

Penerapan XGBoost untuk Prediksi Status Pelanggan di PT XYZ dan Pencegahan Churn Berdasarkan Riwayat Interaksi Customer Service

I Gede Wisnu Tangkas Gapara¹, Agus Adi Putrawan², Ni Nyoman Harini Puspita³

^{1,2,3}Program Studi Sarjana Terapan Teknologi Rekayasa Perangkat Lunak, Jurusan Teknologi Informasi, Politeknik Negeri Bali, Indonesia

¹wisnutangkas@gmail.com, ²putrawanagusadi@pnb.ac.id, ³mangari@pnb.ac.id

Abstrak

Berlangganan saat ini merupakan salah satu bisnis ekonomi digital yang bergerak di berbagai sektor industri seperti layanan telekomunikasi. Perubahan ini mempengaruhi industri untuk memprediksi dan mencegah pelanggan berhenti berlangganan (*churn*), ini dipengaruhi oleh biaya untuk akuisisi pelanggan baru mencapai 5 hingga 25 kali lebih tinggi daripada retensi. Tujuan utama dari penelitian ini yaitu mengimplementasikan algoritma *eXtreme Gradient Boosting* (XGBoost) dengan fokus pada penanganan ketidakseimbangan data melalui teknik *Synthetic Minority Oversampling Technique* (SMOTE) sebagai solusi otomatisasi deteksi pelanggan *churn* menggunakan hasil percakapan dari pelanggan dengan *customer service*. Fitur yang di gunakan dalam model ini mencakup skor *sentiment*, kendala jaringan, permasalahan penagihan. Data latih sebanyak 11.388 entri di seimbangkan menggunakan SMOTE untuk memastikan representasi yang adil antara kelas pelanggan setia dan pelanggan yang *churn*. Pengujian dilakukan dengan menerapkan ambang batas probabilitas (*threshold*) sebesar 0,4 lebih rendah dari standar 0,5. Penyesuaian ini bertujuan untuk meningkatkan sensitivitas deteksi agar lebih agresif dalam mendeteksi risiko *churn* dini, mengingat risiko *false negative* memiliki dampak kerugian yang lebih besar dibandingkan *false positive*. Hasil menunjukkan bahwa model mencapai akurasi sebesar 0.89, dengan tingkat *Precision* sebesar 0.98 dan *Recall* sebesar 0.90. Nilai ROC AUC sebesar 0.893 mengonfirmasi kemampuan model dalam membedakan karakteristik pelanggan secara efektif. Penelitian ini menyimpulkan bahwa kombinasi XGBoost dan SMOTE mampu memberikan prediksi yang andal untuk membantu Perusahaan mengambil langkah preventif dalam menjaga loyalitas pelanggan.

Kata kunci: Churn Prediction, XGBoost, SMOTE, *Machine Learning*, *Sentiment Analysis*.

1. Pendahuluan

Dalam bisnis ekonomi digital yang terus berkembang pesat, berlangganan kini jadi pilihan utama di berbagai sektor seperti *streaming media*, *software*, hingga telekomunikasi. Perubahan ini mempengaruhi perusahaan yang sebelumnya sekadar mengejar penjualan satu kali kemudian membangun hubungan jangka panjang dengan pelanggan. Laporan industri secara konsisten mencatat bahwa biaya akuisisi pelanggan baru, bisa 5 hingga 25 kali lebih tinggi daripada retensi. Situasi ini di perparah sejak tahun 2023, di mana biaya akuisisi melonjak hingga 40% (Imani, Joudaki, et al., 2025), ini disebabkan pemasaran digital yang sudah jenuh dan persaingan global yang semakin ketat (Dr. Lukman Patel, 2025).

Kasus di PT XYZ menunjukkan peningkatan jumlah pelanggan yang melakukan pemutusan layanan dari tahun ke tahun, yang di dorong oleh faktor ketidakpuasan terhadap kualitas layanan, penanganan keluhan yang lambat dan tawaran kompetitif dari pesaing. Pendekatan sering menghasilkan tingkat kesalahan pencatatan yang tinggi karena

keputusan di ambil secara objektif dan analisis yang dihasilkan cenderung hanya menjelaskan kejadian kurang lengkap dan jelas, akibatnya ini menjadi faktor keterlambatan proses penanganan keluhan yang terjadi. Sebaliknya, metode *machine learning* memiliki tingkat fleksibilitas yang lebih tinggi karena mampu mempelajari pola baru secara otomatis dari data historis yang tersedia (De Alwis & Ekanayake, 2025). Pada kenyataanya churn terjadi akibat beberapa faktor yang saling mempengaruhi secara bersamaan dan bersifat tidak berurutan penelitian saat ini menggunakan data pelanggan layanan internet (Fixed Broadband) yang memiliki karakteristik perilaku penggunaan data yang berbeda (Maulana & Hidayati, 2025). Oleh karena itu, algoritma *eXtreme Gradient Boosting* (XGBoost) algoritma ini tidak hanya menawarkan akurasi prediksi yang superior, tetapi juga kemampuan untuk menangani data yang tidak lengkap dan fitur yang saling berkorelasi, yang merupakan karakteristik umum dari *dataset* telekomunikasi (Imani, Beikmohammadi, et al., 2025). Tantangan teknis terbesar dalam pengembangan

