

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**PREDIKSI *CHURN* PELANGGAN DALAM *CUSTOMER*
RELATIONSHIP MANAGEMENT DENGAN MODEL
*GWO-ATTENTION-CONVLSTM***

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat
untuk Memperoleh Gelar Sarjana Komputer pada
Program Studi Sistem Informasi



Oleh:

PEDRO MASDY

12250311042



UIN SUSKA RIAU

UIN SUSKA RIAU

FAKULTAS SAINS DAN TEKNOLOGI

UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU

PEKANBARU

2026

LEMBAR PERSETUJUAN
PREDIKSI *CHURN* PELANGGAN DALAM *CUSTOMER*
***RELATIONSHIP* MANAGEMENT DENGAN MODEL**
GWO-ATTENTION-CONVLSTM

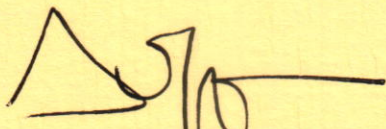
TUGAS AKHIR

Oleh:

PEDRO MASDY
12250311042

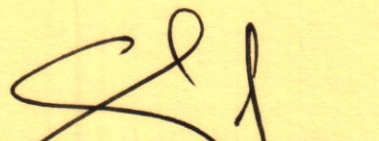
Telah diperiksa dan disetujui sebagai laporan tugas akhir
di Pekanbaru, pada tanggal 15 Januari 2026

Ketua Program Studi



Angraini, S.Kom., M.Eng., Ph.D.
NIP. 198408212009012008

Pembimbing



Siti Monalisa, ST., M.Kom.
NIP. 198502142015032004

LEMBAR PENGESAHAN

PREDIKSI *CHURN* PELANGGAN DALAM *CUSTOMER* *RELATIONSHIP* MANAGEMENT DENGAN MODEL *GWO-ATTENTION-CONVLSTM*

TUGAS AKHIR

Oleh:

PEDRO MASDY


12250311042

Telah dipertahankan di depan sidang dewan penguji
sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau
di Pekanbaru, pada tanggal 06 Januari 2026

Pekanbaru, 06 Januari 2026

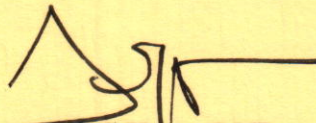
Mengesahkan,

Dekan


Dr. Yuslenita Muda, M.Sc.

NIP. 197701032007102001

Ketua Program Studi


Angraini, S.Kom., M.Eng., Ph.D.
NIP. 198408212009012008

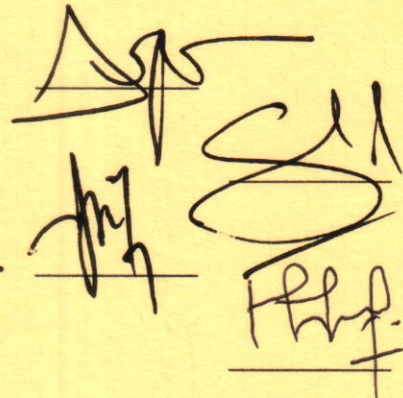
DEWAN PENGUJI:

Ketua : Angraini, S.Kom., M.Eng., Ph.D.

Sekretaris : Siti Monalisa, ST., M.Kom.

Anggota 1 : Fitriani Muttakin, S.Kom., M.Cs.

Anggota 2 : Megawati, S.Kom., MT.



Lampiran Surat :
Nomor : Nomor 25/2021
Tanggal : 10 September 2021

SURAT PERNYATAAN

Saya yang bertandatangan di bawah ini:

Nama : Pedro Masdy
NIM : 12250311042
Tempat/Tgl. Lahir : Pekanbaru, 10 Desember 2003
Fakultas/~~Pascasarjana~~ : Sains dan Teknologi
Prodi : Sistem Informasi

Judul Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya*:

PREDIKSI CHURN PELANGGAN DALAM CUSTOMER RELATIONSHIP
MANAGEMENT DENGAN MODEL GWO- ATTENTION - CONV LSTM.

Menyatakan dengan sebenar-benarnya bahwa :

1. Penulisan Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya* dengan judul sebagaimana tersebut di atas adalah hasil pemikiran dan penelitian saya sendiri.
2. Semua kutipan pada karya tulis saya ini sudah disebutkan sumbernya.
3. Oleh karena itu Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya* saya ini, saya nyatakan bebas dari plagiat.
4. Apa bila dikemudian hari terbukti terdapat plagiat dalam penulisan Disertasi/Thesis/Skripsi/(Karya Ilmiah lainnya)* saya tersebut, maka saya bersedia menerima sanksi sesuai peraturan perundang-undangan.

Demikianlah Surat Pernyataan ini saya buat dengan penuh kesadaran dan tanpa paksaan dari pihak manapun juga.

Pekanbaru, 21 Januari 2026
Yang membuat pernyataan



NIM : 12250311042

*pilih salah satu sesuai jenis karya tulis



LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL

Tugas Akhir yang tidak diterbitkan ini terdaftar dan tersedia di Perpustakaan Universitas Islam Negeri Sultan Syarif Kasim Riau adalah terbuka untuk umum, dengan ketentuan bahwa hak cipta ada pada peneliti. Referensi kepustakaan diperkenankan dicatat, tetapi pengutipan atau ringkasan hanya dapat dilakukan atas izin peneliti dan harus dilakukan mengikuti kaedah dan kebiasaan ilmiah serta menyebutkan sumbernya.

Penggandaan atau penerbitan sebagian atau seluruh Tugas Akhir ini harus memperoleh izin tertulis dari Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau. Perpustakaan dapat meminjamkan Tugas Akhir ini untuk anggotanya dengan mengisi nama, tanda peminjaman dan tanggal pinjam pada *form* peminjaman.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



UIN SUSKA RIAU



LEMBAR PERNYATAAN

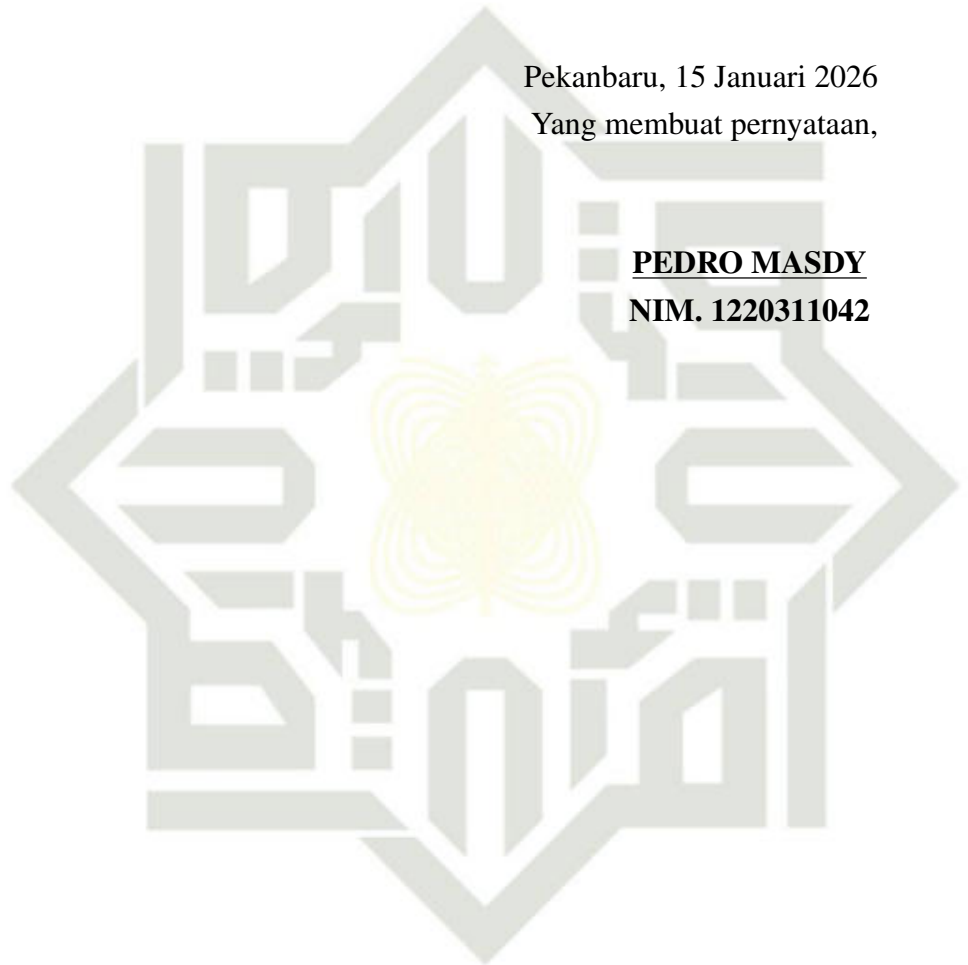
Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar kesarjanaan di suatu Perguruan Tinggi, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan di dalam daftar pustaka.

Pekanbaru, 15 Januari 2026

Yang membuat pernyataan,

PEDRO MASDY

NIM. 1220311042



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



LEMBAR PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Dengan menyebut nama Allah yang maha pengasih lagi maha penyayang

Alhamdulillah Rabbil 'Alamin, segala puji bagi Allah Subhanahu Wa Ta'ala sebagai bentuk rasa syukur atas segala nikmat yang telah diberikan tanpa ada kekurangan sedikitpun. Shalawat beserta salam tidak lupa pula kita ucapkan kepada Nabi Muhammad Shallallahu 'Alaihi Wa Sallam dengan mengucapkan Allahumma Sholli'ala Sayyidina Muhammad Wa'ala Ali Sayyidina Muhammad. Semoga kita semua selalu senantiasa mendapat syafaat-Nya di dunia maupun di akhirat, Aamiin Ya Rabbal'alaamiin.

Dengan penuh rasa syukur dan kebanggaan, peneliti menyusun Tugas Akhir ini sebagai bagian dari pencapaian akademik peneliti. Tugas Akhir ini tidak hanya merupakan wujud dari hasil kerja keras dan dedikasi peneliti selama ini, tetapi juga merupakan bentuk penghargaan dan terima kasih peneliti kepada kedua orang tua yang telah memberikan dukungan dan kasih sayang yang tiada henti.

