

Temporal Pattern Recognition: A BiLSTM-based Framework for Churn Prediction

Muhammad Reza Zulman¹, Rifa'atun Mahmudah², Muhammad Arhami^{3*}, Muhammad Davi⁴
^{1,2,3,4}Teknologi Informasi dan Komputer, Politeknik Negeri Lhokseumawe, Lhokseumawe, 24355, Indonesia

Informasi Artikel

Diterima : 18 Mei 2025
Revisi : 24 Mei 2025
Publikasi : 20 Juni 2025

Kata Kunci:

BiLSTM
Prediksi *Churn*
Pengenalan Pola Temporal
Telekomunikasi
Retensi Pelanggan

ABSTRAK

Industri telekomunikasi menghadapi tantangan besar dalam mempertahankan basis pelanggannya, di mana *churn* atau perpindahan pelanggan ke penyedia layanan pesaing menjadi isu krusial yang secara langsung memengaruhi kinerja finansial, efisiensi operasional, serta daya saing perusahaan dalam jangka panjang. Untuk menjawab tantangan ini, diperlukan pendekatan analitik yang mampu memprediksi kemungkinan *churn* secara akurat. Penelitian ini bertujuan untuk mengevaluasi efektivitas jaringan saraf *Bidirectional Long Short-Term Memory* (BiLSTM) dalam memprediksi *churn* pelanggan PT Medianusa Permana melalui analisis data sekuensial temporal. Dataset yang digunakan mencakup data pelanggan dari April 2020 hingga Mei 2023, dengan berbagai variabel prediktif seperti jenis layanan, media transmisi, alokasi bandwidth, status langganan, status kemitraan, ketentuan kontrak, serta riwayat keluhan. Arsitektur BiLSTM yang diterapkan terdiri dari tiga lapisan LSTM *bidirectional*, dirancang untuk memaksimalkan pengenalan pola temporal sekaligus mengurangi *overfitting* guna meningkatkan akurasi model. Validasi dilakukan melalui teknik *cross-validation* dan *confusion matrix*, yang menunjukkan bahwa model mampu mencapai akurasi rata-rata sebesar 89% serta performa klasifikasi yang tinggi dalam mengidentifikasi pelanggan yang *churn* maupun tidak *churn*. Hasil penelitian ini menegaskan bahwa BiLSTM efektif dalam menangkap indikator perilaku halus yang mendahului *churn*, dan dapat menjadi dasar yang kuat dalam pengembangan strategi retensi pelanggan yang lebih proaktif dan berbasis data.

ABSTRACT

The telecommunications industry faces significant challenges in maintaining its customer base, with churn—customers switching to competing service providers—emerging as a critical issue that directly affects financial performance, operational efficiency, and long-term competitiveness. To address this challenge, accurate predictive approaches are essential for identifying potential churn early. This study aims to evaluate the effectiveness of a Bidirectional Long Short-Term Memory (BiLSTM) neural network in predicting customer churn at PT Medianusa Permana through temporal sequential analysis. The dataset spans from April 2020 to May 2023 and includes various predictive variables such as service type, transmission medium, bandwidth allocation, subscription status, partnership agreements, contract terms, and complaint history. The proposed BiLSTM architecture consists of three bidirectional LSTM layers designed to enhance the recognition of temporal patterns while minimizing overfitting to improve predictive accuracy. The model was validated using cross-validation and a confusion matrix, yielding an average accuracy of 89% and strong classification performance in identifying both churned and retained customers. These results confirm that BiLSTM is effective in capturing subtle behavioral indicators preceding churn, providing a robust foundation for the development of more proactive, data-driven customer retention strategies.

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



*Penulis Koresponden

Email: muhammad.arhami@pnl.ac.id

Cara sitasi IEEE:

M. R. Zulman, R. Mahmudah, M. Arhami, dan M. Davi, "Temporal Pattern Recognition: A BiLSTM-based Framework for Churn Prediction" *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 2, p. 651-659, Juni 2025. doi:10.30811/jaise.v5i2.6952

1. PENDAHULUAN

Telekomunikasi seluler memainkan peran krusial dalam dinamika sosio-ekonomi masyarakat Indonesia [1]. Persaingan dalam bidang *internet provider* ini semakin ketat. Lingkungan yang kompetitif meningkatkan risiko *churn* pelanggan dan memungkinkan pelanggan memilih layanan berdasarkan preferensi dan harga yang lebih baik [2]. Pelanggan kini memiliki otonomi untuk memilih layanan sesuai dengan preferensi individual dan pertimbangan ekonomis, menyajikan tantangan kompleks bagi penyedia layanan internet dalam mengimplementasikan strategi retensi pelanggan yang efektif [3].