system prediksi churn adalah sifat alami *dataset* yang sangat tidak seimbang. Sebagai contoh, jika 95% pelanggan adalah pelanggan setia maka sebuah model naif yang memprediksi “Tidak Churn” untuk semua pelanggan akan mencapai tingkat akurasi 95% (Seymen et al., 2023). Secara statistik angka ini terlihat mengesankan, namun secara bisnis model sama sekali tidak berguna karena gagal mendeteksi satu-pun pelanggan yang berisiko churn yang seharusnya adalah tujuan utama dari system tersebut (Agiwal, 2025). Oleh karena itu latar belakang pengembangan system ini menekankan pada penggunaan teknik *resampling* data yang canggih, khususnya *Synthetic Minority Oversampling Technique* (SMOTE). Sebagai alternatif dari metode oversampling tradisional yang hanya menduplikasi observasi lama, algoritma SMOTE beroperasi dengan cara mensintesis titik data baru berdasarkan karakteristik data aslinya yang masuk akal secara statistik di antara sampel-sampel minoritas yang ada, sehingga memperkaya ruang fitur tanpa menyebabkan *overfitting* yang berlebihan. Penelitian terbaru tahun 2024 membuktikan bahwa kombinasi algoritma XGBoost dengan teknik SMOTE mampu menghasilkan keseimbangan optimal antara *Precision* dan *Recall*, memberikan kinerja terbaik dalam mendeteksi pelanggan berisiko tinggi (Andespa et al., 2025).


Dengan permasalahan dan peluang teknologi yang didapat, pembaharuan dari penelitian ini ditekankan pada pemanfaatan fitur analisis *sentiment* dari teks interaksi *customer service*, berbeda dengan studi terdahulu yang mayoritas bergantung pada data numerik historis. Oleh karena itu, penelitian ini secara spesifik difokuskan pada upaya pengembangan serta membangun sebuah model prediksi churn secara akurat dan dapat diinterpretasikan, yang tidak hanya menjawab kebutuhan akademis tetapi juga memberikan solusi praktis bagi tantangan industri telekomunikasi di Indonesia.

2. Metode

Proses penelitian ini dimulai dengan pengumpulan *dataset* pada PT XYZ dengan jumlah *dataset* aktual sebanyak 11.388 kemudian diikuti dengan proses *preprocessing* yang mencakup *data collection*, *data cleaning* dan penyeimbangan data menggunakan SMOTE. Setelah proses tersebut selesai, data akan dipisahkan menjadi bagian pelatihan (*training*) dan pengujian (*testing*) untuk dimodelkan menggunakan algoritma XGBoost. Langkah terakhir dari penelitian ini adalah menguji seberapa baik kinerja model yang telah dibuat. Alur lengkap mengenai tahapan analisis data ini dapat dilihat lebih jelas pada Gambar 1.

A. Pre-Processing

Tahapan pre-processing bertindak sebagai pilar utama pada penambahan data, dengan tujuan inti




Gambar 1. Teknik Analisis Data

untuk memodifikasi informasi awal ke dalam bentuk yang lebih terstruktur dan siap olah. Mengingat sekumpulan data awal umumnya dikumpulkan dari berbagai sumber, tidak jarang ditemukan anomali seperti missing values, kecacatan, maupun ketidakkonsistenan informasi. Oleh sebab itu, standarisasi dan pembersihan kualitas data mutlak dilakukan untuk menjamin tingkat presisi serta keandalan hasil akhir dari analisis yang dilakukan (Wahyu et al., 2025). Tahapan yang dilakukan sebagai berikut.

1) Data Collection

Pada tahap ini adalah mengumpulkan data yang relevan. Penelitian ini mengambil data dari PT XYZ hasil pencatatan dari *customer service*. Tahapan proses pengolahan data yang digunakan pada penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Visualisasi Data Collection

Pada Gambar 2 terlihat hasil pengumpulan data dari hasil interaksi antara *customer service* dengan pelanggan selama periode Januari 2024 – Januari 2026 dengan total 11.388 data. *Dataset* memiliki lima atribut fitur, yaitu catatan keluhan pelanggan, keterangan dihubungi, minat *callback* dan alasan pelanggan, serta satu label target berupa status churn. Label target terdiri dari dua kelas yaitu '1' mewakili pelanggan 'Churn' sebanyak 10274 dan '0' mewakili pelanggan 'Non-Churn' sebanyak 1114.

2) Data Cleaning


Data cleaning merupakan pengolahan data yang sebelumnya sudah di peroleh dengan cara menghapus data yang duplikat, data kosong, karakter khusus, memperbaiki dan menyamakan format data bertujuan untuk memastikan data tidak ada kesalahan dalam formatnya sehingga mendapatkan hasil akurat pada model (Ramadhan et al., 2023). Kemudian diekstraksi menjadi fitur numerik proses ini menghasilkan variabel *sentiment_score*, *network_issue*,

billing_issue, *competitor_mention*, dan label *churn*.

