

EVALUASI KINERJA LIGHTGBM DAN CATBOOST UNTUK PREDIKSI CHURN BERDASARKAN DATASET PELANGGAN LAYANAN STREAMING MUSIK

Akge Ninov Royana, Yisti Vita Via, Chrystia Aji Putra
Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur
Jalan Raya Rungkut Madya, Surabaya, Indonesia
yistivia.if@upnjatim.ac.id

ABSTRAK

Industri layanan streaming musik mengalami pertumbuhan yang pesat, namun dengan meningkatnya jumlah pengguna, risiko *churn* atau pelanggan yang berhenti berlangganan juga semakin tinggi. *Churn* dapat berdampak signifikan terhadap pendapatan dan efisiensi biaya akuisisi pelanggan baru, sehingga penting bagi perusahaan untuk mengidentifikasi pelanggan yang berisiko *churn* dengan tepat. Penelitian ini mengusulkan penggunaan dua algoritma pembelajaran mesin berbasis *gradient boosting*, yaitu LightGBM dan CatBoost, untuk memprediksi *churn* pelanggan layanan streaming musik. Model ini dilatih menggunakan dataset Streaming Subscription Churn, dengan menerapkan teknik SMOTE untuk menangani ketidakseimbangan kelas. Evaluasi model dilakukan menggunakan metrik seperti akurasi, presisi, recall, F1-Score, dan AUC-ROC. Hasil penelitian menunjukkan bahwa kedua model memiliki akurasi yang hampir identik, yaitu 84%. Namun, CatBoost unggul dalam *recall* (0.86) dibandingkan LightGBM (0.84), yang menunjukkan kemampuannya yang lebih baik dalam mendeteksi pelanggan berisiko *churn*. Model CatBoost juga memiliki F1-Score 0.85 dan AUC-ROC 0.94, sementara LightGBM memiliki F1-Score 0.84 dan AUC-ROC 0.94. Berdasarkan hasil ini, CatBoost lebih direkomendasikan untuk strategi retensi pelanggan karena lebih efektif dalam mengidentifikasi pelanggan yang berpotensi *churn*.

Kata kunci : *Churn, LightGBM, CatBoost, Prediksi pelanggan, Akurasi*

1. PENDAHULUAN

Perkembangan industri layanan streaming musik mengalami lonjakan yang signifikan dalam beberapa tahun terakhir. Kemajuan teknologi, meningkatnya konektivitas internet, serta adopsi perangkat pintar telah mengubah cara masyarakat menikmati musik. Layanan seperti Spotify, Apple Music, dan YouTube Music kini menjadi pilihan utama dalam mengakses musik secara digital, menggantikan media konvensional seperti radio dan pemutar CD. YouTube Music (44,18%), diikuti oleh Spotify (17,52%), Google Play Music (16,86%), dan Apple Music (1,63%) [1].

Seiring meningkatnya jumlah pengguna, persaingan antarplatform streaming musik juga semakin ketat. Setiap penyedia layanan berupaya mempertahankan pelanggannya dengan menghadirkan konten eksklusif, kualitas audio tinggi, serta pengalaman pengguna yang dipersonalisasi. Namun, persaingan ini juga meningkatkan potensi terjadinya *churn*, yaitu pelanggan yang berhenti berlangganan atau berpindah ke platform lain [2]. *Churn* dapat berdampak signifikan terhadap pendapatan dan efisiensi biaya akuisisi pelanggan baru [3]. Oleh karena itu, pendekatan berbasis teknologi seperti machine learning diperlukan untuk mengidentifikasi pola perilaku pelanggan yang berisiko *churn* agar dapat dilakukan intervensi yang tepat waktu.

Dalam studi ini, dua algoritma pembelajaran mesin berbasis *gradient boosting* digunakan untuk membangun model prediksi *churn*, yaitu LightGBM dan CatBoost. LightGBM dikenal dengan efisiensinya dalam pelatihan model dan penggunaan memori, serta menghasilkan akurasi yang tinggi [4]. Sementara itu,

CatBoost unggul dalam menangani fitur kategorikal tanpa proses *encoding* yang kompleks dan lebih stabil terhadap *overfitting* melalui pendekatan *ordered boosting* [5]. Pemilihan kedua algoritma ini didasarkan pada performa unggul dalam berbagai penelitian terdahulu, terutama dalam menangani permasalahan klasifikasi yang kompleks.