Sejak diberlakukannya Undang-Undang Nomor 36 Tahun 1999 tentang telekomunikasi, lanskap industri mengalami transformasi fundamental, membuka peluang partisipasi bagi beragam entitas bisnis termasuk BUMN, BUMD, perusahaan swasta, dan koperasi [1]. Menurut laporan Badan Pusat Statistik (BPS) tahun 2022, jumlah perusahaan penyedia layanan internet (*Internet Service Provider*) di Indonesia sebanyak 828 perusahaan, mengalami peningkatan sebesar 35,52% dibandingkan tahun sebelumnya [4]. Perkembangan jumlah provider internet di Indonesia terus mengalami pertumbuhan yang signifikan dari tahun ke tahun [5]. Pertumbuhan ini mencerminkan tingginya tingkat persaingan di industri [6].

Perilaku pelanggan yang memutuskan untuk berhenti menggunakan layanan dikenal dengan istilah *churn* [7]. Analisis terhadap *churn* pelanggan berfokus pada pengukuran tingkat loyalitas individu terhadap layanan yang diberikan oleh sebuah bisnis, dengan tujuan untuk mengetahui kemungkinan mereka tetap bertahan atau berhenti menggunakan layanan tersebut. Oleh karena itu, pengukuran dan prediksi terhadap loyalitas pelanggan menjadi aspek krusial dalam mengevaluasi kinerja suatu usaha [8]. Menarik pelanggan baru memerlukan biaya yang jauh lebih tinggi dibandingkan mempertahankan pelanggan lama [9]. Bahkan, upaya mempertahankan pelanggan yang sudah ada memiliki potensi untuk meningkatkan keuntungan perusahaan secara signifikan, mencapai persentase yang sangat tinggi [10].

PT Medianusa Permana adalah perusahaan yang menyediakan solusi layanan terintegrasi untuk kebutuhan konektivitas internet dan pengembangan jaringan komunikasi. Meski telah aktif sebagai salah satu penyedia layanan internet di Indonesia, perusahaan ini belum memanfaatkan sistem atau aplikasi yang mampu memprediksi potensi pelanggan *churn* secara otomatis. Hingga saat ini, identifikasi pelanggan *churn* masih dilakukan dengan metode survei yang disebarakan kepada pelanggan. Namun, pendekatan ini memiliki beberapa keterbatasan. Pertama, survei dilakukan dalam rentang waktu yang panjang sehingga tidak memungkinkan pendeteksian *churn* secara *real-time*. Kedua, survei hanya menggambarkan tingkat kepuasan pelanggan secara umum tanpa mengungkap faktor-faktor spesifik yang menyebabkan pelanggan berhenti. Ketiga, hasil survei berisiko mengandung bias, baik karena masukan asal-asalan maupun distribusi survei yang tidak merata, sehingga mengurangi keandalan prediksi *churn*.

Guna mengatasi berbagai keterbatasan tersebut, diperlukan sebuah aplikasi prediksi *churn* yang dapat membantu dalam upaya pencegahan kehilangan pelanggan di masa mendatang. Kajian mengenai prediksi *churn* telah banyak dilakukan dalam berbagai literatur. Dalam perkembangan terbaru, prediksi *churn* menjadi fokus utama berbagai perusahaan dan analisis data [10]. Pendekatan tradisional sering kali menghadapi tantangan dalam hal penskalaan, sehingga memerlukan rekayasa fitur secara manual untuk meningkatkan kinerja model [12]. Pendekatan berbasis *Machine Learning* merupakan salah satu metode yang umum digunakan dalam membangun sistem prediksi [13]. Salah satu studi yang pernah dilakukan menunjukkan bahwa metode ini berhasil digunakan dalam mendeteksi pelanggan *churn* di sektor perbankan dengan tingkat akurasi model yang cukup tinggi [14]. Namun demikian, pendekatan berbasis *Deep Neural Network* (DNN) dilaporkan mampu memberikan hasil yang lebih baik dibandingkan dengan metode *Machine Learning*

konvensional [13]. Lebih lanjut, hasil penelitian menunjukkan bahwa pendekatan BiLSTM mampu menghasilkan akurasi yang lebih tinggi dibandingkan metode RNN dan LSTM [15].

BiLSTM, atau *Bidirectional Long Short-Term Memory*, merupakan pengembangan dari metode LSTM dalam bidang *Deep Learning* [16]. Berdasarkan berbagai penelitian sebelumnya, metode BiLSTM terbukti memiliki tingkat akurasi yang tinggi dan telah berhasil diterapkan dalam sistem prediksi di berbagai sektor, seperti bidang kesehatan [16], investasi [17], prakiraan cuaca [15][18], dan perbankan [19]. Dalam penelitian ini, metode BiLSTM digunakan untuk memprediksi pelanggan yang berpotensi *churn* pada PT Medianusa Permana. Sistem prediksi *churn* ini diharapkan dapat memberikan dukungan analitis bagi tim pemasaran dan CRM dalam mengidentifikasi pelanggan yang berisiko, sehingga memungkinkan mereka melakukan pendekatan proaktif serta menawarkan solusi yang relevan demi mencegah terjadinya *churn* dan meningkatkan profitabilitas perusahaan.