Untuk keluarga tercinta, peneliti ingin menyampaikan rasa terima kasih yang mendalam atas peran besar serta dukungan yang telah di berikan selama perjalanan pendidikan ini. Tanpa bimbingan, do'a, dan dorongan moral dari keluarga tercinta, peneliti tidak akan mampu mencapai tahap ini. Kehadiran dan semangat yang di berikan senantiasa menjadi sumber kekuatan dan motivasi sehingga setiap tantangan dan kesulitan yang dihadapi terasa lebih ringan.

Karya ini peneliti persembahkan sebagai bentuk penghormatan, rasa terima kasih dan bakti khususnya kepada kedua orang tua tercinta. Terima kasih yang tak terhingga atas segala cinta, pengorbanan dan kesabaran dalam merawat serta membesarkan peneliti dengan sepenuh hati, hingga peneliti dapat meraih gelar sarjana seperti yang diimpikan.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

© Hak cipta milik UIN Suska Riau
State Islamic University of Sultan Syarif Kasim Riau



KATA PENGANTAR

Puji dan syukur peneliti panjatkan ke hadirat Allah SWT yang telah melimpahkan rahmat dan karunia-Nya sehingga peneliti dapat menyelesaikan Tugas Akhir dengan judul "Prediksi Churn Pelanggan Dalam Customer Relationship Management Dengan Model *Grey Wolf Optimizer-Attention-ConvLSTM*". Tugas Akhir ini disusun untuk memenuhi salah satu syarat dalam menyelesaikan sarjana di Program Studi Sistem Informasi Universitas Islam Negeri Sultan Syarif Kasim Riau.

Dalam proses penyusunan Tugas Akhir ini, peneliti telah menerima banyak dukungan, bimbingan dan bantuan dari berbagai pihak. Oleh karena itu, peneliti ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Ibu Prof. Dr. Hj. Leny Nofianti MS, SE, M.Si, Ak, CA., sebagai Rektor Universitas Islam Negeri Sultan Syarif Kasim Riau.
2. Ibu Dr. Yuslenita Muda, M.Sc., sebagai Dekan Fakultas Sains dan Teknologi.
3. Ibu Angraini, S.Kom., M.Eng., Ph.D., sebagai Ketua Program Studi Sistem Informasi, sekaligus Pembimbing Akademik Peneliti, dan Ketua Sidang Tugas Akhir ini
4. Ibu Dr. Rice Novita, S.Kom., M.Kom., sebagai Sekretaris Program Studi Sistem Informasi Islam Negeri Sultan Syarif Kasim Riau
5. Ibu Siti Monalisa, ST., M.Kom., sebagai dosen pembimbing Tugas Akhir ini.
6. Ibu Fitriani Muttakin, S.Kom., M.Cs., sebagai penguji pertama Tugas Akhir ini.
7. Ibu Megawati, S.Kom., MT., sebagai penguji kedua Tugas Akhir ini.
8. Ayah dan Bunda penulis yang senantiasa mendukung penulis dalam pembuatan laporan Tugas Akhir
9. Kepada saudara dan saudari penulis yang terus memberikan semangat dan motivasi kepada penulis dapat menyelesaikan Kerja Praktek.
10. Teman-teman, "Awal yang baru" yang Persahabatan ini bukan sekadar kebetulan, melainkan sebuah takdir yang mempertemukan kita dalam tawa, canda, perjuangan, hingga setiap momen berharga yang kita lalui bersama
11. Segenap Dosen dan Karyawan Program Studi Sistem Informasi Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau.

Semoga segala do'a dan dorongan yang telah diberikan selama ini menjadi amal kebajikan dan mendapat balasan setimpal dari Allah *Subhanahu Wa Ta'ala*.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

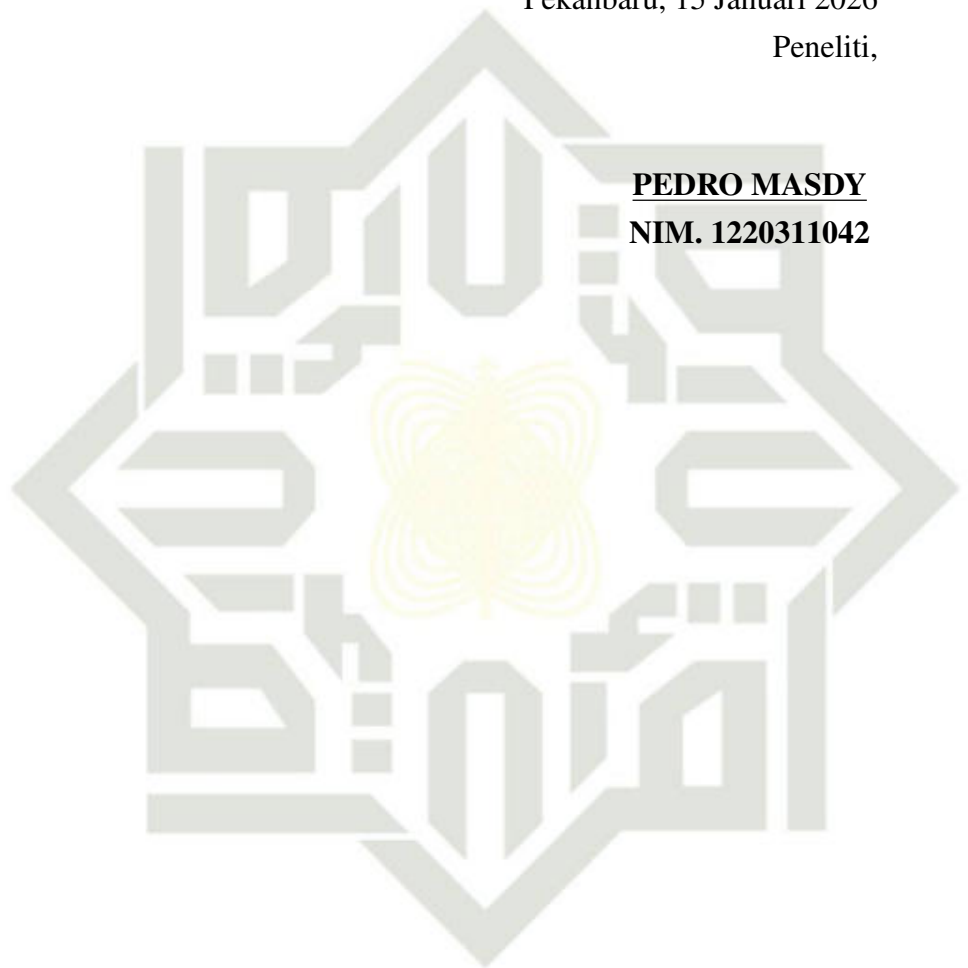
Peneliti menyadari bahwa penulisan Tugas Akhir ini masih terdapat kekurangan dan jauh dari kata sempurna. Peneliti berharap masukan dan saran yang membangun agar dapat disampaikan melalui *e-mail* 12250311042@students.uin-suska.ac.id untuk Tugas Akhir ini dan semoga Laporan Tugas Akhir ini bermanfaat bagi kita semua. Akhir kata peneliti ucapkan terima kasih.

Pekanbaru, 15 Januari 2026

Peneliti,

PEDRO MASDY

NIM. 1220311042



UIN SUSKA RIAU



1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

PREDIKSI *CHURN* PELANGGAN DALAM *CUSTOMER RELATIONSHIP MANAGEMENT* DENGAN MODEL *GWO-ATTENTION-CONVLSTM*

PEDRO MASDY
NIM: 12250311042

Tanggal Sidang: 06 Januari 2026
Periode Wisuda:

Program Studi Sistem Informasi
Fakultas Sains dan Teknologi
Universitas Islam Negeri Sultan Syarif Kasim Riau
Jl. Soebrantas, No. 155, Pekanbaru

ABSTRAK

Penelitian ini mengusulkan model hibrida *GWO-Attention-ConvLSTM* untuk memprediksi *customer churn* pada *Customer Relationship Management (CRM)* berbasis data panel bulanan pelanggan asuransi tahun 2024. Data disusun menjadi urutan 12 bulan per pelanggan melalui *windowing* dan dipetakan ke tensor 5D berukuran ($\text{pelanggan} \times 12 \times 3 \times 3 \times 3$) agar *ConvLSTM* dapat mengekstraksi pola temporal-spasial. Keluaran *ConvLSTM* dirangkum menggunakan *attention* untuk menekankan bulan yang paling berpengaruh, sedangkan hiperparameter dioptimasi menggunakan *Grey Wolf Optimizer (GWO)* sebelum pelatihan akhir. Evaluasi dilakukan menggunakan akurasi, presisi, recall, F1-score, dan *Area Under the Curve (AUC)*. Pada data uji, model mencapai *AUC* 0.9377 dan akurasi 0.8663. Dengan *threshold* 0.35, recall 0.6923 dan presisi 0.7000, yang menunjukkan peningkatan sensitivitas deteksi churn dengan konsekuensi kenaikan *false positive*. Model menghasilkan peringkat risiko churn yang dapat diintegrasikan sebagai masukan keputusan retensi pada sistem CRM.

Kata kunci: *customer churn, CRM, ConvLSTM, Attention Mechanism, Grey Wolf Optimizer*

UIN SUSKA RIAU



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

CUSTOMER CHURN PREDICTION IN CUSTOMER RELATIONSHIP MANAGEMENT USING THE GWO-ATTENTION-CONVLSTM MODEL

PEDRO MASDY
NIM: 12250311042

Date of Final Exam: Januari 06th 2026
Graduation Period:

Department of Information System
Faculty of Science and Technology
State Islamic University of Sultan Syarif Kasim Riau
Soebrantas Street, No. 155, Pekanbaru

ABSTRACT

This study proposes a GWO–Attention–ConvLSTM hybrid model for customer churn prediction in Customer Relationship Management (CRM) using monthly insurance panel data (2024). Customer records are organized into 12-month sequences via windowing and mapped into a 5D tensor ($customers \times 12 \times 3 \times 3 \times 3$) to enable temporal–spatial feature extraction by ConvLSTM. The ConvLSTM outputs are aggregated using an attention mechanism to emphasize the most influential months, while hyperparameters are optimized with the Grey Wolf Optimizer (GWO) prior to final training. Performance is evaluated using accuracy, precision, recall, F1-score, and Area Under the Curve (AUC). On the test set, the model achieves an AUC of 0.9377 and an accuracy of 0.8663. With a classification threshold of 0.35, recall reaches 0.6923 while precision is 0.30, indicating higher churn sensitivity at the cost of increased false positives. The resulting churn-risk ranking can support retention prioritization within CRM decision support.