Dalam tahapan ekstraksi informasi dari data tidak terstruktur berupa riwayat percakapan layanan pelanggan memerlukan penanganan khusus. Pendekatan ini mengimplementasikan teknik Natural Language Processing (NLP) berbasis bahasa pemrograman Python guna menganalisis makna dan konteks semantik dari setiap percakapan. Melalui serangkaian pemrosesan tekstual tersebut, naskah mentah hasil interaksi pelanggan berhasil dikonversi secara komputasional menjadi metrik *sentiment score*, serta ditransformasikan ke dalam representasi fitur numerik maupun biner yang siap diumpukan sebagai variabel prediktor pada pemodelan klasifikasi.

3) Imbalance handling dengan SMOTE

Synthetic Minority Over-Sampling Technique (SMOTE) proses ini bertujuan untuk menyamakan ketidakseimbangan kelas pada *dataset* dengan membuat sampel sintesis dari kelas minoritas dengan cara menemukan tetangga terdekatnya dan menginterpolasi nilai fitur untuk menghasilkan sampel baru sehingga model dapat lebih akurat dalam memprediksi kelas minoritas (Masruriyah et al., 2023). Arsitektur model yang diterapkan dalam penelitian ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi SMOTE

Pada Gambar 3 terlihat data sudah diseimbangkan menggunakan teknik SMOTE sehingga terlihat pelanggan tidak *churn* bertambah sebanyak 10.274 dan pelanggan *churn* tetap sebanyak 10.274.

B. Split Data

Proses selanjutnya melibatkan pemisahan *dataset* ke dalam proporsi kelompok data pelatihan dan pengujian sebagai dasar untuk memvalidasi tingkat keandalan dari model prediksi secara objektif. Dengan menggunakan metode *train_test_split*, dialokasikan 80% data sebagai basis pembelajaran pola dan 20% sisanya sebagai evaluasi kinerja (Aryanti et al., 2023). Strategi pembagian diterapkan untuk memvalidasi model supaya tidak menghafal (*over-fitting*), tetapi memberikan prediksi akurat terhadap data yang belum di kenal.

C. Modelling

Penelitian ini menggunakan algoritma XGBoost untuk memprediksi status pelanggan dan mencegah *churn*. XGBoost membangun serangkaian pohon keputusan secara iteratif, di mana setiap pohon baru dilatih untuk memperbaiki kesalahan prediksi (*residual error*) dari pohon sebelumnya (Mazdadi et al., 2026). Algoritma XGBoost digunakan dalam penelitian ini mengingat keunggulannya saat memproses data tidak seimbang melalui pendekatan *boosting iterative*, di samping kemampuannya untuk menaikkan nilai bobot pada data yang salah diklasifikasikan setiap kali proses iterasi dilakukan. XGBoost efisien dalam memproses *dataset* berukuran besar dan memiliki kemampuan optimasi yang baik untuk meningkatkan akurasi prediksi secara bertahap (Wakhidah et al., 2025).

D. Evaluation

Proses evaluasi dilakukan menggunakan *confusion matrix* mengingat adanya potensi ketidakseimbangan data (*imbalanced data*), *F1-score* digunakan sebagai penyeimbang antara *precision* dan *recall*. Nilai ROC AUC dihitung untuk melihat seberapa baik model bisa memisahkan kelompok pelanggan yang *churn* dan tidak *churn* di titik batas prediksi. Semakin tinggi skor yang didapat, berarti kinerja model tersebut semakin bagus. Secara keseluruhan, langkah pengujian ini dilakukan untuk memastikan seberapa tepat model mampu meramalkan pelanggan yang akan berhenti berlangganan.

Metode *confusion matrix* diimplementasikan untuk meninjau kualitas model klasifikasi melalui penyajian detail mengenai ketepatan dan kesalahan hasil klasifikasi yang dilakukan oleh sistem (Sidiq & Anggraini, 2023). Matriks ini merinci performa model melalui empat parameter utama: *True Positives* (TP) yang menunjukkan keberhasilan model dalam memprediksi pelanggan *churn*; *True Negatives* (TN) untuk prediksi tepat pada kelas *non-churn*; *False Positives* (FP) yang merepresentasikan kesalahan model dalam memprediksi *churn* pada data aktual yang stabil, serta *False Negatives* (FN) yang menunjukkan kegagalan model dalam mendeteksi pelanggan yang sebenarnya melakukan *churn*. Melalui pemetaan ini, akurasi dan presisi klasifikasi model dapat dievaluasi secara lebih mendalam.