Untuk meningkatkan keandalan model prediksi, penelitian ini juga mempertimbangkan distribusi kelas dalam data. Jika terdapat ketidakseimbangan jumlah antara pelanggan *churn* dan tidak *churn*, maka teknik SMOTE (*Synthetic Minority Over-sampling Technique*) akan diterapkan sebagai langkah praproses. Evaluasi performa model dilakukan menggunakan metrik seperti akurasi, presisi, *recall*, *f1-score*, dan AUC-ROC (*Area Under the Curve*) guna memberikan gambaran menyeluruh terhadap efektivitas model dalam memprediksi *churn*.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Terdapat beberapa penelitian terdahulu mengenai prediksi *churn* pelanggan dengan menggunakan metode LightGBM dan CatBoost yang menunjukkan efektivitas kedua algoritma tersebut dalam mengidentifikasi perilaku pelanggan. Salah satu penelitian menggunakan 7.043 data pelanggan dengan 21 fitur yang mencakup data demografis dan informasi layanan. Hasil perbandingan antara CatBoost, Stochastic Gradient Boost, dan XGBoost menunjukkan bahwa CatBoost menghasilkan performa terbaik dengan akurasi sebesar 94% dan *recall* sebesar 97%, berkat kemampuannya dalam menangani fitur kategorikal secara efisien [6].

Penelitian lainnya memanfaatkan data pelanggan bank dari Kaggle yang memiliki ketidakseimbangan kelas churn sebesar 20,37%. Dengan melakukan penyetelan parameter *scale_pos_weight*, CatBoost mencatat nilai *recall* tertinggi sebesar 0,79, menunjukkan keunggulannya dalam mengatasi data yang tidak seimbang [7].

Sementara itu, penelitian lain menggunakan data pelanggan dari perusahaan penyedia sistem kasir dan menerapkan metode LightGBM untuk klasifikasi, serta analisis survival dengan model Cox Proportional Hazard. Model LightGBM mencatatkan akurasi sebesar 96,4% dan F1-score sebesar 98%, dengan fitur paling berpengaruh seperti total harga langganan, jumlah transaksi, dan kota pelanggan. Temuan ini menunjukkan bahwa baik CatBoost maupun LightGBM memiliki performa yang unggul dalam memprediksi churn pelanggan dan dapat diandalkan sebagai dasar perumusan strategi retensi yang lebih efektif [8].

2.2. Layanan Streaming Musik

Layanan streaming musik memungkinkan pengguna mendengarkan musik secara online maupun offline melalui aplikasi atau situs web. Layanan ini menawarkan fitur seperti pencarian lagu, daftar putar pribadi, dan unduhan untuk pemutaran tanpa internet. Popularitasnya terus meningkat, dengan platform populer seperti Spotify, JOOX, dan YouTube Music [9].

2.3. Churn

Churn terjadi saat pelanggan beralih ke kompetitor dan tidak lagi aktif. Hal ini menjadi tantangan besar bagi industri telekomunikasi karena berdampak pada pendapatan. Penyebab churn antara lain kurangnya interaksi, layanan buruk, ulasan negatif, ketidakpuasan, ketidaksesuaian teknologi, dan tawaran lebih baik dari pesaing. Seringkali, alasan pasti churn tidak diketahui perusahaan [10].

2.4. LightGBM

LightGBM adalah algoritma machine learning berbasis pohon keputusan yang efisien untuk dataset besar. Menggunakan metode gradient boosting dan strategi pertumbuhan pohon leaf-wise, algoritma ini menawarkan pelatihan cepat dan akurasi tinggi. LightGBM mendukung klasifikasi, regresi, serta analisis fitur penting, sehingga cocok untuk aplikasi skala besar dan analisis data kompleks [11].

2.5. CatBoost


CatBoost adalah algoritma boosting berbasis gradient boosting dengan decision tree yang mendukung regresi dan otomatis menangani data kategorikal secara statistik. Algoritma ini mencegah overfitting dengan mengoptimalkan parameter input dan menggunakan permutasi acak serta perhitungan rata-rata label untuk data kategorikal [12].

2.6. Confusion Matrix

Confusion matrix merupakan metode evaluasi yang umum digunakan untuk mengukur kinerja model, terutama dalam menentukan akurasi pada data mining atau sistem pendukung keputusan. Matriks ini mencakup empat komponen utama: True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN) [13].