Keywords: *customer churn, CRM, ConvLSTM, Attention Mechanism, Grey Wolf Optimizer.*

UIN SUSKA RIAU

DAFTAR ISI

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LEMBAR PERSETUJUAN	ii
LEMBAR PENGESAHAN	iii
LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL	iv
LEMBAR PERNYATAAN	v
LEMBAR PERSEMBAHAN	vi
KATA PENGANTAR	vii
ABSTRAK	ix
ABSTRACT	x
DAFTAR ISI	xi
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xv
DAFTAR SINGKATAN	xvi
1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	3
1.3 Batasan Masalah	3
1.4 Tujuan	3
1.5 Manfaat	3
1.6 Sistematika Penulisan	4
2 LANDASAN TEORI	5
2.1 Customer Relationship Management (CRM)	5
2.2 <i>Customer Churn</i>	5
2.3 Prediksi <i>Churn</i> Berbasis <i>Machine Learning</i>	6
2.4 <i>Convolutional Long Short-Term Memory</i> (ConvLSTM)	7
2.5 <i>Attention Mechanism</i>	9

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.6	<i>Grey Wolf Optimizer (GWO)</i>	9
2.7	Posisi Penelitian	10
2.8	Penelitian Terdahulu	10
3	METODOLOGI PENELITIAN	13
3.1	Desain Penelitian	13
3.2	Dataset Dan Sumber Data	14
3.3	Tahap Pengolahan Data	14
3.4	Preprocessing Data	15
3.5	Pembentukan Data Time Series (Windowing)	16
3.6	Pembentukan Tensor 5D	16
3.7	Arsitektur Model	17
3.7.1	<i>Grey Wolf Optimizer (GWO)</i>	17
3.7.2	<i>Convolutional LSTM (ConvLSTM)</i>	17
3.7.3	<i>Attention Mechanism</i>	17
3.7.4	<i>Fully Connected Layer</i>	18
3.8	Pembagian Data	18
3.9	Pelatihan Model	18
3.10	Evaluasi Model	19
4	ANALISIS DAN HASIL	21
4.1	Tahap Pengolahan Data	21
4.1.1	Struktur dan Karakteristik Dataset	21
4.1.2	Distribusi Label Churn	22
4.1.3	Contoh Data Mentah	22
4.2	Preprocessing	23
4.2.1	Pembersihan Nilai Hilang dan Kesalahan Data	23
4.2.2	Encoding Kolom Kategorikal	24
4.2.3	Rekayasa Fitur (Feature Engineering)	24
4.2.4	Seleksi Fitur	25
4.2.5	Normalisasi Fitur	25
4.2.6	Hasil Akhir Preprocessing	25
4.3	Konversi Data Menjadi Urutan Waktu (<i>Windowing</i>)	26
4.3.1	Proses Windowing	26
4.3.2	Hasil Windowing Dataset	26
4.3.3	Representasi Array	27
4.4	Pembentukan Tensor 5D	27



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

4.4.1	Proses Pembentukan Tensor 5D	27
4.4.2	Bentuk Tensor	27
4.4.3	Hasil Tensorisasi Seluruh Dataset	28
4.5	Convolutional LSTM	28
4.6	<i>Attention Mechanism</i>	29
4.7	<i>Grey Wolf Optimizer</i> (GWO)	29
4.8	Visualisasi Hasil Penelitian	30
4.8.1	Distribusi Prediksi <i>Churn</i>	30
4.8.2	Confussion Matrix	31
4.8.3	Kurva ROC dan AUC	32
4.8.4	Grafik Accuracy dan Loss	33
4.9	Evaluasi Hasil Prediksi	34
4.10	Hasil Prediksi	35
4.11	Implikasi Sistem Informasi	37
5	PENUTUP	39
5.1	Kesimpulan	39
5.2	Saran	39
DAFTAR PUSTAKA		
LAMPIRAN A DATA TRANSAKSI		A - 2
LAMPIRAN B CODE PYTHON		B - 1



DAFTAR GAMBAR

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.1	Struktur Model ConvLSTM	7
3.1	Metodologi Penelitian	13
4.1	Distribusi Hasil Prediksi Churn	30
4.2	Confussion Matrix	31
4.3	Kurva ROC dan AUC	32
4.4	Grafik Accuracy dan Loss	33
4.5	Top 20 Probability <i>Churn</i>	36
A.1	Data Transaksi 12 Bulan	A - 2
A.2	Data Transaksi 12 Bulan	A - 2
B.1	<i>Code Phyton</i> Untuk Pengolahan Data <i>Deep Learning</i>	B - 1
B.2	<i>Code Phyton</i> Untuk Pengolahan Data <i>Deep Learning</i>	B - 1



DAFTAR TABEL

2.1	Penelitian Terdahulu 1	10
2.2	Penelitian Terdahulu 2	11
2.3	Penelitian Terdahulu 3	12
4.1	Contoh Data Mentah	22
4.2	Tabel Perbandingan Pelanggan Churn	23
4.3	Contoh Hasil Validasi Data	24
4.4	Contoh Data Hasil Encoding Kolom Kategorikal	24
4.5	Hasil Tahapan Seleksi Fitur	24
4.6	Contoh Hasil Rekayasa Fitur <i>arrears_ratio</i>	25
4.7	Tahapan Normalisasi Fitur	25
4.8	Tabel Hasil Tahapan Preprocessing	26
4.9	Data Hasil Windowing	26
4.10	Representasi Array	27
4.11	Ilustrasi Representasi Tensor pada Timestep Awal dan Akhir	28
4.12	Hasil Tensorisasi Seluruh Dataset	28
4.13	Perubahan Bentuk Data	28
4.14	Bentuk Data Pengolahan <i>Attention Mechanism</i>	29
4.15	Bentuk Data Pengolahan <i>Grey Wolf Optimizer</i>	30
4.16	Evaluasi Hasil Prediksi	34
4.17	Top 20 Probability Churn	35

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR SINGKATAN

2D	<i>Two-Dimensional</i> (dua dimensi)
3D	<i>Three-Dimensional</i> (tiga dimensi)
5D	<i>Five-Dimensional</i> (lima dimensi)
AI	<i>Artificial Intelligence</i>
AUC	<i>Area Under the Curve</i>
CLV	<i>Customer Lifetime Value</i>
CNN	<i>Convolutional Neural Network</i>
ConvLSTM	<i>Convolutional Long Short-Term Memory</i>
ConvLSTM2D	<i>Convolutional LSTM 2D</i>
CRM	<i>Customer Relationship Management</i>
F1-Score	<i>F1-Score</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
GRU	<i>Gated Recurrent Unit</i>
GWO	<i>Grey Wolf Optimizer</i>
KNN	<i>K-Nearest Neighbors</i>
LSTM	<i>Long Short-Term Memory</i>
ML	<i>Machine Learning</i>
MinMaxScaler	Metode normalisasi <i>min-max</i> (0–1)
RFM	<i>Recency, Frequency, Monetary</i>
ROC	<i>Receiver Operating Characteristic</i>
SVM	<i>Support Vector Machine</i>
TIK	Teknologi Informasi dan Komunikasi
TN	<i>True Negative</i>
TP	<i>True Positive</i>

UIN SUSKA RIAU



BAB 1

PENDAHULUAN

1.1 Latar Belakang

Dengan munculnya teknologi digital, Manajemen Hubungan Pelanggan (CRM) telah berevolusi menjadi sebuah konsep yang memanfaatkan Teknologi Informasi dan Komunikasi untuk memelihara hubungan pelanggan jangka panjang (Perez-Vega, Hopkinson, Singhal, dan Mariani, 2022). Berbagai penelitian pun telah menyoroti adanya kaitan antara implementasi CRM dengan peningkatan kinerja perusahaan di berbagai industri (Ivens, Kasper-Brauer, Leischnig, dan Thornton, 2024). Seiring dengan kemajuan teknologi digital, konsep Manajemen Hubungan Pelanggan (CRM) terus mengalami evolusi. Fokus utama dari CRM adalah pemanfaatan Teknologi Informasi dan Komunikasi (TIK) untuk memfasilitasi pengembangan serta pemeliharaan hubungan pelanggan jangka panjang. Berbagai penelitian telah menyoroti adanya kaitan yang kuat antara implementasi CRM dengan peningkatan kinerja perusahaan, di mana dampak positif ini telah teramati di berbagai sektor industri (Al-Kharabsheh, 2024).

Di tengah persaingan pasar yang ketat, perusahaan dihadapkan pada tantangan besar, yaitu fenomena perpindahan pelanggan (*Customer Churn*) (Manzoor, Qureshi, Kidney, dan Longo, 2024). Kehilangan pelanggan tidak hanya berarti hilangnya pendapatan di masa depan, tetapi juga dapat meningkatkan biaya akuisisi pelanggan baru, yang umumnya jauh lebih mahal daripada mempertahankan pelanggan yang sudah ada (L. Saha, Tripathy, Gaber, El-Gohary, dan El-kenawy, 2023). Oleh karena itu, kemampuan untuk memprediksi pelanggan yang berpotensi *churn* menjadi sangat krusial bagi keberlanjutan dan pertumbuhan bisnis (Khoh, Pang, Ooi, Wang, dan Poh, 2023).

Secara tradisional, prediksi *Customer Churn* seringkali mengandalkan metode statistik atau machine learning konvensional (Bhuria dkk., 2025). Meskipun metode ini telah memberikan kontribusi, mereka seringkali memiliki keterbatasan dalam menangani kompleksitas dan sifat dinamis dari data perilaku pelanggan. Data pelanggan modern, terutama di sektor layanan seperti telekomunikasi, memiliki karakteristik deret waktu (*time-series*) yang kaya (L. Saha dkk., 2023). Pola perilaku pelanggan berkembang dan berubah seiring waktu, dan metode konvensional seringkali gagal mengekstrak fitur spasial-temporal yang mendalam dari data berurutan ini. Akibatnya, model prediksi yang dihasilkan mungkin tidak cukup akurat atau andal untuk memberikan wawasan yang dapat ditindaklanjuti.