2. METODE

2.1 Pengumpulan Data

Pengumpulan data dilakukan dengan mengunduh histori interaksi pelanggan dari sistem CRM milik PT Medianusa Permana. Data yang digunakan mencakup periode April 2020 hingga Mei 2023, dengan total sebanyak 850 entri. Dataset ini digunakan sebagai dasar dalam membangun model prediksi *churn* berbasis temporal menggunakan pendekatan BiLSTM.

2.2. Explorasi Data

Eksplorasi data merupakan tahap awal yang esensial untuk memahami struktur, karakteristik, serta distribusi data. Tujuan dari tahap ini adalah untuk mengidentifikasi pola awal, mendeteksi keberadaan nilai ekstrem (*outlier*), dan memahami konteks temporal dari perilaku pelanggan. Tahap ini juga membantu menentukan teknik pra-proses yang sesuai sebelum data digunakan dalam pelatihan model BiLSTM.

2.3. Pra-proses Data

Pra-prosesan data bertujuan untuk mempersiapkan dataset agar siap digunakan dalam proses pelatihan model *deep learning*. Langkah-langkah yang dilakukan meliputi:

2.3.1. Penanganan *Missing Value*

Dalam proses analisis data, seringkali ditemui nilai-nilai yang hilang (*missing values*) pada dataset. Salah satu metode yang umum digunakan untuk menangani hal ini adalah metode penghapusan (*deletion*), yaitu dengan menghapus seluruh baris data yang memiliki nilai kosong, seperti "NaN" (*Not a Number*). Metode ini sederhana dan efektif ketika jumlah data yang hilang relatif kecil dibandingkan dengan keseluruhan dataset. Namun, jika proporsi data yang hilang cukup besar, penghapusan dapat menyebabkan kehilangan informasi yang signifikan dan berpotensi mengurangi kualitas model. Oleh karena itu, penting untuk mempertimbangkan proporsi dan distribusi data yang hilang sebelum memutuskan untuk menggunakan metode ini.

2.3.2. *Labeling Data*

Data kategorik, seperti status pelanggan atau jenis langganan, perlu diubah menjadi format numerik agar dapat diproses oleh model pembelajaran mesin seperti BiLSTM. Salah satu teknik yang digunakan adalah Label Encoding, di mana setiap kategori unik diberikan nilai numerik tertentu. Teknik ini cocok untuk data kategorik yang memiliki urutan atau hierarki (*ordinal*), karena menjaga informasi tentang urutan tersebut. Namun, untuk data kategorik tanpa urutan (*nominal*), Label Encoding dapat memperkenalkan asumsi urutan yang tidak ada, sehingga dalam kasus tersebut, One-Hot Encoding mungkin lebih sesuai [20].

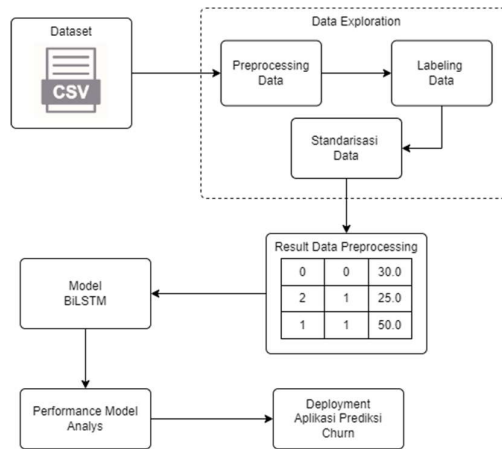
2.3.3. Standarisasi Data

Standarisasi data adalah proses transformasi data numerik agar memiliki distribusi normal dengan rata-rata (mean) 0 dan deviasi standar (standard deviation) 1. Proses ini penting untuk memastikan bahwa setiap fitur memiliki skala yang sama, sehingga model tidak memprioritaskan fitur tertentu hanya karena skala nilainya lebih besar. Dalam konteks model BiLSTM, yang sensitif terhadap skala input, standarisasi membantu dalam mempercepat proses pelatihan dan meningkatkan konvergensi model. Dengan data yang terstandarisasi, model dapat lebih efektif dalam mengenali pola temporal yang ada dalam data [22].

2.4. Perancangan Model BiLSTM

Model BiLSTM (*Bidirectional Long Short-Term Memory*) dirancang untuk mengenali pola temporal dalam data pelanggan. Rangkaian tahapan dalam perancangan model mencakup pemuatan dan reprocessing data pelanggan, labeling dan standarisasi data, pembentukan arsitektur model BiLSTM, evaluasi performa

model menggunakan metrik akurasi dan *confusion matrix*, deploy model untuk implementasi prediksi churn secara real-time.