3. Hasil dan Pembahasan

Pada tahap awal data telah melalui berbagai proses hingga penyeimbangan kelas menggunakan metode SMOTE. Metode SMOTE dipilih karena bisa menambah jumlah data pada kelompok minoritas tanpa harus membuang data dari kelompok mayoritas. Cara ini lebih aman dibandingkan prosedur pemotongan data yang dapat mengakibatkan ter-

buangnya informasi berharga. Dengan mengadopsi teknik SMOTE, jumlah data antar kelompok menjadi lebih seimbang sehingga model bisa belajar dengan lebih baik. Melalui pendekatan ini proporsi kelas minoritas yang awalnya timpang dapat diseimbangkan. Hal ini berdampak positif pada peningkatan akurasi dan daya generalisasi model. Implementasi ini memegang peranan penting untuk analisis *churn*, mengingat ketimpangan data yang ekstrem sering kali memicu bias algoritma terhadap kelas mayoritas. Setelah proses penyeimbangan tahap berikutnya melibatkan pemisahan himpunan data menjadi dua bagian utama. Sebanyak 80% dari total observasi digunakan untuk proses pelatihan algoritma, sedangkan 20% sisanya disisihkan untuk keperluan evaluasi model.

Ketergantungan terhadap metrik akurasi semata dapat menimbulkan interpretasi yang menyesatkan pada *dataset* yang tidak seimbang, mengingat prediksi model rentan didominasi oleh kelas mayoritas. Sebagai solusinya, evaluasi diperluas menggunakan metrik *precision* dan *recall* untuk mengukur tingkat ketepatan serta sensitivitas model dalam mengidentifikasi pelanggan *churn*. Keseimbangan antara kedua metrik tersebut kemudian diukur melalui F1-score. Sementara itu, ketangguhan model ketika mendiskriminasikan pelanggan *churn* dan pelanggan tidak *churn* pada berbagai titik ambang keputusan (*threshold*) dievaluasi menggunakan ROC AUC, kombinasi dari seluruh metrik ini menjamin bahwa model yang di bangun tidak sekadar memiliki akurasi global yang tinggi, tetapi juga terbukti efektif dalam mendeteksi potensi *churn*.

Tahap pengujian diawali dengan melakukan penilaian terhadap kinerja algoritma XGBoost secara keseluruhan. Rincian hasil pengukuran yang mencakup metrik evaluasi standar seperti tingkat akurasi, *precision*, *recall*, dan F1-score guna mengukur kemampuan sistem dalam memprediksi status pelanggan disajikan secara lengkap pada gambar berikut.

	precision	recall	f1-score	support
No Churn	0.46	0.81	0.59	279
Churn	0.98	0.90	0.94	2568
accuracy			0.89	2847
macro avg	0.72	0.86	0.76	2847
weighted avg	0.93	0.89	0.90	2847

Gambar. Hasil Evaluasi XGBoost
Gambar 4. Evaluasi XGBoost

Hasil evaluasi yang ditunjukan pada Gambar 4 implementasi SMOTE efektif dalam mengatasi ketimpangan data, sehingga mampu meningkatkan reliabilitas prediksi dan stabilitas model. Model XGBoost terlihat mempunyai performa yang baik dengan nilai akurasi 0.89 dan skor AUC ROC sebesar 0.893, yang menunjukkan tingkat pemisahan kelas yang sangat kuat (Adji Purnama et al., 2024). Peningkatan sig-

nifikan pada metrik *recall* 0.90 menegaskan efektivitas XGBoost dalam mengenali karakteristik pelanggan yang cenderung *churn* dibandingkan algoritma lainnya. Mengingat pelanggan *churn* merupakan kelas minoritas, kemampuan model untuk meminimalisir kesalahan klasifikasi pada sektor ini menjadi prioritas utama guna memastikan strategi retensi pelanggan dapat dilakukan secara tepat sasaran. Fokus utama pemodelan ini bukanlah pencapaian akurasi total semata, melainkan seberapa sensitif model mampu mendeteksi potensi *churn*. Secara keseluruhan, XGBoost secara konsisten menunjukkan ketajamannya dalam mengklasifikasikan kelompok pelanggan yang akan berhenti berlangganan. Oleh karena itu, instrumen prediksi ini sangat direkomendasikan sebagai alat yang andal untuk mengoptimalkan efisiensi strategi retensi pada industri telekomunikasi.

Untuk mengevaluasi kestabilan model, dilakukan validasi menggunakan metode *cross validation* disajikan secara lengkap pada Tabel 1.


Tabel 1. Cross Validation

Fold	Accuracy	Precision	Recall	F1-Score	ROC-AUC
Fold 1	0.88	0.97	0.89	0.93	0.89
Fold 2	0.89	0.97	0.91	0.94	0.90
Fold 3	0.88	0.97	0.90	0.93	0.86
Fold 4	0.88	0.98	0.89	0.93	0.90
Fold 5	0.89	0.97	0.90	0.93	0.87
Rata-Rata	0.89	0.97	0.90	0.93	0.88

Mengingat distribusi kelas yang tidak seimbang, teknik SMOTE diterapkan melalui *Pipeline*, sehingga proses oversampling dilakukan hanya pada data pelatihan di setiap fold tanpa memengaruhi data validasi. Hasil pengujian menunjukkan rata-rata *Accuracy* sebesar 0,89, *Precision* 0,97, *Recall* 0,90, F1-score 0,93, dan ROC-AUC 0,88. Nilai tersebut menunjukkan bahwa model memiliki performa yang konsisten dalam mendeteksi pelanggan yang berpotensi melakukan *churn*. Tingginya metrik *Precision* dan *Recall* ini mengindikasikan bahwa sistem tidak hanya akurat, tetapi juga memiliki tingkat sensitivitas yang presisi sekaligus mampu menekan jumlah kesalahan prediksi palsu.