Sektor Asuransi adalah salah satu industri yang paling rentan terhadap *Customer Churn*. Tingkat persaingan yang tinggi, kemudahan bagi pelanggan untuk beralih penyedia layanan, serta perubahan preferensi pelanggan yang cepat, membuat retensi pelanggan menjadi prioritas utama (Yang, Xia, Zheng, Zhang, dan Yu, 2025). Diperlukan pendekatan yang lebih canggih untuk menganalisis data pelanggan yang masif dan dinamis guna mengidentifikasi sinyal-sinyal *churn* secara lebih efektif.

Dalam konteks asuransi, ketidakselarasan antara janji produk dan pemahaman nasabah (*mis-selling*/kurang literasi polis) memperlebar *expectation gap* (Lages, Perez-Vega, Kadić-Maglajlić, dan Borghei-Razavi, 2023). Ketika *expectation gap* muncul pada momen klaim/layanan, kepercayaan turun dan perilaku defensif seperti penundaan pembayaran hingga lapse lebih mungkin terjadi (Khan, Salamzadeh, Iqbal, dan Yang, 2022). Secara bisnis, kondisi ini menekan nilai hubungan pelanggan (CLV) dan memangkas peluang *cross/upsell* dalam kerangka CRM (Ngai dan Wu, 2022). Eskalasi keluhan juga meningkatkan risiko reputasi dan memperburuk kualitas interaksi layanan (Lages et al., 2023). Di level operasional, perusahaan merespons dengan strategi retensi proaktif berbasis prediksi *churn* mengalokasikan anggaran edukasi dan *win-back* ketimbang ekspansi murni (Gattermann-Itschert dan Thonemann, 2022).

Munculnya teknologi *deep learning* menawarkan solusi yang menjanjikan untuk mengatasi keterbatasan metode tradisional (De Bock dkk., 2024). Jaringan saraf tiruan yang dalam memiliki kemampuan luar biasa untuk mempelajari representasi fitur yang kompleks dari data mentah, termasuk data deret waktu. Dalam konteks prediksi *Customer Churn*, model *deep learning* dapat memanfaatkan pola perilaku pelanggan yang berurutan secara lebih efisien (L. Saha dkk., 2023). Salah satu arsitektur *deep learning* yang menunjukkan potensi besar untuk data deret waktu dan spasial adalah *Convolutional Long Short-Term Memory* (ConvLSTM) (Ge, Li, Cheng, dan Chen, 2022). Namun, untuk lebih meningkatkan kinerjanya, integrasi dengan mekanisme Attention dapat membantu model memfokuskan perhatian pada bagian data yang paling relevan (Shi dkk., 2024), sementara algoritma optimasi seperti *Grey Wolf Optimizer* (GWO) dapat menyempurnakan parameter model secara adaptif (Shidik dkk., 2024).

Oleh karena itu, penelitian ini mengusulkan penerapan model GWO-attention-ConvLSTM untuk memprediksi *Customer Churn* dalam konteks data pelanggan Perusahaan asuransi XYZ. Model hibrida ini diharapkan mampu mengekstraksi fitur spasial-temporal yang lebih kaya dari data perilaku pelanggan,



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

meningkatkan akurasi prediksi, dan pada akhirnya, memberikan alat yang lebih andal bagi perusahaan untuk merumuskan strategi retensi pelanggan yang proaktif dan efektif dalam upaya Manajemen Hubungan Pelanggan.

1.2 Perumusan Masalah

1. Bagaimana memodelkan data pelanggan yang bersifat dinamis dan berubah dari waktu ke waktu agar pola perilaku pelanggan dapat di analisis dengan lebih baik dalam prediksi *Customer Churn*?
2. Bagaimana membangun model prediksi *Customer Churn* yang mampu memahami pola waktu, menyoroti fitur yang paling berpengaruh, serta mengoptimasi parameter secara otomatis melalui integrasi metode *ConvLSTM-Attention-Grey Wolf Optimizer (GWO)* untuk meningkatkan akurasi prediksi?

1.3 Batasan Masalah

Batasan masalah yang akan dibahas pada pembuatan laporan tugas akhir ini agar pembahasan tidak menyimpang dan melebar dari permasalahan maka penulis membatasi masalah hanya pada:

1. Data yang digunakan hanya mencakup nasabah Perusahaan asuransi XYZ tahun 2024 dengan data lengkap selama 12 bulan.
2. Model yang digunakan hanya *GWO-Attention-ConvLSTM*, tanpa membandingkan dengan model lain.
3. Hasil penelitian hanya berupa prediksi *churn*, tidak membahas strategi bisnis lanjutan atau keputusan manajemen.
4. Pengolahan data ini menggunakan *tools* Google Colab dan dibantu asisten AI dalam pengerjaannya.

1.4 Tujuan

Memprediksi *Customer Churn* berbasis *GWO-Attention-ConvLSTM* pada data pelanggan Perusahaan XYZ untuk menangkap pola spasial-temporal perilaku pelanggan secara efektif.

1.5 Manfaat

1. Menghasilkan model prediksi *churn* yang lebih akurat lewat kombinasi *ConvLSTM-Attention-GWO*.
2. Menyediakan alur kerja/*pipeline* yang jelas dan bisa diulang (pra-proses → pelatihan → evaluasi).
3. Menghasilkan skor risiko *churn* per pelanggan untuk membantu prioritas



1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

intervensi retensi.

4. Dapat diterapkan ulang pada data sejenis di organisasi lain dengan karakteristik mirip.

1.6 Sistematika Penulisan

Sistematika penulisan laporan adalah sebagai berikut:

BAB 1. PENDAHULUAN

Bab ini berisi latar belakang masalah, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan. Bab ini memberikan gambaran awal mengenai pentingnya penelitian serta arah dan ruang lingkup yang akan dibahas.

BAB 2. LANDASAN TEORI

Bab ini memuat kajian teoritis dan hasil-hasil penelitian terdahulu yang relevan. Dalam bab ini dibahas konsep-konsep dasar seperti *Customer Relationship Management* (CRM), *customer churn*, *deep learning*, ConvLSTM, *Attention Mechanism*, dan *Grey Wolf Optimizer* (GWO), serta bagaimana model-model tersebut telah diterapkan dalam konteks prediksi *churn*.

BAB 3. METODOLOGI PENELITIAN

Bab ini menjelaskan pendekatan penelitian yang digunakan, jenis dan sumber data, tahapan preprocessing data, rancangan arsitektur model GWO-Attention-ConvLSTM, serta metode evaluasi performa model seperti akurasi, precision, recall, F1-score, dan AUC.

BAB 4. ANALISA DAN PERANCANGAN

Berisi hasil eksperimen yang diperoleh dari implementasi model, analisis terhadap performa model yang diusulkan berdasarkan metrik evaluasi (*Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *AUC*), serta pembahasan kelebihan dan keterbatasan pendekatan yang digunakan

BAB 5. PENUTUP

Bab ini berisi kesimpulan dari hasil penelitian yang telah dilakukan serta saran untuk pengembangan dan penelitian selanjutnya agar hasil penelitian dapat ditingkatkan dan diimplementasikan lebih optimal.

BAB 2

LANDASAN TEORI

2.1 Customer Relationship Management (CRM)

Customer Relationship Management (CRM) adalah sebuah strategi bisnis komprehensif yang dirancang untuk mengelola dan menganalisis interaksi pelanggan dengan tujuan meningkatkan loyalitas dan retensi pelanggan (Farmania, Elsyah, dan Tuori, 2021). Pelanggan adalah titik kunci bagi perusahaan untuk terus berkembang karena produk yang dihasilkan tidak akan dibeli jika tidak ada pelanggan yang berarti kebangkrutan. Jadi, perusahaan harus dapat membuat program untuk membantu pelanggan mendukung setiap produk saat masuk ke pasar (Abdurohim dkk., 2022).

Dalam lingkungan bisnis yang sangat kompetitif, di mana produk dan layanan mudah ditiru, kemampuan untuk membangun dan memelihara hubungan jangka panjang dengan pelanggan menjadi keunggulan kompetitif yang krusial. Tujuan utama dari CRM adalah untuk memahami kebutuhan, preferensi, dan perilaku pelanggan secara lebih mendalam melalui pengumpulan dan analisis data. Dengan wawasan ini, perusahaan dapat memberikan layanan yang lebih personal dan relevan, yang pada akhirnya akan meningkatkan kepuasan dan mendorong pertumbuhan pendapatan (Paşcalău, Popescu, Bîrlădeanu, dan Gigauri, 2024).

Strategi CRM yang efektif tidak hanya berfokus pada pelanggan baru, tetapi juga pada pelanggan yang sudah ada. Mengelola hubungan dengan pelanggan yang loyal adalah investasi yang sangat berharga, karena biaya untuk mempertahankan pelanggan jauh lebih rendah daripada biaya untuk mengakuisisi pelanggan baru (Hason Rudd, Huo, dan Xu, 2022). Oleh karena itu, kemampuan untuk memprediksi dan mencegah kehilangan pelanggan atau *customer churn* adalah hal yang penting dari setiap inisiatif CRM yang sukses. Selain membangun hubungan dengan pelanggan, manajemen hubungan pelanggan (CRM) juga merupakan strategi untuk mengoptimalkan profitabilitas melalui peningkatan kepuasan pelanggan (Abdurohim dkk., 2022).

2.2 Customer Churn

Churn adalah penghentian hubungan pelanggan dengan perusahaan dalam horizon waktu tertentu, mencakup *voluntary* misalkan pindah karena harga, layanan atau *brand* dan *involuntary* misalkan pemblokiran akun atau kartu pasif (Lalwani, Mishra, Chadha, dan Sethi, 2022). Fenomena ini krusial dalam CRM karena berkaitan erat dengan loyalitas pelanggan melalui peran mediasi kepuasan (Khan dkk.,



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2022). Dalam analitik prediktif, tujuan utamanya adalah mengestimasi probabilitas individu untuk *churn* pada jangka waktu tertentu, $P(\text{churn} | x)$, agar intervensi retensi bisa tepat sasaran (Lalwani dkk., 2022). Data yang lazim dipakai mencakup riwayat transaksi atau penggunaan dan ukuran RFM (*Recency, Frequency, Monetary*) yang berubah seiring waktu (*time-varying*) juga interaksi layanan serta atribut pelanggan (Mena dkk., 2023). Tantangan sentralnya adalah ketidakseimbangan kelas, pendekatan seperti *oversampling* atau GAN-based *synthetic sampling* sering dipakai untuk mengatasinya (S. Saha, Saha, Haque, Alam, dan Talukder, 2024). Oleh karena itu, desain fitur, pemilihan horizon prediksi, dan metrik evaluasi seperti AUC, F1, serta *recall* kelas churn menjadi komponen kunci dalam studi *churn* modern (L. Saha dkk., 2023).