Gambar 1. Rangkaian Tahapan Perancangan Model BiLSTM

Perancangan model BiLSTM dijelaskan melalui diagram blok seperti ditunjukkan oleh Gambar 1, yang mengambarkan tahapan-tahapan utama dalam penerapan model BiLSTM untuk memprediksi churn pelanggan, dimulai dari proses pemuatan data hingga tahap prediksi.

2.5. Evaluasi Model

Evaluasi merupakan tahap penting dalam penelitian ini untuk mengukur seberapa baik model BiLSTM yang telah dibangun dalam memprediksi churn pelanggan. Setelah model dilatih, perlu dilakukan evaluasi kinerja model untuk memastikan bahwa model tersebut *reliabel* dan memberikan hasil yang akurat. Evaluasi dilakukan menggunakan *cross validation* dan *confusion matrix*

2.5.1. Cross Validation

Cross validation merupakan salah satu teknik yang digunakan *machine learning* untuk mengukur kinerja dan generalisasi suatu model. Langkah-langkah kerja *cross validation* mencakup pembagian dataset menjadi K bagian dimana setiap bagian disebut dengan *fold*. Selanjutnya, iterasi *Cross validation* dilakukan sebanyak K kali, dimana setiap iterasi disebut sebagai *fold* ke- i . Setiap iterasi, satu *fold* menjadi data *test* dan sisanya menjadi data *train*. Pada setiap iterasi, model dilatih menggunakan data *train* dan data diuji pada data *test*. Akurasi dihitung berdasarkan performa model pada setiap iterasi. Perhitungan akurasi untuk setiap iterasi menggunakan metrik evaluasi yang sesuai dengan rata-rata akurasi yang dihasilkan dari akurasi K iterasi dan rata-rata akurasi yang dihasilkan menjadi akurasi final model.

Teknik *5-fold cross validation* digunakan untuk menguji generalisasi model. Dataset dibagi menjadi 5 bagian (*fold*), dan pada setiap iterasi satu *fold* digunakan sebagai data pengujian, sementara sisanya digunakan untuk pelatihan. Prosedur ini dilakukan sebanyak 5 kali, kemudian dihitung rata-rata akurasi sebagai performa akhir model.

Tabel 1. Tabel iterasi *cross validation*

Fold	Basis Data	Digunakan Sebagai
1	1 - 170	Data Uji (Iterasi ke 1)
2	171 - 340	Data Uji (Iterasi ke 2)
3	341 - 510	Data Uji (Iterasi ke 3)
4	511 - 680	Data Uji (Iterasi ke 4)
5	681 - 849	Data Uji (Iterasi ke 5)

2.5.2. Confusion Matrix

Selain menggunakan metrik akurasi, kinerja model dalam penelitian ini juga dievaluasi melalui *confusion matrix*, yang berfungsi untuk menilai seberapa baik model dalam mengklasifikasikan pelanggan yang mengalami churn dan yang tidak. *Confusion matrix* menyajikan informasi detail mengenai hasil prediksi model terhadap masing-masing kelas, baik yang benar maupun yang salah. Komponen utama dalam *confusion matrix* terdiri dari jumlah pelanggan yang benar-benar churn dan berhasil diprediksi churn oleh model *True Positive (TP)*, jumlah pelanggan yang tidak churn dan berhasil diprediksi tidak churn oleh model *True Negative (TN)*, jumlah pelanggan yang tidak churn tetapi salah diprediksi sebagai churn *False Positive (FP)*, dan jumlah pelanggan yang churn tetapi salah diprediksi sebagai tidak churn *False Negative (FN)*.

Dari komponen tersebut, perhitungan akurasi dapat dilakukan dengan persamaan (1) untuk mengukur proporsi dari keseluruhan prediksi yang benar.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+F} \quad (1)$$

Selanjutnya, untuk mengevaluasi model yang memiliki distribusi data yang tidak seimbang dapat dilakukan dengan perhitungan *F1 Score* seperti ditunjukkan pada persamaan (4) yang merupakan rata-rata harmonik dari presisi (2) dan recall (3).

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

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

$$F1\ Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

Melalui perhitungan metrik-metrik ini, confusion matrix memberikan wawasan yang lebih komprehensif terhadap kekuatan dan kelemahan model BiLSTM dalam melakukan klasifikasi churn pelanggan, khususnya dalam konteks data riil di PT Medianusa Permana.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini merupakan data pelanggan dari PT. Medianusa Permana dengan total sebanyak 859 entri data. Dataset ini bersifat *supervised* karena sudah dilengkapi dengan label target berupa informasi churn pelanggan, yaitu apakah pelanggan melakukan *churn* ("Yes") yang berjumlah 156 data atau tetap bertahan ("No") yang berjumlah 693 data.