Untuk membedah lebih dalam karakteristik performa dari algoritma XGBoost tersebut, evaluasi lanjutan dilakukan dengan memetakan hasil prediksi ke dalam *confusion matrix*. Jika metrik evaluasi sebelumnya memberikan gambaran performa secara agregat dalam bentuk persentase probabilitas, *confusion matrix* berperan untuk menyajikan rincian kuantitas secara absolut. Melalui matriks ini, distribusi prediksi model dapat dianalisis secara transparan, mencakup jumlah prediksi yang tepat sasaran maupun kesalahan klasifikasi pada masing-masing kelas. Detail lengkap mengenai komparasi antara label aktual pelanggan dengan hasil dapat dilihat pada gambar

berikut.




Gambar 5. Confusion Matrix XGBoost

Pada Gambar 5 terdapat rincian mengenai seberapa banyak tebakan yang dijawab dengan tepat maupun keliru oleh algoritma pada masing-masing kategori. Penggunaan *Confusion Matrix* ini sangat membantu dalam memvisualisasikan persebaran hasil prediksi model, khususnya saat menangani kasus *dataset* dengan proporsi kelas yang asimetris, layaknya isu perpindahan pelanggan di bidang telekomunikasi. Melalui tahapan penilaian ini, indikator *True Positives* (TP) mempresentasikan tingkat keberhasilan pada algoritma dalam mengidentifikasi pelanggan yang secara faktual melakukan *churn*. Sebaliknya, kegagalan sistem mengenali pelanggan yang keluar direpresentasikan oleh *False Negatives* (FN). Minimalisasi angka FN sangatlah krusial tingginya kegagalan deteksi ini berarti hilangnya peluang Perusahaan untuk melakukan langkah retensi preventif. Di sisi lain, parameter sementara metrik *True Negatives* (TN) beserta *False Positives* (FP) diimplementasikan untuk mengevaluasi tingkat efisiensi operasional pemodelan. kesalahan klasifikasi berupa FP berisiko mengakibatkan pemborosan sumber daya dan anggaran pada pelanggan yang pada dasarnya loyal. Sebagai pelengkap analisis komprehensif, metrik ROC AUC diimplementasikan untuk mengukur sejauh mana keandalan model dalam mendiskriminasi antara kelompok *churn* dan pelanggan aktif (*non-churn*). Visualisasi kurva tersebut mengilustrasikan titik keseimbangan (*trade-off*) antara metrik *True Positive Rate* dengan *False Positive Rate* melintasi bermacam nilai ambang keputusan.

Berdasarkan *confusion matrix*, model XGBoost masih menghasilkan 53 kasus *False Positive* dan 257 kasus *False Negative*. Jumlah tersebut menunjukkan bahwa sebagian kecil pelanggan masih mengalami kesalahan klasifikasi. Meskipun demikian, model tetap mampu mengidentifikasi sebagian besar pelanggan *churn* dengan nilai *Recall* sebesar 90%, yang menunjukkan bahwa mayoritas pelanggan yang berpotensi *churn* berhasil diprediksi dengan benar. Kesalahan prediksi yang masih terjadi

kemungkinan disebabkan oleh adanya karakteristik pelanggan *churn* yang memiliki kemiripan dengan pelanggan yang tidak *churn*, sehingga model mengalami kesulitan dalam membedakan kedua kelompok tersebut. Oleh karena itu, penelitian selanjutnya dapat difokuskan pada penambahan fitur yang lebih representatif dan optimasi hyperparameter untuk meningkatkan kemampuan model dalam mengurangi kesalahan prediksi.


Selain *confusion matrix*, kinerja model dalam membedakan kelas *churn* dan loyal juga dievaluasi berdasarkan nilai ROC AUC. Hasil visualisasi perbandingan *True Positive Rate* dan *False Positive Rate* ditunjukkan pada gambar berikut.



Gambar 6. ROC Curve XGBoost

Pada Gambar 6 menyajikan visualisasi kurva ROC Curve dari algoritma XGBoost, yang bertujuan untuk memaparkan performa prediksi model secara grafis. Pemilihan ROC AUC dipilih karena fungsinya yang mampu memvalidasi ketangguhan model dalam memisahkan kategori pelanggan yang berhenti dengan pelanggan loyal pada berbagai tingkatan batas probabilitas. Di lingkungan bisnis telekomunikasi, akurasi pengenalan pelanggan yang berisiko keluar sangat dibutuhkan untuk memandu Perusahaan dalam memfokuskan strategi retensi secara efisien dan hemat sumber daya. Capaian ROC AUC yang menyentuh angka 0.893 merupakan indikator kuat bahwa algoritma memiliki daya pisah (*class separation*) yang sangat presisi. Keandalan hasil prediksi ini pada akhirnya memberikan landasan yang kokoh bagi pemangku kepentingan untuk mengambil keputusan manajerial yang tepat. Algoritma XGBoost yang menerapkan konsep *gradient boosting* dikenal lebih tangguh saat dihadapkan pada masalah data yang timpang. Hal ini dikarenakan model tersebut memiliki kemampuan untuk memprioritaskan, atau memberikan nilai bobot yang lebih tinggi, pada data dari kelompok minoritas ketika proses pembelajaran (*training*) sedang berlangsung. Hasil evaluasi model berdasarkan metrik kinerja yang digunakan dapat diamati pada Gambar 7.