2.3 Prediksi Churn Berbasis Machine Learning

Pada data tabular, model *Machine Learning* (ML) klasik seperti *Decision Tree*, *Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN), dan *Random Forest* umumnya efektif, namun kurang luwes dalam menangkap pola temporal yang berubah-ubah (S. Saha dkk., 2024). Riset terkini mendorong penggunaan model deret waktu berbasis *deep learning* seperti *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), serta hibrida CNN–LSTM untuk mengekstrak representasi perilaku pelanggan dari sejarah penggunaan (S. Saha dkk., 2024; Abdurrohman dkk., 2022).

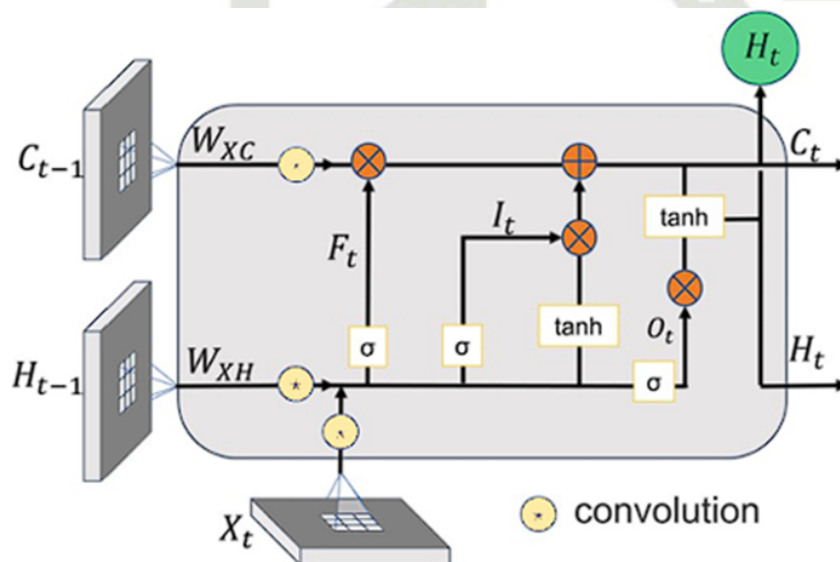
Masalah yang paling sering muncul pada dataset *churn* adalah ketidakseimbangan kelas, yang dapat membuat model menjadi bias terhadap kelas mayoritas (Zhu, Pan, vanden Broucke, dan Xiao, 2022). Akibatnya, arsitektur sekuens yang lebih kuat yang secara eksplisit memodelkan dinamika temporal, seperti varian CNN–LSTM, semakin banyak diadopsi (Wang, Rao, Hu, Xiao, dan Goh, 2024). Di saat yang sama, penalaan hiperparameter berbasis metaheuristik seperti *Grey Wolf Optimizer* (GWO) menjadi relevan untuk meningkatkan kinerja model secara handal (Makhadmeh dkk., 2023).

Dalam penilaian model prediksi kehilangan pelanggan ukuran yang berfokus pada akurasi sering kali tidak cukup menggambarkan hasil karena adanya ketidakseimbangan antara pelanggan yang pergi dan yang tetap. Oleh karena itu, kurva *Receiver Operating Characteristic* (ROC) dan nilai *Area Under the Curve* (AUC) sering digunakan untuk mengevaluasi seberapa baik model dapat membedakan kedua jenis pelanggan tersebut pada berbagai ambang keputusan. Nilai AUC menunjukkan seberapa baik model dapat melakukan diskriminasi secara keselu-

ruhan dan dianggap lebih konsisten dibandingkan dengan akurasi dalam situasi data yang tidak seimbang (Manzoor dkk., 2024).

2.4 Convolutional Long Short-Term Memory (ConvLSTM)

ConvLSTM adalah arsitektur hibrida yang menggabungkan elemen CNN dan LSTM dalam satu rangkaian pemrosesan urutan (Dehghani dkk., 2023). Berbeda dari LSTM standar yang hanya memakai operasi linear pada *gate*, ConvLSTM menerapkan operasi konvolusi pada input dan *gate* sehingga struktur spasial tetap terjaga (Yadav, Tiwari, Pandey, dan Akbar, 2022). Konfigurasi ini memungkinkan penangkapan pola spasial-temporal secara simultan pada data deret waktu yang kompleks (Yadav dkk., 2022). Pada data yang direpresentasikan sebagai urutan dua dimensi atau tiga dimensi (misalnya *frame* atau *heatmap* aktivitas), ConvLSTM efektif karena setiap “piksel” memuat konteks lokal yang berubah seiring waktu (Yadav dkk., 2022). Berikut Gambar 2.1 merupakan Struktur Model ConvLSTM



Gambar 2.1. Struktur Model ConvLSTM

Dalam konteks prediksi *churn* pada industri asuransi, pendekatan berbasis CNN-LSTM sebagai kerabat dekat ConvLSTM relevan untuk penilaian risiko churn karena mampu memodelkan pola perilaku nasabah yang bersifat berurutan dari data historis periodik. Pendekatan ini mendukung penggunaan arsitektur spatio-temporal untuk menangkap perubahan perilaku nasabah dari waktu ke waktu (Wang dkk., 2024). Dibandingkan dengan LSTM konvensional, studi peramalan deret waktu menunjukkan bahwa arsitektur berbasis ConvLSTM mampu



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

menangkap dinamika data yang tidak tertangkap oleh model yang hanya bersifat temporal (Dehghani dkk., 2023).

Dengan memasukkan operasi konvolusi ke dalam setiap *gate*, ConvLSTM merupakan pengembangan dari jaringan LSTM tradisional dan memungkinkan pemrosesan data sekuensial yang memiliki dimensi temporal dan informasi spasial. Persamaan pada setiap *gate* berikut dapat digunakan untuk menjelaskan mekanisme kerja ConvLSTM secara matematis (Zhang dan Zhang, 2024):

$$\mathbf{i}_t = \sigma(\mathbf{W}_{xi} * \mathbf{X}_t + \mathbf{W}_{hi} * \mathbf{H}_{t-1} + \mathbf{b}_i) \quad (2.1)$$

$$\mathbf{f}_t = \sigma(\mathbf{W}_{xf} * \mathbf{X}_t + \mathbf{W}_{hf} * \mathbf{H}_{t-1} + \mathbf{b}_f) \quad (2.2)$$

$$\mathbf{C}_t = \mathbf{f}_t \odot \mathbf{C}_{t-1} + \mathbf{i}_t \odot \tanh(\mathbf{W}_{xc} * \mathbf{X}_t + \mathbf{W}_{hc} * \mathbf{H}_{t-1} + \mathbf{b}_c) \quad (2.3)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_{xo} * \mathbf{X}_t + \mathbf{W}_{ho} * \mathbf{H}_{t-1} + \mathbf{b}_o) \quad (2.4)$$

$$\mathbf{H}_t = \mathbf{o}_t \odot \tanh(\mathbf{C}_t) \quad (2.5)$$

Dengan keterangan:

- \mathbf{i}_t : *input gate*
- \mathbf{f}_t : *forget gate*
- \mathbf{o}_t : *output gate*
- \mathbf{C}_t : *cell state*
- \mathbf{H}_t : *hidden state*
- \mathbf{W} : bobot konvolusi
- $*$: operasi konvolusi
- \odot : perkalian elemen (*Hadamard product*)

Dari Persamaan 2.1, Persamaan 2.3 Persamaan 2.2 Persamaan 2.5 Persamaan 2.4 tersebut dapat dipahami bahwa ConvLSTM mampu mempertahankan



informasi penting dari data historis sekaligus mempelajari pola spasial yang terdapat pada fitur input. Hal ini menjadikan ConvLSTM lebih efektif dibandingkan LSTM standar dalam mengolah data perilaku pelanggan yang bersifat multivariat dan temporal, seperti frekuensi *login*, jumlah keluhan, serta riwayat pembayaran.

2.5 Attention Mechanism

Attention Mechanism memungkinkan model memfokuskan perhatian pada bagian input yang paling relevan saat melakukan prediksi. Dalam kerangka GWO–Attention–ConvLSTM untuk prediksi *churn*, Attention menimbang *time step* dan fitur yang bernilai tinggi, misalnya lonjakan keluhan atau penurunan penggunaan menjelang terjadinya *churn*, sehingga konteks tertimbang yang masuk ke ConvLSTM menjadi lebih informatif. Pendekatan ini sejalan dengan temuan pada studi *churn* berbasis *deep learning* (Zhang dan Zhang, 2024) serta penerapan *attention* pada data sekuensial pelanggan (de Santana Correia dan Colombini, 2022).

Bersamaan dengan itu, GWO berperan dalam menyetel hiperparameter model secara adaptif untuk memaksimalkan kinerja. Kombinasi antara GWO, *Attention Mechanism*, dan ConvLSTM dilaporkan mampu meningkatkan nilai AUC, F1-score, dan *recall* pada kelas *churn* dibandingkan dengan model baseline, sebagaimana ditunjukkan dalam studi rujukan GWO–Attention–ConvLSTM tahun 2024 yang menjadi acuan utama dalam penelitian ini.

2.6 Grey Wolf Optimizer (GWO)

GWO adalah algoritma optimasi metaheuristik yang didasarkan pada hierarki sosial serigala abu-abu dan perilaku berburu di alam liar (Makhadmeh dkk., 2023). Algoritma ini meniru empat tingkat kepemimpinan serigala:

1. Alpha (α): Serigala pemimpin yang berada di puncak hierarki.
2. Beta (β): Serigala wakil pemimpin, yang membantu alpha.
3. Delta (δ): Serigala bawahan.
4. Omega (ω): Serigala dengan peringkat terendah.

Dalam konteks optimasi, solusi terbaik yang ditemukan oleh algoritma direpresentasikan sebagai α , diikuti oleh β dan δ . Serigala lainnya, yang bertindak sebagai ω , diarahkan untuk mendekati tiga serigala terbaik tersebut di ruang pencarian. Proses iteratif ini berlanjut hingga populasi serigala menemukan solusi yang optimal atau mendekati optimal (Meidani, Hemmasian, Mirjalili, dan Barati Fariyani, 2022).