Distribusi label ini menunjukkan bahwa data tidak seimbang (imbalanced dataset), di mana mayoritas data merupakan pelanggan yang tidak churn. Ketidakeimbangan ini menjadi salah satu tantangan dalam pembangunan model prediksi karena dapat menyebabkan bias model terhadap kelas mayoritas. Oleh karena itu, pendekatan evaluasi yang lebih komprehensif seperti precision, recall, dan *F1-score* diperlukan untuk menilai performa model secara adil.

Dataset pelanggan yang digunakan memiliki 10 feature seperti ditunjukkan pada Gambar 2 yang akan digunakan sebagai variabel input ke dalam model BiLSTM. 10 feature ini terdiri dari *company_name*, *service_type*, *packet_service*, *media_transmisi*, *bandwidth*, *state*, *partner*, *contract*, *complaint*, dan label *churn*.

	Company name	Service_types	Packet_service	Media_transmisi	Bandwidth	State	Partner	Contract	Complaint	Churn
754	SANOP MARIHOT SIMANJUNTAK	Retail	Permana Home	Fiber Optic	30.0	Sumatera Utara	No	Monthly	No	No
391	Rumah Dinas Sekretaris Daerah Tapanuli Utara	Corporate	Permana Home	Fiber Optic	50.0	Sumatera Utara	Yes	Yearly	No	No
644	Abdul Halim	Retail	Permana Home	Fiber Optic	30.0	Sumatera Utara	No	Monthly	No	No
183	Mr ABDULLAH AZIZ MUHAMMIN	Corporate	Permana Home	Wireless	25.0	Sumatera Utara	Yes	Yearly	No	No
213	PT EKANURI (COLLO 2)	Corporate	Permana Colocation	Ethernet	10.0	DKI Jakarta	Yes	Yearly	No	No
357	PT TRIPUTRA SENAMUSTIKA/ ROYAL PROPERTY OFFICE	Corporate	Permana Hosta	Wireless	30.0	Kepulauan Riau	Yes	Yearly	No	No
606	Muhammad Reza	Retail	Permana Home	Fiber Optic	30.0	Sumatera Utara	No	Yearly	No	No
161	EXPERED INTERNATIONAL BV - SITE PT. WORLDLINE ...	Corporate	Permana Dedicated	Fiber Optic	30.0	DKI Jakarta	Yes	Yearly	No	No
355	PENGADILAN NEGERI ROKAN HILIR	Corporate	Permana Dedicated	Fiber Optic	50.0	Riau	Yes	Yearly	No	No
197	BPR Barelang Mandiri - Site ATM Nagoya Hill	Corporate	Permana Link	Fiber Optic	10.0	Kepulauan Riau	Yes	Yearly	No	No

Gambar 2. Raw data sample

3.2. Hasil Preprocessing Data

Tahapan preprocessing dilakukan sebelum data digunakan dalam pelatihan model BiLSTM, dengan hasil sebagai berikut.

3.2.1. Missing Value

Penanganan *missing value* yang ditangani menggunakan metode *deletion*, yaitu dengan menghapus record yang memiliki nilai kosong. Penghapusan ini dilakukan agar model tidak menerima input yang tidak valid dan menghindari distorsi pada proses pelatihan.

3.2.2. Labeling Data

Label *churn* dirubah kedalam bentuk kategorikal ("Yes" dan "No") dikonversi menjadi format numerik, yaitu:

Yes \rightarrow 1

No \rightarrow 0

Konversi ini dilakukan agar data dapat diproses oleh model *Deep Learning*, khususnya dalam skenario klasifikasi biner.

3.2.3. Standarisasi Data

Seluruh fitur numerik dilakukan transformasi menggunakan standar distribusi Gaussian, yaitu mean = 0 dan standar deviasi = 1. Proses ini membantu mempercepat konvergensi model dan meningkatkan performa pelatihan. Gambar 3 menunjukkan hasil dataset bersih setelah melewati tahap data *exploration*. Terdapat sejumlah 849 data dengan 8 variabel data yang siap untuk digunakan dalam melakukan *training* model.

	Service_types	Packet_service	Media_transmisi	Bandwidth	State	Partner	Contract	Complaint	Churn
476	0	0	1	30.0	6	0	1	0	1
142	1	0	0	25.0	0	1	1	0	0
257	1	1	1	20.0	0	1	1	0	0
832	0	0	1	30.0	6	0	0	0	0
98	1	2	3	20.0	0	1	1	0	0

Gambar 3. Sampel data hasil *preprocessing*

3.3. Hasil Training Model BiLSTM

Setelah proses *preprocessing* selesai, model Bidirectional Long Short-Term Memory (BiLSTM) dilatih menggunakan data yang telah disiapkan. Pelatihan model dilakukan menggunakan teknik 5-Fold Cross Validation untuk menghindari *overfitting* dan meningkatkan generalisasi. Tabel 2 menunjukkan hasil metrik evaluasi pada masing-masing *fold*.