3. METODE PENELITIAN

Dalam penelitian ini, metodologi Cross-Industry Standard Process for Data Mining (CRISP-DM) diterapkan untuk memprediksi churn pelanggan dengan memanfaatkan algoritma LightGBM dan CatBoost. CRISP-DM adalah metodologi yang digunakan untuk mengarahkan proses data mining dan analisis data [14].



Gambar 1. Alur Penelitian

Gambar 1 menunjukkan alur penelitian yang menggunakan metodologi CRISP-DM, yang mencakup 5 tahap utama, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, dan *evaluation*.

3.1. Business Understanding

Tahap ini memahami tujuan dan kebutuhan bisnis, serta merumuskan masalah yang ingin diselesaikan melalui analisis data [14]. Penelitian ini bertujuan untuk memprediksi churn pelanggan dengan mempertimbangkan atribut dan riwayat pemesanan, mengingat dampak negatif churn terhadap pendapatan perusahaan akibat biaya akuisisi pelanggan baru yang tinggi.

3.2. Data Understanding

Tahap ini mengumpulkan dan mengeksplorasi data awal untuk mendapatkan pemahaman yang lebih baik tentang data yang tersedia dan relevansinya terhadap masalah yang dihadapi [14]. Tahap ini mencakup pengumpulan data dan deskripsi atribut yang relevan.

3.3. Data Preparation

Pada tahap ini akan dilakukan pembersihan, transformasi, dan pemilihan data yang relevan agar data siap digunakan dalam tahap pemodelan [14]. Tahap ini mencakup pembersihan data, normalisasi, dan feature engineering.

3.4. Modeling

Pada tahap ini dilakukan membangun dan menerapkan model analisis data menggunakan teknik

yang sesuai untuk mencapai tujuan yang telah ditetapkan [14]. Proses ini mencakup pemisahan data, penerapan SMOTE (jika diperlukan), inisialisasi hyperparameter tuning, serta pemodelan menggunakan LightGBM dan CatBoost.

3.5. Evaluation

Pada tahap ini akan dilakukan pengujian model yang telah dibangun untuk memastikan bahwa model tersebut memenuhi tujuan bisnis dan memberikan hasil yang diharapkan [14]. Pada tahap ini, confusion matrix digunakan untuk menghitung metrik kinerja, yaitu akurasi, presisi, recall, dan f1-score yang dihasilkan dari prediksi churn pelanggan dengan menggunakan algoritma LightGBM dan CatBoost. Perhitungan masing-masing metrik dilakukan dengan rumus sebagai berikut [15]:

$$\text{akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{presisi} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (3)$$

$$f1 - \text{score} = 2 \times \frac{\text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}} \quad (4)$$

Keterangan:

- *True Positive (TP)*: Pelanggan churn yang berhasil diprediksi churn.
- *True Negative (TN)*: Pelanggan tidak churn yang berhasil diprediksi tidak churn.
- *False Positive (FP)*: Pelanggan tidak churn tetapi diprediksi churn.
- *False Negative (FN)*: Pelanggan churn tetapi diprediksi tidak churn.

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan Data

Data yang digunakan dalam penelitian diperoleh dari sumber sekunder, yaitu situs Kaggle. Dataset yang digunakan berjudul Streaming Subscription Churn dan dipublikasikan oleh Michael Odonnel pada tahun 2024. Dataset tersebut dapat diakses melalui tautan <https://www.kaggle.com/c/streaming-subscription-churn-model/data?select=train.csv>.

4.2. Deskripsi Atribut

Deskripsi lengkap atribut yang digunakan dalam analisis disajikan pada Tabel 1.