Berbeda dengan penelitian sebelumnya yang



Gambar 7. Feature Importance XGBoost

umumnya menggunakan data numerik pelanggan seperti usage dan billing history, penelitian ini memanfaatkan hasil interaksi *customer service* berbasis *sentiment* analisis sebagai fitur utama prediksi churn. Pendekatan ini memungkinkan deteksi churn dilakukan lebih dini berdasarkan pola komunikasi pelanggan. Pada Gambar 7 menunjukkan *feature importance* XGBoost dimana algoritma ini terdapat atribut-atribut krusial yang paling berdampak dalam mengenali potensi berhentinya pelanggan dari layanan telekomunikasi. Adapun *variable-variable* yang memiliki kontribusi paling dominan dalam memprediksi churn pelanggan. Hasil ekstraksi algoritma menyoroti bahwa *sentiment_score* dan *competitor_mention* merupakan dua atribut prediktor yang menduduki peringkat probabilitas tertinggi disusul oleh indikator kendala seperti *billing_issue* dan *network_issue*. Signifikansi dari parameter-parameter ini menunjukkan betapa krusialnya aspek persepsi pelanggan dan pengaruh kompetitor dalam mendefinisikan pola perilaku konsumen. Pemahaman komprehensif terhadap metrik tersebut akan membekali penyedia layanan telekomunikasi dengan landasan empiris untuk menyusun program retensi yang jauh lebih proaktif akurat dan berbasis pada data.

1. *sentiment_score* ini muncul sebagai prediktor utama dengan bobot signifikansi tertinggi dalam pemodelan XGBoost. Dominasi *variable* ini mengindikasikan bahwa kondisi emosional dan evaluasi subjektif pelanggan terhadap kualitas layanan memegang peranan paling fundamental dalam memicu keputusan *churn*. Ketika interaksi atau keluhan pelanggan direpresentasikan oleh *sentiment* yang sangat negatif, probabilitas mereka untuk menghentikan layanan akan tereskalasi secara drastis. Dari perspektif manajerial, metrik *sentiment* ini beroperasi sebagai indikator holistik yang memotret akumulasi pengalaman konsumen terhadap ekosistem perusahaan. Atas dasar pertimbangan inilah pihak penyedia layanan memiliki ugens untuk mengadopsi system deteksi *sentiment* secara *real-time* guna memfasilitasi intervensi persuasive sedini mungkin sebelum pelanggan mencapai titik frustrasi puncak.

Pada penelitian ini, fitur *sentiment_score* diperoleh menggunakan pendekatan rule-based berbasis kata kunci, sehingga tidak menggunakan model analisis sentimen seperti VADER, TextBlob, maupun model pretrained bahasa Indonesia. Proses perhitungan diawali dengan mengubah seluruh teks ulasan menjadi huruf kecil (*lowercase*), kemudian sistem mencocokkan kata-kata pada ulasan dengan kamus yang terdiri dari 8 kata positif (baik, bagus, senang, puas, suka, terima kasih, oke, dan setuju) serta 8 kata negatif (tidak, buruk, jelek, marah, kecewa, batal, komplain, dan masalah). Selanjutnya, nilai *sentiment_score* dihitung berdasarkan perbandingan jumlah kata positif terhadap total kata positif dan negatif, sedangkan apabila tidak ditemukan kata yang sesuai, sistem memberikan nilai 0,5 sebagai nilai netral. Skor yang dihasilkan berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan sentimen yang lebih positif, sedangkan nilai yang mendekati 0 menunjukkan sentimen yang lebih negatif. Nilai *sentiment_score* tersebut kemudian digunakan secara langsung sebagai fitur numerik pada model XGBoost.

2. *competitor_mention* menunjukkan Tingkat urgensi yang hampir setara dengan *sentiment* pelanggan. Tingginya kontribusi fitur ini dalam algoritma menegaskan bahwa eksplorasi atau penyebutan merek kompetitor oleh pelanggan saat berinteraksi dengan layanan pelanggan merupakan sinyal bahaya yang sangat nyata bagi retensi. Pelanggan yang secara eksplisit membandingkan pelayanan saat ini dengan alternatif di pasar pada umumnya sudah berada pada fase transisi sebelum benar-benar melakukan perpindahan (*churn*). Untuk memitigasi ancaman eksternal ini, pihak manajemen perlu merancang strategi pertahanan (*defensive strategy*) yang adaptif seperti penawaran promosi tandingan atau kampanye *winback* yang dikustomisasi ketika pelanggan mulai mengarah pada penyedia layanan pesaing.
3. *billing_issue* turut memberikan dampak yang substansial terhadap hasil prediksi model. Kendala terkait administrasi tagihan baik berupa ketidaksesuaian tarif kegagalan system pembayaran, maupun kurangnya transparansi rincian biaya sering kali menjadi bertindak sebagai titik gesekan utama yang menggerus kepercayaan pelanggan secara perlahan. Meskipun bobot pengaruhnya tidak semasif faktor *sentiment* atau ketertarikan pada kompetitor kompilasi finansial semacam ini berisiko memperburuk persepsi loyalitas jika dibiarkan berlarut-larut. Langkah penyelesaian yang direkomendasikan adalah optimalisasi akurasi penagihan otomatis serta

penyediaan jalur resolusi sengketa tagihan yang sangat responsif dan transparan.