Tabel 2. Hasil metrik evaluasi setiap *fold*

<i>Fold</i>	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
1	92,35	100	91,61	95,62
2	87,65	100	86,18	92,58
3	88,24	100	87,58	93,38
4	90,59	98,60	90,97	94,63
5	86,98	100	86,08	92,52

Dari hasil metrik evaluasi (Gambar 4) *fold* menunjukkan, nilai rata-rata (*mean*) evaluasi untuk akurasi adalah 89,16 %, untuk presisi 99,72%, untuk *recall* 88,48%, dan *F1-Score* nya adalah 93,75%. Hasil *training* model BiLSTM menunjukkan performa yang sangat baik dalam mendeteksi pelanggan yang kemungkinan akan melakukan *churn*. Presisi yang tinggi menunjukkan bahwa model hampir tidak melakukan kesalahan dalam melakukan prediksi. Sementara, nilai *recall* yang juga tinggi mengindikasikan bahwa sebagian besar pelanggan *churn* berhasil terdeteksi. *F1-Score* yang tinggi (diatas 93%) menegaskan keseimbangan antara presisi dan *recall*, yang sangat penting dalam konteks *churn prediction*, karena kesalahan klasifikasi bisa berakibat pada keputusan bisnis yang kurang tepat.

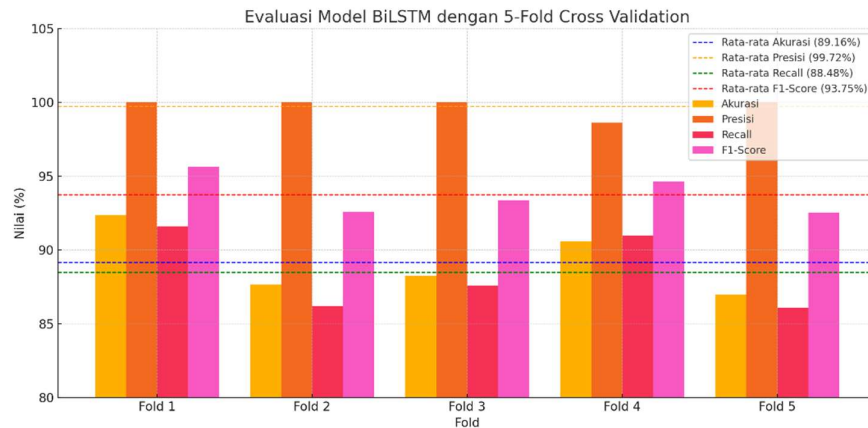
3.4. Evaluasi Menggunakan Confusion Matrix

Selain menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, evaluasi model BiLSTM dalam penelitian ini juga dilakukan dengan menggunakan confusion matrix. Confusion matrix memberikan informasi yang lebih rinci mengenai performa model dalam mengklasifikasikan pelanggan yang *churn* dan tidak *churn*.

Tabel 3. Hasil *confusion matrix*

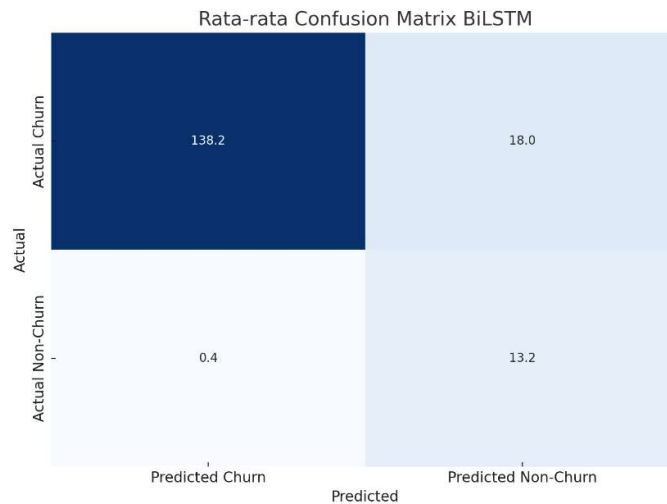
<i>Fold</i>	TP	FP	FN	TN
1	142	0	13	15
2	131	0	21	18
3	141	0	20	9
4	141	2	14	13
5	136	0	22	11

Dari hasil *confusion matrix* yang ditunjukkan pada tabel 3, perhitungan nilai rata-rata dari masing-masing komponen yaitu rata-rata dari *TP (True Positive)* adalah sebesar 138,2, *FP (False Positive)* sebesar 0,4, *FN (False Negative)* sebesar 18,0, dan *TN (True Negative)* sebesar 13,2.