Tabel 1. Dataset

Nama Atribut	Deksripsi
customer_id	Nomor identifikasi pelanggan yang unik
age	Usia pengguna
location	Negara bagian pengguna di Amerika Serikat
subscription_type	Jenis langganan
payment_plan	Frekuensi pembayaran pengguna
num_subscription_pauses	Jumlah pengguna menghentikan langganan sementara
payment_method	Metode pembayaran yang digunakan oleh pengguna
customer_service_inquiries	Frekuensi pengguna menghubungi layanan pelanggan
signup_date	Tanggal pengguna mendaftar layanan streaming musik
weekly_hours	Rata-rata waktu mendengarkan musik per minggu
average_session_length	Rata-rata durasi setiap sesi mendengarkan musik (dalam jam)
song_skip_rate	Persentase lagu yang tidak diselesaikan oleh pengguna
weekly_songs_played	Rata-rata jumlah lagu yang diputarkan pengguna dalam seminggu
weekly_unique_songs	Rata-rata jumlah lagu unik yang diputarkan pengguna dalam seminggu
num_favorite_artists	Jumlah artis yang ditandai sebagai favorit oleh pengguna
num_platform_friends	Jumlah koneksi pengguna dengan pengguna lain di aplikasi
num_playlists_created	Jumlah <i>playlist</i> yang dibuat oleh pengguna
num_shared_playlists	Jumlah <i>playlist</i> yang dibagikan secara publik
notifications_clicked	Jumlah notifikasi dalam aplikasi yang diklik oleh pengguna
churned	Variabel target, 0 = pelanggan masih aktif, 1 = pelanggan berhenti berlangganan

Tabel 1 berisi data pelanggan layanan streaming musik dengan berbagai atribut terkait profil, aktivitas, dan interaksi pengguna, serta status churned yang menunjukkan apakah pelanggan masih aktif atau sudah berhenti berlangganan.

4.3. Pembersihan Data

Tahap pembersihan data mencakup tiga langkah utama, yaitu penanganan *missing value*, penghapusan data duplikasi, dan penghapusan kolom yang tidak

relevan. Seluruh baris yang mengandung nilai kosong telah dihapus untuk menjaga kualitas data. Data duplikat juga diidentifikasi dan dihapus agar tidak memengaruhi hasil pemodelan. Selain itu, kolom 'customer_id' dihapus karena tidak memiliki kontribusi terhadap proses prediksi churn.

Setelah proses pembersihan, dataset akhir terdiri dari 125.000 baris data tanpa *missing value* maupun duplikasi, dan memuat 19 kolom yang relevan untuk dianalisis.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 125000 entries, 0 to 124999
Data columns (total 19 columns):
#   Column                                Non-Null Count  Dtype
---  ---                                -
0   age                                   125000 non-null  int64
1   location                             125000 non-null  object
2   subscription_type                    125000 non-null  object
3   payment_plan                         125000 non-null  object
4   num_subscription_pauses              125000 non-null  int64
5   payment_method                       125000 non-null  object
6   customer_service_inquiries           125000 non-null  object
7   signup_date                         125000 non-null  int64
8   weekly_hours                        125000 non-null  float64
9   average_session_length               125000 non-null  float64
10  song_skip_rate                       125000 non-null  float64
11  weekly_songs_played                  125000 non-null  int64
12  weekly_unique_songs                  125000 non-null  int64
13  num_favorite_artists                 125000 non-null  int64
14  num_platform_friends                 125000 non-null  int64
15  num_playlists_created                125000 non-null  int64
16  num_shared_playlists                 125000 non-null  int64
17  notifications_clicked                 125000 non-null  int64
18  churned                             125000 non-null  int64
```

Gambar 2. Struktur dataset setelah pembersihan data

Gambar 2 menunjukkan informasi struktur dari dataset yang berisi 125.000 data pelanggan dan 19 kolom. Setiap kolom memiliki tipe data tertentu (seperti int64, float64, atau object) dan tidak ada nilai yang hilang (non-null). Data ini siap digunakan untuk analisis lebih lanjut seperti prediksi churn pelanggan.

4.4. Normalisasi

Pada tahap normalisasi, sejumlah kolom numerik dari data pelatihan seperti 'age', 'weekly_hours', 'song_skip_rate', dan lainnya dipilih untuk dinormalisasi. Proses ini dilakukan menggunakan MinMaxScaler yang mengubah nilai-nilai pada kolom tersebut ke dalam rentang 0 hingga 1 melalui metode fit_transform. Nilai hasil normalisasi langsung menggantikan nilai aslinya dalam data pelatihan.