Seperti yang dijelaskan dalam penelitian utama, keunggulan GWO adalah kemampuannya menyeimbangkan antara eksplorasi (mencari area solusi baru)

dan eksploitasi (memperhalus solusi yang ada). Hal ini menjadikannya efektif untuk menemukan parameter optimal pada model *deep learning*. Dalam penelitian ini, GWO digunakan untuk mengoptimalkan parameter dari model ConvLSTM–Attention, memastikan model beroperasi pada konfigurasi terbaiknya untuk memaksimalkan akurasi prediksi *churn* (Makhadmeh dkk., 2023; Meidani dkk., 2022).

2.7 Posisi Penelitian

Studi terdahulu membuktikan bahwa LSTM dan CNN–LSTM efektif untuk prediksi *churn*, serta mekanisme *attention* mampu meningkatkan kinerja model dengan menekankan informasi yang relevan. Namun, pada industri asuransi, riset yang secara simultan menggabungkan ConvLSTM (pola spasial–temporal), *attention* (fokus temporal), dan GWO sebagai penalaan hiperparameter masih terbatas. Sebagian besar penelitian sebelumnya berfokus pada sektor telekomunikasi atau tidak melibatkan komponen penalaran metaheuristik.

Penelitian ini mengisi celah tersebut dengan mengembangkan dan mengevaluasi model GWO–Attention–ConvLSTM pada data internal Perusahaan Asuransi XYZ. Tujuan penelitian ini adalah sebagai berikut:

1. membangun model prediksi *churn* yang *robust* pada metrik Recall, F1-Score, dan AUC melalui pemisahan data secara kronologis serta penanganan ketidakseimbangan kelas yang diterapkan hanya pada data latih
2. menyediakan interpretabilitas model melalui peta bobot *attention* untuk mengidentifikasi periode waktu dan fitur yang memicu risiko *churn*
3. menghasilkan skor risiko *churn* yang bersifat operasional dan dapat dimanfaatkan secara langsung dalam strategi retensi pelanggan.

2.8 Penelitian Terdahulu

Setiap penelitian diperlukan acuan dasar (referensi) yang berupa teori ataupun temuan-temuan melalui hasil penelitian yang telah dilakukan sebelumnya, hal tersebut disebut dengan kajian terdahulu. Kajian terdahulu berisi uraian secara sistematis mengenai hasil-hasil penelitian yang diperoleh dari penelitian sebelumnya dan memiliki keterkaitan dengan penelitian yang akan dilakukan.

Adapun beberapa kajian terdahulu yang relevan dengan judul penelitian ini dapat di lihat pada Tabel 2.1, Tabel 2.2, dan Tabel 2.3 berikut:

Tabel 2.1. Penelitian Terdahulu 1

Nama Peneliti	Iqbal Muhammad Latief, Agus Subekti, Windu Gata
----------------------	-------------------------------------------------

Judul Penelitian	Prediksi Tingkat Pelanggan <i>Churn</i> pada Perusahaan Telekomunikasi dengan Algoritma Adaboost
Metode Penelitian	Data mining menggunakan Algoritma <i>Ensemble</i> (<i>Adaboost</i> , <i>Random Forest</i> , <i>XGBoost</i>). Evaluasi dilakukan menggunakan pembagian dataset <i>train-test</i> dengan rasio 80:20.
Hasil Penelitian	Algoritma Adaboost memberikan akurasi tertinggi sebesar 80% dalam memprediksi <i>churn</i> pelanggan. Variabel yang paling berpengaruh terhadap <i>churn</i> adalah <i>TotalCharges</i> , <i>MonthlyCharges</i> , dan <i>Tenure</i> .
Perbedaan dengan Penelitian Ini	Penelitian ini hanya membandingkan algoritma machine learning klasik dan tidak menggunakan model <i>deep learning</i> , <i>attention mechanism</i> , maupun optimasi hiperparameter berbasis metaheuristik (GWO).
Persamaan dengan Penelitian Ini	Sama-sama membahas prediksi <i>churn</i> pelanggan dan menggunakan dataset pelanggan yang mencakup perilaku dan transaksi pelanggan.

Tabel 2.2. Penelitian Terdahulu 2

Nama Peneliti	Iip Imron Daipah, Rini Astuti, Willy Prihartono
Judul Penelitian	Prediksi <i>Churn</i> Pelanggan pada Layanan Desain Grafis Home Desain Menggunakan Algoritma Naïve Bayes
Metode Penelitian	Pendekatan Knowledge Discovery in Database (KDD) yang meliputi seleksi data, <i>preprocessing</i> , transformasi data, <i>data mining</i> , dan evaluasi. Algoritma yang digunakan adalah Naïve Bayes.
Hasil Penelitian	Model memperoleh performa sangat tinggi dengan nilai akurasi sebesar 99%, precision 1.00, recall 0.99, F1-score 0.99, dan ROC-AUC 0.99.
Perbedaan dengan Penelitian Ini	Penelitian berfokus pada model klasifikasi sederhana (Naïve Bayes) dan dataset UMKM layanan desain, bukan data spasial-temporal seperti pada <i>churn</i> asuransi. Tidak menggunakan ConvLSTM, Attention, maupun optimasi GWO.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Persamaan dengan Penelitian Ini	Sama-sama bertujuan memprediksi <i>churn</i> pelanggan serta menggunakan tahapan <i>preprocessing</i> dan evaluasi metrik seperti precision, recall, F1-score, dan ROC-AUC.
----------------------------------------	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------

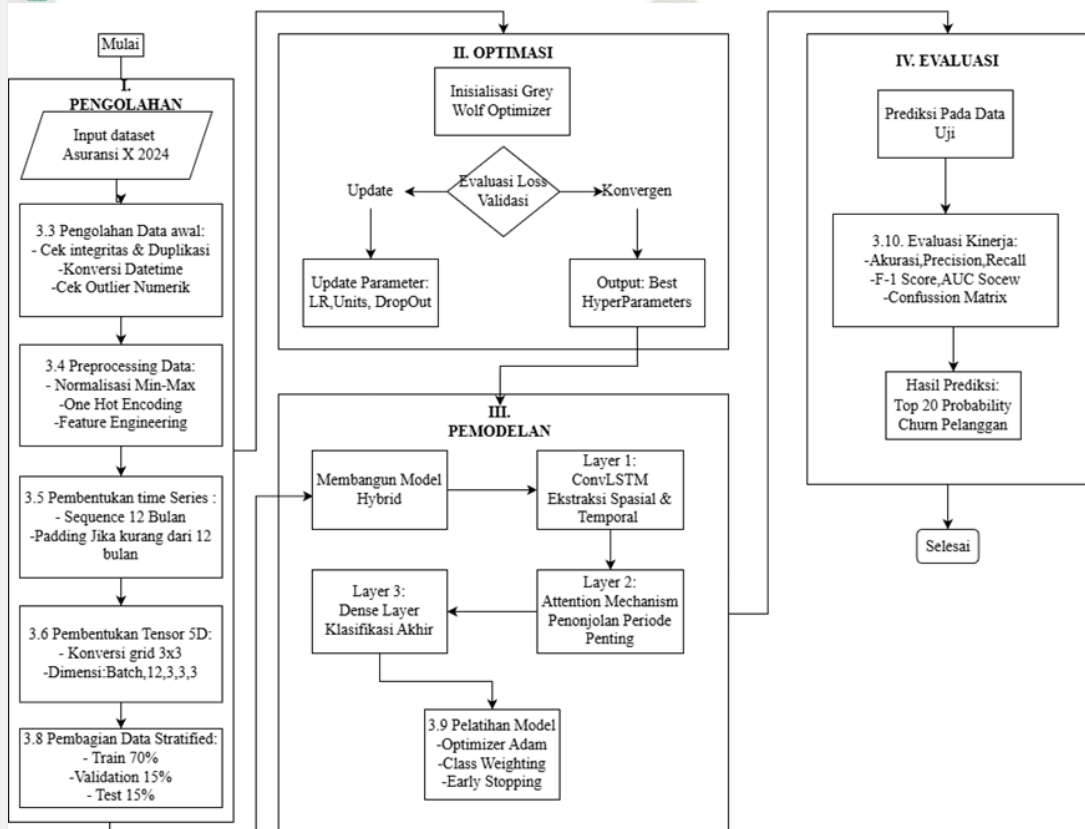
Tabel 2.3. Penelitian Terdahulu 3

Nama Peneliti	Mohammad Fajar Sidiq dan Dwi Mardika
Judul Penelitian	Prediksi <i>Customer Churn</i> Menggunakan Algoritma Decision Tree
Metode Penelitian	Pendekatan data mining menggunakan algoritma Decision Tree untuk klasifikasi <i>churn</i> . Dataset pelanggan dianalisis melalui tahapan <i>preprocessing</i> dan pelatihan model.
Hasil Penelitian	Model berhasil melakukan klasifikasi <i>churn</i> dengan tingkat akurasi yang memenuhi kriteria evaluasi, ditunjukkan melalui <i>confusion matrix</i> dan perbandingan metrik performa.
Perbedaan dengan Penelitian Ini	Penelitian hanya menggunakan satu algoritma (Decision Tree), tidak menangani data sekuens bulanan seperti pada ConvLSTM, serta tidak melibatkan optimasi hiperparameter maupun mekanisme <i>attention</i> .
Persamaan dengan Penelitian Ini	Sama-sama memprediksi <i>churn</i> pelanggan dan menggunakan dataset pelanggan sebagai dasar analisis.

BAB 3

METODOLOGI PENELITIAN

Metodologi Penelitian merupakan cara, langkah atau proses ilmiah yang disusun secara teratur untuk mencapai tujuan penelitian yang diinginkan dan informasi yang bermanfaat. Metode penelitian ini dimulai dari tahap perencanaan, tahap pengumpulan data, tahap pengolahan data dan tahap evaluasi dapat dilihat pada Gambar 3.1 berikut



Gambar 3.1. Metodologi Penelitian

3.1 Desain Penelitian

Desain penelitian ini disusun untuk membangun model prediksi churn pelanggan asuransi menggunakan pendekatan hybrid deep learning yang menggabungkan GWO, Attention Mechanism, dan ConvLSTM. Alur penelitian dimulai dari pengumpulan data pelanggan dalam format panel bulanan, dilanjutkan proses preprocessing untuk memastikan kualitas dan konsistensi data, pembentukan urutan waktu (*sequence*) selama 12 bulan, serta konversi data menjadi tensor 5D sebagai input bagi arsitektur ConvLSTM.

