dengan lebih banyak pertanyaan, serta memastikan tingkat kepuasan peserta yang lebih tinggi.

Meskipun model ini memberikan hasil yang baik, masih terdapat beberapa kesalahan klasifikasi pada False Positives dan False Negatives, terutama pada Pipeline Dasar. Model masih mengalami kesulitan dalam membedakan antara kategori berhasil dan gagal pada beberapa kasus, yang menunjukkan bahwa lebih banyak data atau peningkatan fitur dapat membantu meningkatkan akurasi prediksi. Misalnya, distribusi data yang tidak seimbang, seperti lebih banyak kategori 'berhasil' dibandingkan 'gagal', bisa menyebabkan kesalahan klasifikasi. Oleh karena itu, langkah-langkah perbaikan seperti menyeimbangkan dataset atau memperkenalkan teknik sampling mungkin dapat membantu mengurangi kesalahan ini. Perbaikan lebih lanjut dalam pemilihan fitur dan optimasi model dapat membantu mengurangi kesalahan ini dan meningkatkan keakuratan prediksi dalam pendampingan LKPM.

Hasil *Feature Importance* menunjukkan bahwa durasi sesi Zoom, jumlah pertanyaan, dan kepuasan pengguna adalah fitur-fitur yang paling berpengaruh dalam menentukan keberhasilan model pendampingan LKPM. Temuan ini memberikan wawasan penting bagi DPMPSTP, yang dapat memperbaiki interaksi selama sesi Zoom dengan meningkatkan durasi sesi dan mendorong peserta untuk mengajukan lebih banyak pertanyaan, yang dapat meningkatkan efektivitas pendampingan. Selain itu, waktu respons dan jumlah laporan LKPM juga menunjukkan pengaruh yang signifikan terhadap keberhasilan model.

Waktu respons yang cepat menciptakan suasana yang lebih efisien, membantu peserta merasa lebih dihargai, dan meningkatkan efektivitas pendampingan. Jumlah laporan LKPM meskipun pengaruhnya lebih kecil, tetap memberikan indikasi tingkat keterlibatan peserta dalam proses administratif yang juga berperan penting untuk keberhasilan pendampingan. Meskipun XGBoost telah menunjukkan performa yang baik, evaluasi lebih lanjut dengan cross-validation atau teknik validasi lain yang lebih mendalam dapat memberikan hasil yang lebih stabil dan menunjukkan ketahanan model terhadap variabilitas data yang lebih luas. Oleh karena itu, tambahan teknik validasi seperti Stratified Cross-Validation atau Bootstrapping bisa memberikan

gambaran yang lebih kuat tentang kestabilan dan keandalan model.

Hasil dari analisis ini dapat digunakan untuk merancang strategi pendampingan yang lebih efektif, meningkatkan kualitas layanan, dan mengoptimalkan alokasi sumber daya berdasarkan faktor-faktor yang terbukti mempengaruhi keberhasilan pendampingan LKPM.

IV. KESIMPULAN

Penelitian ini berhasil menerapkan model XGBoost untuk menganalisis keberhasilan pendampingan LKPM melalui aplikasi Zoom di DPMPSTP Kabupaten Lampung Selatan. Berdasarkan analisis Feature Importance, ditemukan bahwa durasi sesi Zoom, jumlah pertanyaan, dan kepuasan pengguna adalah faktor utama yang mempengaruhi keberhasilan pendampingan. Penerapan optimasi hiperparameter dengan Optuna pada Pipeline Lanjutan menunjukkan peningkatan akurasi signifikan hingga 87.16%, dengan Precision, Recall, dan F1-Score yang lebih baik, menunjukkan bahwa optimasi ini meningkatkan kemampuan model dalam memprediksi keberhasilan pendampingan.

Hasil penelitian ini menjawab tujuan untuk mengembangkan model yang dapat memprediksi keberhasilan pendampingan LKPM dengan menggunakan data sesi Zoom dan faktor-faktor terkait. Temuan ini memberikan wawasan penting bagi DPMPSTP dalam meningkatkan kualitas pendampingan, seperti memperpanjang durasi sesi, meningkatkan interaksi dengan lebih banyak pertanyaan, dan memastikan kepuasan peserta yang lebih tinggi. Selain itu, model ini memberikan dasar untuk merancang strategi pendampingan yang lebih efektif dan berbasis data di masa depan.

Meskipun model ini memberikan hasil yang baik, penelitian ini terbatas pada penggunaan Zoom sebagai platform utama untuk pendampingan. Penelitian lanjutan dapat memperluas model dengan mempertimbangkan penggunaan platform lain untuk interaksi daring, yang mungkin lebih sesuai untuk pelaku usaha di daerah dengan keterbatasan akses atau kemampuan digital. Selain itu, perbaikan lebih lanjut dalam optimasi fitur dan pembagian data yang lebih seimbang dapat meningkatkan performa model, serta melibatkan lebih banyak variabel eksternal yang mungkin memengaruhi keberhasilan pendampingan, seperti faktor sosial-ekonomi peserta atau kondisi lokal. Penelitian berikutnya juga bisa fokus pada analisis perbandingan model dengan algoritma lain seperti Random Forest atau Logistic Regression untuk melihat keunggulan relatif XGBoost dalam konteks ini.