Gambar 4. Evaluasi model BiLSTM 5-fold cross validation

Gambar 5 menunjukkan visualisasi dalam bentuk *heatmap confusion matrix* rata-rata dari hasil evaluasi model BiLSTM yang menggunakan *5-fold cross validation*. Prediksi *churn* benar (*True Positive*) rata-rata menunjukkan bahwa model mampu memprediksi pelanggan yang benar-benar *churn* dengan sangat baik. Prediksi *non-churn* benar (*True Negative*) menyatakan model cukup akurat dalam mengenali pelanggan yang tetap bertahan. Rata-rata *False Positive* sangat rendah yaitu **0.4**, mengindikasikan bahwa model hampir tidak pernah salah memprediksi pelanggan *non-churn* sebagai *churn*. Sedangkan rata-rata *False Negative* menunjukkan bahwa sebagian kecil pelanggan yang sebenarnya *churn* diprediksi tidak *churn* oleh model.




Gambar 5. Rata-rata *confusion matrix*

3.5. Trade-off Antara Sensitivitas dan Sensibilitas Model

Untuk mengevaluasi kemampuan model BiLSTM dalam membedakan pelanggan yang melakukan *churn* dan yang tidak, dilakukan analisis menggunakan kurva Receiver Operating Characteristic (ROC) serta perhitungan Area Under Curve (AUC) pada setiap fold dalam proses validasi silang 5-fold.

Hasil analisis ditampilkan pada Gambar 6, yang memperlihatkan kurva ROC untuk masing-masing fold. Kurva-kurva tersebut cenderung mendekati sudut kiri atas grafik, yang menunjukkan performa klasifikasi yang sangat baik. Seluruh nilai AUC yang diperoleh berada di atas angka 0,90, mengindikasikan bahwa model memiliki tingkat sensitivitas dan spesifisitas yang tinggi. Hal ini menunjukkan bahwa model BiLSTM dapat menjadi alat yang andal dalam mendukung pengambilan keputusan terkait strategi retensi pelanggan.



Gambar 6. Kurva ROC dan nilai AUC Model BiLSTM setiap *fold*

4. KESIMPULAN

Model BiLSTM terbukti efektif dalam memprediksi pelanggan yang berpotensi churn di PT Medianusa Permana. Dengan akurasi 89,16%, presisi 99,72%, recall 88,48%, dan F1-Score 93,75%, model menunjukkan kinerja yang sangat baik dan seimbang. Evaluasi melalui confusion matrix juga memperkuat bahwa model mampu meminimalkan kesalahan prediksi, khususnya pada pelanggan non-churn. Sistem prediksi berbasis BiLSTM terbukti memberikan hasil yang akurat, yang didukung oleh persentase akurasi model sebesar 89,16% dan presisi hingga 99,72%.

Meskipun model BiLSTM menunjukkan performa yang sangat baik dalam memprediksi churn pelanggan, pendekatan ini masih memiliki beberapa keterbatasan, seperti penggunaan data yang terbatas pada histori dari sistem CRM, serta ketidakseimbangan kelas pada dataset yang dapat menyebabkan bias terhadap kelas mayoritas. Pengembangan lanjutan dapat diarahkan pada integrasi model dengan sistem monitoring real-time, perluasan fitur menggunakan data dari media sosial, *call log*, atau perilaku pengguna, serta eksplorasi arsitektur lanjutan seperti BiLSTM+Attention atau Transformer untuk meningkatkan akurasi dan interpretabilitas model.