```
age  signup_date  weekly_hours  average_session_length \
0  0.229508      0.450531      0.447827      0.877290
1  0.754098      0.008559      0.585884      0.432793
2  0.540984      0.881205      0.308006      0.199193
3  0.737705      0.009586      0.456841      0.694099
4  0.590164      0.968846      0.463023      0.433441

song_skip_rate  weekly_songs_played  weekly_unique_songs \
0  0.176874      0.334677      0.358108
1  0.981840      0.104839      0.540541
2  0.048407      0.485887      0.385135
3  0.035687      0.885081      0.841216
4  0.039734      0.483871      0.766892

num_favorite_artists  num_platform_friends  num_playlists_created \
0  0.367347      0.160804      0.525253
1  0.897959      0.165829      0.121212
2  0.408163      0.648241      0.505051
3  0.959184      0.603015      0.555556
4  0.836735      0.331658      0.404040

num_shared_playlists  notifications_clicked
0  0.714286      0.938776
1  0.510204      0.755102
2  0.571429      0.775510
3  0.346939      0.489796
4  0.653061      0.959184
```

Gambar 3. Kolom numerik setelah dinormalisasi

Gambar 3 menampilkan beberapa baris pertama dari data setelah dilakukan normalisasi. Semua nilai numerik telah diskalakan ke rentang 0 hingga 1, sehingga setiap fitur (seperti 'age', 'weekly_hours', 'song_skip_rate', dll.) memiliki skala yang seragam. Normalisasi ini penting untuk menghindari dominasi

fitur tertentu dalam proses analisis atau pelatihan model.

4.5. Feature Engineering

Dilakukan one-hot encoding pada fitur kategorikal seperti 'location', 'subscription_type', 'payment_plan', 'num_subscription_pauses', 'payment_method', dan 'customer_service_inquiries'. Proses ini mengubah data kategorikal menjadi numerik biner agar dapat diproses oleh model LightGBM. Hasil encoding menghasilkan 50 kolom baru pada dataset.

```
payment_method_Apple Pay  location_New York  location_New Jersey \
0  False  False  False  False
1  False  False  False  True
2  False  False  False  False
3  True  False  False  False
4  False  False  False  False

num_subscription_pauses_4  location_Virginia  payment_method_Paypal \
0  False  False  True
1  False  False  True
2  False  False  False
3  True  False  False
4  False  False  True