Model kemudian dioptimalkan menggunakan GWO untuk mendapatkan hiperparameter terbaik sebelum dilakukan pelatihan penuh. Tahap selanjutnya melibatkan mekanisme attention untuk menonjolkan periode waktu yang paling berpengaruh terhadap risiko *churn*. Pada akhir proses, kinerja prediktif model dievaluasi menggunakan metrik seperti akurasi, AUC, dan *confusion matrix*. Desain penelitian ini memastikan model mampu menangkap pola temporal perilaku pelanggan secara efektif.

3.2 Dataset Dan Sumber Data

Dataset yang digunakan dalam penelitian ini merupakan data panel pelanggan Perusahaan Asuransi X tahun 2024 yang berisi catatan aktivitas bulanan setiap nasabah. Data disusun dalam bentuk customer-month panel, di mana satu pelanggan dapat memiliki hingga 12 baris yang merepresentasikan perilaku mereka selama satu tahun periode observasi. Dataset ini memuat total 14.916 baris dengan 1.243 pelanggan unik, dan dikumpulkan dari sistem operasional perusahaan asuransi yang menjadi objek penelitian.

Setiap entri data menggambarkan kondisi pelanggan pada bulan tertentu, meliputi variabel terkait pembayaran premi, tunggakan, klaim, *complain*, jenis produk, metode pembayaran, frekuensi premi, dan atribut polis lainnya. Selain itu, dataset ini juga terdapat kolom target *churn* yang menunjukkan apakah pelanggan berhenti pada akhir kontrak.

Dataset ini tidak memiliki nilai kosong kritis sehingga dapat langsung diproses, ketidakseimbangan distribusi label churn ditemukan secara alami, di mana sebagian besar pelanggan berstatus non-churn. Ketidakseimbangan ini tetap dipertahankan sebagai bentuk representasi kondisi nyata pada operasional bisnis asuransi. Dataset ini menjadi sumber utama untuk seluruh proses preprocessing, pembentukan sequence, dan pelatihan model yang dijelaskan pada subbab sebelumnya.

3.3 Tahap Pengolahan Data

Tahap pengolahan data dilakukan untuk memastikan dataset berada dalam kondisi layak sebelum memasuki proses preprocessing yang lebih teknis. Langkah ini dimulai dengan pemeriksaan integritas data, meliputi pengecekan duplikasi, format penulisan tanggal, konsistensi tipe data, dan kelengkapan nilai pada setiap kolom. Variabel tanggal seperti *event_time* dan *policy_start_date* dikonversi menjadi tipe *datetime* agar dapat digunakan dalam perhitungan interval dan penyusunan urutan waktu yang akurat.

Selanjutnya dilakukan inspeksi terhadap variabel numerik seperti *pre-*



Hak Cipta Ditanggung Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

premium_amount, *arrears_amount*, *claims_amount*, *sum_assured*, dan *satisfaction_score* untuk memastikan tidak terdapat nilai ekstrem yang tidak logis atau rentang nilai yang tidak sesuai karakteristik bisnis. Variabel kategorik seperti *product_type*, *PLAN_CD*, dan *premium_freq* diperiksa untuk memastikan kategori konsisten, tidak ada salah ketik, dan semua kategori dapat dipetakan pada proses *encoding* selanjutnya.

Data kemudian dikelompokkan berdasarkan *customerID* untuk memastikan setiap pelanggan memiliki riwayat temporal yang lengkap serta urutan bulan yang sesuai. Pemeriksaan ini penting guna menghindari inkonsistensi panjang *sequence* antar pelanggan. Pada tahap ini juga dilakukan identifikasi ketidakseimbangan label *churn* yang akan ditangani pada tahap pemodelan.

Tahap pengolahan data ini menghasilkan dataset bersih dan terstruktur, yang kemudian siap diproses lebih lanjut pada tahap preprocessing untuk standarisasi dan pembentukan fitur sesuai kebutuhan model.

3.4 Preprocessing Data

Preprocessing dilakukan untuk mengubah data mentah menjadi format numerik yang konsisten dan siap digunakan oleh model berbasis *deep learning*. Tahap ini dimulai dengan normalisasi variabel numerik seperti *premium_amount*, *arrears_amount*, *claims_amount*, *sum_assured*, dan *satisfaction_score* menggunakan skala min-max agar seluruh nilai berada pada rentang yang seragam. Normalisasi diperlukan untuk menghindari dominasi variabel tertentu yang memiliki skala besar selama proses pelatihan model.

Variabel kategorik seperti *product_type*, *PLAN_CD*, *premium_freq*, dan *CHANNEL* dikonversi menjadi bentuk numerik melalui metode *one-hot encoding* sehingga setiap kategori direpresentasikan sebagai kolom biner. Tahap berikutnya adalah rekayasa fitur (*feature engineering*) untuk memperkaya informasi temporal dan perilaku pelanggan, antara lain perhitungan *arrears_ratio* untuk mengukur proporsi tunggakan, *delta_claims* untuk menangkap perubahan jumlah klaim antar-bulan, serta *policy_age* yang dihitung berdasarkan selisih antara tanggal mulai polis dan waktu observasi.

Seluruh kolom kemudian diperiksa kembali untuk memastikan tidak terdapat nilai hilang setelah proses transformasi. Dataset juga disusun ulang berdasarkan urutan bulan sehingga setiap pelanggan memiliki alur data kronologis yang konsisten. Hasil akhir preprocessing berupa data numerik yang telah dinormalisasi, *ter-encode*, dan diperkaya dengan fitur tambahan, sehingga siap dikonversi menjadi

urutan waktu pada tahap berikutnya.

3.5 Pembentukan Data Time Series (Windowing)

Pembentukan data *time-series* dilakukan untuk mengubah data panel pelanggan menjadi urutan waktu yang dapat diproses oleh model berbasis *sequence* seperti ConvLSTM. Proses ini dimulai dengan mengelompokkan data berdasarkan *customerID* dan mengurutkannya menurut *event_time*, sehingga setiap pelanggan memiliki riwayat perilaku yang konsisten secara kronologis. Setelah itu, setiap kelompok pelanggan dibentuk menjadi jendela waktu (*window*) tetap sepanjang 12 bulan, sesuai dengan periode observasi yang digunakan dalam penelitian.

Apabila seorang pelanggan memiliki kurang dari 12 bulan riwayat data, jendela waktu dilengkapi menggunakan pendekatan *padding* dengan nilai nol agar panjang *sequence* tetap konsisten. Sebaliknya, apabila seorang pelanggan memiliki lebih dari 12 bulan riwayat, hanya 12 bulan terakhir yang digunakan agar panjang *sequence* tetap seragam. Pendekatan ini memastikan bahwa seluruh pelanggan memiliki struktur *time-series* yang identik, sehingga dapat diproses secara paralel pada tahap pemodelan.

Windowing ini menjadi fondasi penting dalam menangkap pola temporal perilaku pelanggan, karena setiap pelanggan direpresentasikan dalam rangkaian data berurutan yang siap untuk dikonversi menjadi bentuk tensor pada tahap selanjutnya.

3.6 Pembentukan Tensor 5D

Pembentukan tensor 5D dilakukan untuk menyiapkan data *time-series* agar kompatibel dengan arsitektur ConvLSTM, yang membutuhkan input dalam format spasial dan temporal secara bersamaan. Setelah setiap pelanggan memiliki urutan waktu sepanjang 12 bulan, setiap *time-step* direpresentasikan dalam bentuk grid berukuran 3×3 yang berisi pengelompokan fitur ke dalam tiga *channel* berbeda. Pembagian ini dilakukan dengan cara mengelompokkan fitur-fitur yang memiliki karakteristik serupa—misalnya fitur pembayaran, klaim, komplain, dan karakteristik polis—ke dalam struktur spasial yang merepresentasikan hubungan antarvariabel secara lebih terorganisir.

Setelah fitur dikonversi ke dalam bentuk grid, seluruh *sequence* pelanggan disusun menjadi tensor dengan format (*batch_size*, 12, 3, 3, 3) yang merepresentasikan jumlah pelanggan, panjang urutan waktu, tinggi grid, lebar grid, dan jumlah *channel*. Struktur tensor ini memungkinkan ConvLSTM mengekstraksi pola spasial di dalam setiap *time-step* sekaligus mempelajari dinamika temporalnya dari bulan

ke bulan. Pembentukan tensor 5D ini merupakan tahap akhir dari persiapan data sebelum masuk ke tahap pemodelan.

3.7 Arsitektur Model

Arsitektur model yang digunakan dalam penelitian ini dirancang untuk mempelajari pola temporal dan spasial perilaku pelanggan secara bersamaan melalui kombinasi metode Grey Wolf Optimizer (GWO), Convolutional LSTM (ConvLSTM), dan Attention Mechanism. Setiap komponen memiliki peran spesifik untuk menangkap karakteristik perilaku pelanggan dari data panel bulanan hingga menghasilkan prediksi churn yang akurat.

3.7.1 Grey Wolf Optimizer (GWO)

GWO digunakan untuk melakukan optimasi *hyperparameter* sebelum model dilatih secara penuh. Algoritma ini meniru perilaku sosial kawanan serigala abu-abu, di mana sejumlah kandidat solusi (serigala) mengevaluasi parameter seperti *learning rate*, jumlah unit ConvLSTM, *dropout*, dan ukuran *batch* berdasarkan nilai *loss* pada tahap validasi. Proses iteratif ini menghasilkan konfigurasi *hyperparameter* yang stabil dan efektif sehingga performa pelatihan model meningkat seperti Gambar B.1 Gambar B.2.

3.7.2 Convolutional LSTM (ConvLSTM)

ConvLSTM digunakan sebagai komponen inti untuk mengekstraksi pola temporal dan spasial dari *sequence* data berukuran 12 bulan. Dengan memproses tensor 5D berformat (*batch, time, height, width, channel*), ConvLSTM dapat memahami perubahan nilai fitur pada tiap bulan sekaligus memodelkan hubungan antarfitur dalam representasi grid berukuran 3×3 . Lapisan ini menghasilkan rangkaian *feature map* berdimensi tetap yang menggambarkan dinamika risiko churn pada berbagai periode waktu.