DAFTAR PUSTAKA

- [1] Kementerian Investasi/BKPM, Pedoman Pelaporan Laporan Kegiatan Penanaman Modal (LKPM) melalui OSS RBA, Jakarta, Indonesia, 2023.
- [2] D. Sutopo dan R. Nugroho, "Challenges in implementing online investment reporting systems in regional governments," *Jurnal Administrasi Publik*, vol. 18, no. 2, pp. 101–112, 2021.
- [3] J. Brooke, "SUS: A quick and dirty usability scale," in *Usability Evaluation in Industry*, P. W. Jordan et al., Eds. London, UK: Taylor & Francis, 1996, pp. 189–194.
- [4] A. Parasuraman, V. A. Zeithaml, and L. L. Berry, "SERVQUAL: A multiple-item scale for measuring consumer perceptions of service quality," *Journal of Retailing*, vol. 64, no. 1, pp. 12–40, 1988.
- [5] K. Battista, S. Haddad, S. T. Leatherdale, and R. Bélanger, "Characteristics of adolescent cannabis use and social context predicting problematic use: A decision tree analysis," *Addictive Behaviors*, vol. 170, Art. no. 108445, 2025.
- [6] J. R. Quinlan, "Induction of decision trees," *Machine Learning*, vol. 1, no. 1, pp. 81–106, 1986.
- [7] L. Breiman, J. Friedman, R. Olshen, and C. Stone, *Classification and Regression Trees*, Belmont, CA, USA: Wadsworth, 1984.
- [8] M. Erkamim, S. Suswadi, M. Z. Subarkah, and E. Widarti, "Komparasi Algoritme Random Forest dan XGBoosting dalam Klasifikasi Performa UMKM," *Jurnal Sistem Informasi Bisnis*, vol. 13, no. 2, pp. 127–134, Oct. 2023, doi: 10.21456/vol13iss2pp127-134.
- [9] A. Wibowo, B. Santoso, and F. Lestari, "Digital public service transformation in regional investment services," *Journal of E-Government Studies*, vol. 5, no. 1, pp. 33–45, 2023.
- [10] S. R. Kotsiantis, *Supervised Machine Learning: A Review of Classification Techniques*, *Informatica*, vol. 31, no. 3, pp. 249–268, 2022.
- [11] D. G. Blei, A. Y. Ng, and M. I. Jordan, "Latent Dirichlet Allocation," *Journal of Machine Learning Research*, vol. 3, pp. 993–1022, 2003.
- [12] P. Tan, M. Steinbach, and V. Kumar, *Introduction to Data Mining*, 2nd ed. Boston: Pearson, 2018.
- [13] M. B. M. S. Sadiku, "Data mining: Concepts and techniques," *IEEE Potentials*, vol. 22, no. 3, pp. 18–22, 2003.
- [14] B. K. Gupta and R. Gupta, "Analysis of Large-Scale Data Using XGBoost," *International Journal of Computer Applications*, vol. 176, no. 12, pp. 15–22, 2022.
- [15] T. Y. Zhang, H. K. Law, and W. H. Lo, "Improved XGBoost for Classification with Feature Selection," *Data Science and Engineering*, vol. 3, no. 4, pp. 211–225, 2023.
- [16] S. A. Alqahtani, M. H. Saeed, and R. A. K. S. Alwahedi, "A Survey of Machine Learning Approaches for Predictive Modeling of E-Government Services," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 5, pp. 219–227, 2021.
- [17] R. B. D. Yadav, "AI for Public Service Optimization in Indonesia," *Journal of Artificial Intelligence and Data Science*, vol. 4, no. 1, pp. 45–60, 2024.
- [18] B. J. S. C. Murphy, A. Sharma, and D. K. Rajendran, "Optimization Algorithms for Machine Learning Models in Public Sector Applications," *Journal of Public Administration Research and Theory*, vol. 30, no. 2, pp. 102–115, 2020.
- [19] J. H. M. W. Khan, K. Y. Bansal, and T. V. J. C. Singh, "Improved XGBoost-based Predictive Model for Government Services," *International Journal of Public Sector Innovation*, vol. 11, no. 4, pp. 201–212, 2023.
- [20] M. K. I. Sharma and R. K. Gupta, "Application of Decision Trees in Public Sector Digitalization," *International Journal of Public Services*, vol. 9, no. 3, pp. 56–68, 2022.
- [21] M. S. H. B. Fernandes, "Evaluation of Public Service Performance with Machine Learning Algorithms," *Government Technology Journal*, vol. 16, no. 1, pp. 122–134, 2021.
- [22] L. A. Wang and T. T. X. Nguyen, "Optimizing Public Services through Machine Learning Algorithms," *Journal of Government and Policy Studies*, vol. 19, no. 2, pp. 150–162, 2023.
- [23] N. S. Biswas, A. R. S. Ahuja, "Optimizing Government Mentoring Programs with Machine Learning Models," *Journal of Government Technology*, vol. 4, no. 1, pp. 50–60, 2022.
- [24] L. K. Ng, T. S. Y. Li, and D. T. S. Lin, "Machine Learning in Government Decision-Making," *International Journal of Digital Governance*, vol. 8, no. 3, pp. 99–110, 2023.
- [25] S. M. S. Fatima and L. Y. Nasir, "AI Models for Public Service Improvement," *Journal of Artificial Intelligence Applications*, vol. 2, no. 2, pp. 70–84, 2024.