num_subscription_pauses_2  num_subscription_pauses_0  location_Idaho  ... \
0  True  False  False  False  ...
1  False  False  False  False  ...
2  True  False  False  False  ...
3  False  False  False  False  ...
4  False  False  False  False  ...
```

Gambar 4. Hasil encoding

Gambar 4 menunjukkan data setelah dilakukan proses encoding. Terdapat kolom-kolom baru dengan data bentuk numerik biner (True/False).

4.6. Modeling

Setelah data siap digunakan, dilakukan pembagian data dengan rasio 80:20, di mana 80% digunakan untuk data latih dan 20% untuk data uji. LightGBM dan CatBoost menggunakan data yang berbeda, di mana LightGBM menggunakan data yang sudah di-encoding, sementara CatBoost menggunakan data tanpa encoding karena model ini mendukung fitur kategorikal secara langsung. Proses pembangunan model dimulai dengan mendefinisikan parameter grid untuk LightGBM dan CatBoost.

Tabel 2. Parameter Grid untuk LightGBM

Parameter	Nilai
learning_rate	[0.001, 0.01, 0.05, 0.1]
max_depth	[3, 5, 7]
n_estimators	[50, 100, 200]

Tabel 2 berisi kombinasi parameter untuk tuning model LightGBM. Parameter learning_rate mengatur kecepatan belajar, max_depth mengontrol kedalaman pohon, dan n_estimators menentukan jumlah pohon. Kombinasi nilai-nilai ini dicoba untuk memperoleh performa model terbaik.

Tabel 3. Parameter Grid untuk CatBoost

Parameter	Nilai
learning_rate	[0.001, 0.01, 0.05, 0.1]
depth	[5, 7, 9]
iterations	[50, 100, 200]
subsample	[0.8, 0.9, 1.0]

Tabel 3 menunjukkan kombinasi parameter yang diuji untuk mengoptimalkan model CatBoost, termasuk *learning_rate*, *depth*, *iterations*, dan *subsample*, yang mempengaruhi kecepatan, kompleksitas, dan akurasi model. Tujuannya adalah mencari kombinasi parameter terbaik untuk meningkatkan kinerja model.

Selanjutnya, dilakukan Grid Search dengan menggunakan *cross-validation* untuk mengevaluasi performa setiap kombinasi parameter dan memilih konfigurasi yang memberikan hasil terbaik berdasarkan skor F1.

Setelah proses Grid Search selesai, model terbaik dipilih berdasarkan kombinasi *hyperparameter* yang optimal. **Tabel 4** menunjukkan parameter terbaik yang diperoleh untuk LightGBM dan CatBoost.

Tabel 4. Parameter Terbaik

Metode	Parameter	Nilai
LightGBM	<i>learning_rate</i>	0.1
	<i>max_depth</i>	7
	<i>n_estimators</i>	200
CatBoost	<i>learning_rate</i>	0,1
	<i>depth</i>	7
	<i>iterations</i>	50
	<i>subsample</i>	0.8


Tabel 4 menunjukkan parameter terbaik yang diperoleh untuk model LightGBM dan CatBoost setelah melalui proses *tuning* dengan tujuan meningkatkan akurasi dan stabilitas model.

Model yang telah dipilih ini kemudian digunakan untuk prediksi lebih lanjut atau evaluasi akhir menggunakan data uji.

4.7. Evaluation


Pada tahap evaluasi, dilakukan pengukuran performa dari dua model klasifikasi, yaitu LightGBM dan CatBoost, untuk mengetahui sejauh mana model mampu memprediksi pelanggan yang akan melakukan churn. Evaluasi dilakukan dengan menggunakan metrik-metrik klasifikasi seperti akurasi, presisi, *recall*, *f1-Score*, serta ROC-AUC. Selain itu, digunakan Confusion Matrix untuk memberikan gambaran detail terkait jumlah prediksi yang benar dan salah pada masing-masing kelas.

a. Confusion Matrix



Gambar 5. Confusion matrix LightGBM

Gambar 5 menunjukkan *confusion matrix* dari model LightGBM untuk klasifikasi biner, yang menggambarkan performa prediksi terhadap data aktual. Model berhasil mengklasifikasikan 10.785 data positif dan 10.000+ data negatif secara benar, sementara terdapat 2.050 *false negative* dan 1.757 *false positive*.



Gambar 6. Confusion matrix CatBoost

Gambar 6 menunjukkan *confusion matrix* dari model CatBoost yang dilatih menggunakan data original tanpa *encoding*. Model ini berhasil mengklasifikasikan 11.111 data positif dan lebih dari 10.000 data negatif secara benar, dengan kesalahan prediksi sebanyak 2.079 *false positive* dan 1.724 *false negative*.

Hasil dari *confusion matrix* menunjukkan bahwa:

- Model CatBoost memiliki jumlah *false negative* yang lebih sedikit, menunjukkan kemampuan lebih baik dalam mendeteksi pelanggan churn.
- Model LightGBM memiliki jumlah *false positive* yang lebih sedikit, yang berarti lebih sedikit salah memprediksi pelanggan tidak churn sebagai churn.

b. Metrik Evaluasi

Tabel 5. Hasil Evaluasi

Metrik	LightGBM	CatBoost
Akurasi	0.84	0.84