4. *network_issue* teridentifikasi sebagai salah satu elemen penentu dalam struktur pengambilan keputusan model XGBoost. Di dalam lanskap industri telekomunikasi, stabilitas jaringan merupakan inti dari nilai layanan yang dijual (*core product*). Intensitas gangguan konektivitas, latensi yang tinggi, atau hilangnya sinyal terbukti berkontribusi terhadap degradasi pengalaman pengguna. Meskipun dalam hierarki grafik posisinya berada di bawah kendala administratif (*billing*), akumulasi dari masalah teknis jaringan yang tidak teratasi berpotensi memicu efek domino; di mana gangguan ini secara berantai akan menurunkan skor *sentiment* pelanggan dan pada akhirnya mengakselerasi tingkat *churn*.

Hasil analisis *feature importance* secara keseluruhan menunjukkan adanya informasi strategis yang penting bagi perusahaan dalam memahami faktor-faktor utama yang mempengaruhi churn pelanggan. Aspek seperti pengelolaan biaya layanan, lama penggunaan layanan, kualitas layanan yang diberikan, serta fleksibilitas kontrak memiliki kontribusi besar terhadap tingkat loyalitas pelanggan. Melalui pemahaman terhadap tingkat pengaruh masing-masing faktor penentu dalam algoritma klasifikasi churn, entitas penyedia jasa telekomunikasi dapat menyusun strategi retensi yang lebih efektif dan terarah. Upaya tersebut diharapkan mampu meningkatkan kepuasan pelanggan, menekan potensi churn, serta mendukung peningkatan upaya mempertahankan pelanggan sekaligus menjaga keberlanjutan finansial perusahaan secara jangka panjang.

4. Kesimpulan

Kesimpulan dari studi ini menyoroti keberhasilan algoritma SMOTE sebagai solusi efektif untuk menangani asimetri data klasifikasi. Keberhasilan penyeimbangan kelas tersebut berbanding lurus dengan melonjaknya tingkat akurasi sistem deteksi dini *churn* di sektor telekomunikasi. Pemodelan prediktif yang dibangun menggunakan algoritma XGBoost mendemonstrasikan keandalan yang sangat baik, dibuktikan dengan capaian akurasi sebesar 0.89 dan skor ROC AUC mencapai 0.89. Kinerja tersebut merepresentasikan kapabilitas model yang sangat presisi dalam membedakan pelanggan yang akan berhenti berlangganan.

Analisis ekstraksi fitur pada XGBoost mengungkap bahwa probabilitas *churn* sangat dipengaruhi oleh persepsi pelanggan dan kualitas layanan. *Sentiment_score* dan *Competitor_mention* teridentifikasi sebagai prediktor paling dominan, diikuti oleh *billing_issue* dan *network_issue*. Temuan ini menegaskan bahwa akumulasi *sentiment negative* yang

kerap kali dipicu oleh kendala *administrative* maupun gangguan teknis jaringan akan mendorong pelanggan mencari alternatif penyedia layanan pesaing. Secara praktis, implikasi dari penelitian ini menuntut perusahaan telekomunikasi untuk beralih dari pendekatan reaktif menjadi proaktif. Manajemen perlu memprioritaskan sistem pemantauan *sentiment* pelanggan secara *real-time*, mempercepat resolusi sengketa tagihan, serta memastikan stabilitas jaringan. Dengan merespon keluhan secara cepat dan memberikan penawaran tandingan yang kompetitif, perusahaan dapat menekan tingkat churn secara signifikan sekaligus merestorasi kepercayaan pelanggan.

Dalam penelitian mendatang disarankan untuk memperluas skala *dataset* secara longitudinal (pengambilan data berlanjut dan dalam jangka waktu panjang) dan mengeksplorasi penambahan fitur *sentiment* multimodal (penggabungan beberapa tipe data, seperti teks dan audio), seperti pengenalan emosi berbasis suara (*voice recognition*). Selain itu, pengujian komparatif menggunakan arsitektur *Deep Learning* juga sangat direkomendasikan guna memvalidasi skalabilitas dan konsistensi model pada lingkungan operasional yang lebih kompleks.