REFERENSI

- [1] M. N. Faladiba dan R. Haryastuti, "Churn Analisis Pada Data Pelanggan Telekomunikasi Menggunakan Ensemble learning," *Statmat: Jurnal Statistika dan Matematika*, vol. 5, no. 1, pp. 45–54, Jan. 2023. <https://doi.org/10.32493/sm.v5i1.31934>.
- [2] I. M. Latief, A. Subekti, and W. Gata, "Prediksi Tingkat Pelanggan Churn Pada Perusahaan Telekomunikasi Dengan Algoritma Adaboost," *Jurnal Informatika*, vol. 21, no. 1, pp. 34–43, 2021, doi: 10.30873/ji.v21i1.2867.
- [3] P. C. Verhoef and B. Donkers, "The effect of Acquisition Channels on Customer Retention and Cross-buying," *Journal of Interactive Marketing*, vol. 19, no. 2, pp. 31–43, 2005, doi: 10.1002/dir.20033.
- [4] Badan Pusat Statistik, *Statistik Telekomunikasi Indonesia 2022*, Jakarta, Indonesia, 31 Agustus 2023. [Online]. Tersedia: <https://www.bps.go.id/id/publication/2023/08/31/131385d0253c6aae7c7a59fa/statistik-telekomunikasi-indonesia-2022.html>.
- [5] A. W. S. Putra, "Prediksi Customer Churn pada Perusahaan Telekomunikasi Menggunakan Algoritma C4.5 Berbasis Particle Swarm Optimization," *Jurnal Teknik Informatika dan Sistem Informasi (JATI)*, vol. 9, no. 5, pp. 1–6, 2022, doi: 10.36040/jati.v9i5.7476.
- [6] A. K. Ahmad, A. Jafar, and K. Aljoumaa, "Customer churn prediction in telecom using machine learning in big data platform," *Journal of Big Data*, vol. 6, no. 1, p. 28, Dec. 2019, doi: 10.1186/s40537-019-0191-6.
- [7] A. W. S. Putra, "Prediksi Customer Churn pada Perusahaan Telekomunikasi Menggunakan Algoritma C4.5 Berbasis Particle Swarm Optimization," *Jurnal Teknik Informatika dan Sistem Informasi (JATI)*, vol. 7, no. 5, pp. 1–6, 2022, doi: 10.36040/jati.v7i5.7476.
- [8] P. Lalwani, M. Mishra, J. Chadha, and P. Sethi, "Customer Churn Prediction System: A Machine Learning Approach," *Computing*, vol. 104, pp. 1–24, Feb. 2022, doi: 10.1007/s00607-021-00908-y.
- [9] G. Molnar and S. Savage, "Market Structure and Broadband Internet Quality," *The Journal of Industrial Economics*, vol. 65, pp. 73–104, Mar. 2017, doi: 10.1111/joie.12106.
- [10] M. A. Aldalan dan A. Almaleh, "Customer Churn Prediction Using Four Machine Learning Algorithms Integrating Feature Selection and Normalization in the Telecom Sector," *World Academy of Science, Engineering and Technology International Journal of Electronics and Communication Engineering*, vol. 17, no. 3, 2023.
- [11] R. C. Admanegara dan W. Handayani, "Customer Churn Analysis Using Machine Learning to Improve Customer Retention on Vissie Net," *International Journal of Scientific Research and Management (IJSRM)*, vol. 12, no. 09, pp. 7379–7387, Sep. 2024, doi: <https://doi.org/10.18535/ijrm/v12i09.em05>.
- [12] A. Khattak, Z. Mehak, H. Ahmad, M. Asghar, M. Asghar, and A. Khan, "Customer churn prediction using composite deep learning technique," *Scientific Reports*, vol. 13, Oct. 2023, doi: 10.1038/s41598-023-44396-w.
- [13] H. Nalatissifa and H. Pardede, "Customer Decision Prediction Using Deep Neural Network on Telco Customer Churn Data," *Jurnal Elektronika dan Telekomunikasi*, vol. 21, pp. 122–127, Dec. 2021, doi: 10.14203/jet.v21i122-127.
- [14] A. Husein and M. Harahap, "Pendekatan Data Science untuk Menemukan Churn Pelanggan pada Sector Perbankan dengan Machine Learning," *Data Sciences Indonesia (DSI)*, vol. 1, pp. 8–13, Nov. 2021, doi: 10.47709/dsi.v1i1.1169.

-
- [15] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, 2023, doi: 10.34312/euler.v11i1.19791
- [16] D. G. da Silva dan A. A. M. Meneses, "Comparing Long Short-Term Memory (LSTM) and Bidirectional LSTM Deep Neural Networks for Power Consumption Prediction," *Energy Reports*, vol. 10, pp. 3315–3334, Nov. 2023, doi: 10.1016/j.egy.2023.09.175.
- [17] G. Fitrinanda dan A. Djunaidy, "Peramalan Harga Saham PT Adaro Energy Indonesia Tbk yang Mempertimbangkan Faktor Kurs Dolar Amerika Menggunakan Bidirectional Long-Short Term Memory," *Jurnal Teknik ITS*, vol. 11, no. 3, pp. A169–A176, 2022, doi: 10.12962/j23373539.v11i3.92124.
- [18] Y. Cahyadi, S. Redjeki, A. Almagribi, B. Satriani, N. Naufal, "Bidirectional Long Short-Term Memory Model for Intent Classification in Customer Service Chatbot," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 1, p. 296–301, Maret 2025. doi:10.30811/jaise.v5i1.6520.
- [19] Y. Liu, M. Shengdong, G. Jijian, and N. Nedjah, "Intelligent Prediction of Customer Churn with a Fused Attentional Deep Learning Model," *Mathematics*, vol. 10, no. 24, p. 4733, Dec. 2022, doi: 10.3390/math10244733.
- [20] C. Herdian, A. Kamila, dan I. G. A. M. Budidarma, "Studi Kasus Feature Engineering Untuk Data Teks: Perbandingan Label Encoding dan One-Hot Encoding Pada Metode Linear Regresi," *Technologia: Jurnal Ilmiah*, vol. 15, no. 1, pp. 93–108, Jan. 2024, doi: 10.31602/tji.v15i1.13457.