Precision	0.85	0.84
Recall	0.84	0.86
F1-Score	0.84	0.85
ROC-AUC	0.94	0.94

Berdasarkan Tabel 5, model CatBoost menunjukkan keunggulan dalam *recall* sebesar 0.86, yang berarti lebih efisien dalam mengidentifikasi pelanggan yang mengalami churn. Jika tujuan utama adalah mengidentifikasi sebanyak mungkin pelanggan yang berpotensi churn, CatBoost merupakan pilihan yang lebih tepat untuk mengurangi jumlah pelanggan yang tidak terdeteksi.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, model CatBoost menunjukkan keunggulan dalam hal *recall* sebesar 0.86, yang lebih efektif dalam mendeteksi pelanggan

berisiko *churn* dibandingkan dengan LightGBM yang memiliki *recall* 0.84. Kedua model memiliki akurasi yang hampir identik sekitar 84%, namun CatBoost lebih tepat digunakan untuk mengidentifikasi pelanggan yang berpotensi *churn* dan mengurangi jumlah yang terlewatkan. Secara keseluruhan, meskipun kedua model efektif, CatBoost memberikan hasil yang lebih optimal untuk strategi retensi pelanggan.

DAFTAR PUSTAKA

- [1] P. D. Sepnandito and others, "Pengaruh Fitur Spotify Social Dan Pemasaran Personalisasi Terhadap Loyalitas Pelanggan Spotify Dimediasi Dengan Kepuasan Pelanggan," *Journal of Young Entrepreneurs*, vol. 3, no. 2, 2024.
- [2] Y. Yudiana, A. Y. Agustina, N. Khofifah, and others, "Prediksi Customer Churn Menggunakan Metode CRISP-DM Pada Industri Telekomunikasi Sebagai Implementasi Mempertahankan Pelanggan," *Indonesian Journal of Islamic Economics and Business*, vol. 8, no. 1, pp. 1–20, 2023.
- [3] Y. P. Mada, "Prediksi Churn Pelanggan di Layanan Streaming Berbasis Analisis Perilaku dan Sentimen dengan Ensemble Machine Learning: Studi Platform Lokal Vidio vs. Netflix Indonesia," *Jurnal Kajian Ilmu Manajemen*, vol. 5, no. 1, 2025.
- [4] T. A. B. Wirayuda and others, "Customer Churn Prediction Pada Streaming Musics Platform Menggunakan Ensemble Learning," *eProceedings of Engineering*, vol. 12, no. 1, pp. 1982–1989, 2025.
- [5] R. Irfannandhy, L. B. Handoko, and N. Ariyanto, "Analisis Performa Model Random Forest dan CatBoost dengan Teknik SMOTE dalam Prediksi Risiko Diabetes," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 714–723, 2024.
- [6] B. Hasan, Zubair, S. A. Shaikh, A. Khaliq, and G. Nadeem, "Data-Driven Decision-Making: Accurate Customer Churn Prediction with CatBoost," *The Asian Bulletin of Big Data Management*, vol. 4, no. 02, Jun. 2024, doi: 10.62019/abbdm.v4i02.175.
- [7] W. Nugraha and M. Syarif, "Teknik Weighting untuk Mengatasi Ketidakseimbangan Kelas Pada Prediksi Churn Menggunakan XGBoost, LightGBM, dan CatBoost.," *Techno. com*, vol. 22, no. 1, 2023.
- [8] I. Z. Illah, W. S. J. Sapu, and A. T. Damaliana, "Implementasi Metode Klasifikasi LightGBM dan Analisis Survival dalam Memprediksi Pelanggan Churn," *Jurnal Komtika (Komputasi dan Informatika)*, vol. 8, no. 1, 2024.
- [9] F. R. Frimansyah and M. Hutomo, "Pengaruh Persepsi Harga Dan Ekspektasi Kinerja Produk Terhadap Loyalitas Pelanggan Spotify Premium," *Prosiding FRIMA (Festival Riset Ilmiah Manajemen dan Akuntansi)*, vol. 1, no. 7, pp. 836–843, 2024.
- [10] H. D. Nafitra and A. Djunaidy, "Prediksi Churn Pelanggan pada Perusahaan Telekomunikasi Menggunakan Algoritma Pembelajaran Ensambel Berbasis Bagging," *Jurnal Teknik ITS*, vol. 13, no. 3, pp. A217–A223, 2024.
- [11] J. Yan *et al.*, "LightGBM: accelerated genomically designed crop breeding through ensemble learning," *Genome Biol.*, vol. 22, pp. 1–24, 2021.
- [12] A. F. Istianto, A. I. Hadiana, and F. R. Umbara, "Prediksi curah hujan menggunakan metode categorical boosting (Catboost)," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 4, pp. 2930–2937, 2023.
- [13] S. Diantika, "Penerapan Teknik Random Oversampling Untuk Mengatasi Imbalance Class Dalam Klasifikasi Website Phishing Menggunakan Algoritma Lightgbm," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 1, pp. 19–25, 2023.
- [14] S. Santiastry, A. Asriyanik, and W. Apriandari, "PENERAPAN ALGORITMA NAIVE BAYES DAN METODE CRISP-DM DALAM PREDIKSI HASIL TES KEMAMPUAN BAHASA INGGRI MAHASISWA," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 5, pp. 10432–10439, 2024.
- [15] I. P. Putri, "Analisis Performa Metode K-Nearest Neighbor (KNN) dan Crossvalidation pada Data Penyakit Cardiovascular," *Indonesian Journal of Data and Science*, vol. 2, no. 1, pp. 21–28, 2021.