Daftar Pustaka

- Adji Purnama, M., Ramadhani, J., Safitra Anugraha, Y., Efrizoni, L., & Sains Dan Teknologi Indonesia, U. (2024): *Perbandingan Performa Algoritma Random Forest Dan Gradient Boosting Dalam Mengklasifikasi Churn Telco Comparison Of Performance Of Random Forest And Gradient Boosting Algorithm In Classifying Telco Churn*, In Agustus (Vol. 23, Number 3).
- Agiwal, R. (2025): *Comparative Analysis of Machine Learning Algorithms for Customer Churn Prediction*, In International Journal of Scientific Research & Engineering Trends (Vol. 11, Number 2).
- Andespa, R., Sadik, K., Suhaeni, C., & Soleh, A. M. (2025): *Evaluating Random Forest and XGBoost for Bank Customer Churn Prediction on Imbalanced Data Using SMOTE and SMOTE-ENN*, Media Statistika, 18(1), 25–36. <https://doi.org/10.14710/medstat.18.1.25-36>
- Aryanti, R., Misriati, T., & Sagiyanto, A. (2023): *Analisis Sentimen Aplikasi Primaku Menggunakan Algoritma Random Forest dan SMOTE untuk Mengatasi Ketidakseimbangan Data*, Journal of Computer System and Informatics (JoSYC), 5(1), 218–227. <https://doi.org/10.47065/josyc.v5i1.4562>
- De Alwis, S., & Ekanayake, I. (2025): *Explainability, risk modeling, and segmentation based customer churn analytics for personalized retention in e-commerce*, <http://arxiv.org/abs/2510.11604>
- Dr. Lukman Patel. (2025): *AI-Enabled Customer Acquisition and Retention in Entrepreneurial Ven-*

- tures, In JETIR2503985 Journal of Emerging Technologies and Innovative Research (Vol. 12). www.jetir.org
- Imani, M., Beikmohammadi, A., & Arabnia, H. R. (2025): *Comprehensive Analysis of Random Forest and XGBoost Performance with SMOTE, ADASYN, and GNUS Under Varying Imbalance Levels*, Technologies, 13(3). <https://doi.org/10.3390/technologies13030088>
- Imani, M., Joudaki, M., Beikmohammadi, A., & Arabnia, H. R. (2025): *Customer Churn Prediction: A Systematic Review of Recent Advances, Trends, and Challenges in Machine Learning and Deep Learning*, In Machine Learning and Knowledge Extraction (Vol. 7, Number 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/make7030105>
- Masruriyah, A. F. N., Novita, H. Y., Sukmawati, C. E., Arif, S. N. N., & Ramadhan, A. R. (2023): *Evaluasi Algoritma Pembelajaran Terbimbing terhadap Dataset Penyakit Jantung yang telah Dilakukan Oversampling*, Journal MIND Journal | ISSN, 8(2), 242–253. <https://doi.org/10.26760/mindjournal.v8i2.242-253>
- Maulana, B. A., & Hidayati, N. (2025): *Churn Prediction in Credit Customers Using Random Forest and XGBoost Methods*, Indonesian Journal of Data and Science, 6(1), 82–90. <https://doi.org/10.56705/ijodas.v6i1.215>
- Mazdadi, M. I., Saragih, T. H., Budiman, I., & Anshory, M. N. (2026): *JIP (Jurnal Informatika Polinema) Peningkatan Akurasi Model Boosting pada Prediksi Kesehatan Tidur Menggunakan Optuna*, 12. <https://www.kaggle.com/datasets/uom190346a/sleep>
- Ramadhan, B., Firdaus, D., & Rafi, A. R. (2023): *MIND (Multimedia Artificial Intelligent Networking Database) Teknik SMOTE Sebagai Solusi Imbalance Class dalam Model Deteksi Intrusi DDoS dengan Metode PCA-Random Forest*, Journal MIND Journal | ISSN, 8(1), 52–64. <https://doi.org/10.26760/mindjournal.v8i1.52-64>
- Seymen, O. F., Olmez, E., Dogan, O., Er, O., & Hiziroglu, A. (2023): *Customer Churn Prediction Using Ordinary Artificial Neural Network and Convolutional Neural Network Algorithms: A Comparative Performance Assessment*, Gazi University Journal of Science, 36(2), 720–733. <https://doi.org/10.35378/gujs.992738>
- Sidiq, M. M., & Angraini, D. (2023): *Analysis and Classification of Customer Churn Using Machine Learning Models*, Jurnal RESTI, 7(6), 1253–1259. <https://doi.org/10.29207/resti.v7i6.4933>
- Wahyu, D., Sakaro, K. H., Sabrina, N., Ramadhan, E., & Kunci, K. (2025): *Klasifikasi Churn Dengan Algoritma XGBoost Menggunakan Feature Selection Boruta-Shap*, Technology and Science (BITS), 7(2), 1193–1201. <https://doi.org/10.47065/bits.v7i2.7965>
- Wakhidah, L. N., Khanif Zyen, A., & Wahono, B. B. (2025): *Evaluation of Telecommunication Customer Churn Classification with SMOTE Using Random Forest and XGBoost Algorithms*, In Journal of Applied Informatics and Computing (JAIC) (Vol. 9, Number 1). <http://jurnal.polibatam.ac.id/index.php/JAIC>