3.7.3 Attention Mechanism

Attention Mechanism diterapkan setelah ConvLSTM untuk menonjolkan periode waktu yang paling berpengaruh terhadap keputusan churn. Mekanisme ini menghitung bobot kepentingan pada setiap *time-step* dari keluaran ConvLSTM, kemudian menggabungkan representasi temporal tersebut menjadi satu *context vector* yang lebih informatif. Pendekatan ini memungkinkan model untuk lebih fokus pada bulan-bulan yang mengandung perubahan perilaku signifikan, seperti peningkatan tunggakan, klaim bernilai besar, atau penurunan skor kepuasan pelanggan.



3.7.4 Fully Connected Layer

Vektor konteks yang dihasilkan oleh Attention Mechanism diteruskan ke lapisan *Dense* sebagai tahap akhir proses pemodelan. Lapisan ini berfungsi mengonversi representasi fitur menjadi output probabilistik melalui fungsi aktivasi sigmoid, yang kemudian ditetapkan sebagai prediksi churn. Untuk meningkatkan stabilitas pelatihan dan mencegah terjadinya *overfitting*, digunakan *batch normalization* dan *dropout* pada lapisan sebelumnya sesuai dengan konfigurasi hasil optimasi GWO.

3.8 Pembagian Data

Pembagian data dilakukan pada tingkat pelanggan (*customerID*) untuk memastikan bahwa seluruh riwayat 12 bulan setiap pelanggan hanya muncul pada satu subset data. Pendekatan ini mencegah kebocoran informasi antar subset dan menjaga konsistensi temporal. Proses pemisahan dilakukan menggunakan *stratified split* berdasarkan label *churn*, sehingga proporsi churn dan non-churn tetap seimbang pada data latih, validasi, dan uji.

Meskipun tidak menetapkan rasio tertentu secara eksplisit, hasil pembagian data menghasilkan komposisi yang secara alami mendekati 70% data latih dan masing-masing sekitar 15% untuk data validasi dan uji. Data hasil preprocessing kemudian disusun kembali dalam bentuk *sequence* sepanjang 12 bulan dan dikonversi menjadi tensor 5D sebelum digunakan pada proses pelatihan model.

Pembagian final data adalah sebagai berikut:

1. Data Latih: 870 pelanggan
2. Data Validasi: 186 pelanggan
3. Data Uji: 187 pelanggan

Pembagian ini memastikan bahwa model memperoleh cukup variasi pola perilaku pelanggan untuk proses pembelajaran, sekaligus menyediakan data validasi dan uji yang representatif untuk mengukur kinerja model secara objektif.

3.9 Pelatihan Model

Pelatihan model dilakukan dengan menggunakan arsitektur *hybrid* yang terdiri dari ConvLSTM sebagai ekstraktor fitur temporal-spasial, Attention Mechanism sebagai penimbang informasi pada setiap *time-step*, serta lapisan *Dense* sebagai pengambil keputusan akhir. Seluruh konfigurasi *hyperparameter* yang digunakan pada tahap pelatihan merupakan hasil optimasi dari Grey Wolf Optimizer (GWO), sehingga proses pembelajaran berlangsung dengan parameter yang telah disesuaikan untuk meningkatkan stabilitas dan akurasi model.



Model dilatih menggunakan data latih dalam bentuk tensor 5D dengan panjang *sequence* 12 bulan. Fungsi aktivasi sigmoid digunakan pada lapisan output untuk menghasilkan probabilitas churn. Untuk menangani ketidakseimbangan label antara pelanggan churn dan non-churn, diterapkan *class weighting* yang memberikan bobot lebih besar pada kelas minoritas agar model tidak bias terhadap kelas mayoritas. Selama proses pelatihan, digunakan *early stopping* dengan pemantauan nilai *loss* pada data validasi untuk menghentikan pelatihan ketika model tidak lagi menunjukkan peningkatan, sehingga risiko *overfitting* dapat diminimalkan.

Optimasi dilakukan menggunakan algoritma Adam dengan *learning rate* hasil rekomendasi GWO, diikuti dengan penerapan *batch normalization* dan *dropout* pada beberapa lapisan untuk menjaga stabilitas gradien. Pelatihan berlangsung dalam beberapa *epoch*, dan parameter model yang memberikan kinerja terbaik pada data validasi disimpan melalui mekanisme *model checkpoint*. Proses ini menghasilkan model final yang siap dievaluasi menggunakan data uji pada tahap selanjutnya.

3.10 Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja model dalam memprediksi churn pelanggan menggunakan data uji (*test set*) yang tidak dilibatkan selama proses pelatihan. Tahap ini bertujuan untuk memastikan bahwa model yang dibangun mampu melakukan generalisasi dengan baik pada data baru yang merepresentasikan kondisi operasional sebenarnya.

Untuk memberikan penilaian yang komprehensif, digunakan beberapa metrik evaluasi, yaitu akurasi, *precision*, *recall*, F1-score, dan Area Under the Curve (AUC). Penggunaan berbagai metrik diperlukan karena penelitian ini menerapkan pendekatan *class balance* melalui pemberian bobot kelas (*class weighting*) pada proses pelatihan model. Oleh karena itu, metrik yang menekankan kemampuan model dalam mengenali pelanggan churn, seperti *recall* dan F1-score, menjadi fokus utama selain akurasi.

Selain metrik numerik, *confusion matrix* digunakan untuk menggambarkan distribusi hasil prediksi model secara lebih rinci antara kelas churn dan non-churn. Melalui *confusion matrix*, dapat dianalisis jenis kesalahan prediksi yang terjadi, seperti *false positive* dan *false negative*, yang memiliki implikasi langsung terhadap pengambilan keputusan dalam sistem Customer Relationship Management (CRM).

Selanjutnya, kurva ROC (*Receiver Operating Characteristic*) digunakan untuk mengevaluasi kemampuan model dalam membedakan pelanggan churn dan



non-churn pada berbagai nilai ambang keputusan (*threshold*). Nilai AUC digunakan sebagai indikator kinerja global model karena mencerminkan kemampuan pemisahan kelas secara keseluruhan tanpa bergantung pada satu nilai ambang tertentu.

Hasil evaluasi pada tahap ini menjadi dasar analisis kinerja model hybrid GWO–ConvLSTM–Attention yang dibahas lebih lanjut pada Bab IV. Evaluasi yang dilakukan memastikan bahwa model tidak hanya memiliki performa prediksi yang baik, tetapi juga menghasilkan informasi yang andal untuk mendukung pengambilan keputusan berbasis sistem informasi.



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 5

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil evaluasi dan pengujian yang telah dilakukan, dapat disimpulkan bahwa penggunaan model GWO–Attention–ConvLSTM mampu memberikan kinerja yang baik dalam memprediksi kehilangan pelanggan menggunakan data historis bulanan. Model ini efektif dalam menangkap pola temporal dan perilaku pelanggan, sehingga menghasilkan prediksi yang relatif tepat dan konsisten.

Dari sudut pandang sistem informasi, penelitian ini menghasilkan suatu mekanisme analisis yang dapat diintegrasikan dengan sistem Customer Relationship Management (CRM) sebagai sumber informasi strategis. Informasi risiko kehilangan pelanggan yang dihasilkan tidak hanya berfungsi sebagai keluaran teknis model, tetapi juga dapat dimanfaatkan sebagai dasar pengambilan keputusan manajerial, khususnya dalam perencanaan dan pelaksanaan strategi retensi pelanggan.

Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan model prediksi kehilangan pelanggan, tetapi juga memberikan manfaat praktis bagi sistem informasi perusahaan dalam meningkatkan kualitas pengelolaan hubungan pelanggan serta efektivitas pengambilan keputusan berbasis data.

5.2 Saran

Penelitian selanjutnya disarankan untuk menggunakan periode data yang lebih panjang atau lintas tahun agar model dapat mempelajari perubahan pola perilaku pelanggan secara lebih stabil. Selain itu, pengujian pada data dari perusahaan atau sektor asuransi yang berbeda dapat dilakukan untuk menguji kemampuan generalisasi model GWO–Attention–ConvLSTM dalam konteks yang lebih luas.

Hasil prediksi berupa skor risiko churn yang dihasilkan model juga dapat dikembangkan lebih lanjut sebagai bagian dari sistem pendukung keputusan dalam sistem informasi perusahaan. Pengembangan ini memungkinkan identifikasi pelanggan berisiko tinggi dilakukan secara lebih dini dan terstruktur, serta membuka peluang penelitian lanjutan terkait interpretabilitas model guna memperjelas peran variabel-variabel utama dalam memengaruhi risiko churn.

UIN SUSKA RIAU

DAFTAR PUSTAKA

- Abdurohim, Koni, A., Munawir, Hidayatullah, Wijayanto, G., Listiyana, ... Yulianti, M. L. (2022). *Customer relationship management: Strategi pengembangan pelanggan* (1st ed., Vol. 1). Indonesia: Eureka Media Ak-sara. Retrieved from <https://repository.penerbiteureka.com/publications/559324/customer-relationship-management-strategi-pengembangan-pelanggan>
- Al-Kharabsheh, A. (2024). The effect of customer relationship management on customer satisfaction performance in the hotel industry in Jordan. *Innovative Marketing*, 20(4), 134.
- Bhuria, R., Gupta, S., Kaur, U., Bharany, S., Rehman, A. U., Hussien, S., ... Jangir, P. (2025). Ensemble-based customer churn prediction in banking: a vot-ing classifier approach for improved client retention using demographic and behavioral data. *Discover Sustainability*, 6(1), 28.
- De Bock, K. W., Coussement, K., De Caigny, A., Słowiński, R., Baesens, B., Boute, R. N., ... others (2024). Explainable ai for operational research: A defining framework, methods, applications, and a research agenda. *European Journal of Operational Research*, 317(2), 249–272. doi: 10.1016/j.ejor.2023.09.026
- Dehghani, A., Moazam, H. M. Z. H., Mortazavizadeh, F., Ranjbar, V., Mirzaei, M., Mortezaei, S., ... Dehghani, A. (2023). Comparative evaluation of lstm, cnn, and convlstm for hourly short-term streamflow forecasting using deep learning approaches. *Ecological Informatics*, 75, 102119.
- de Santana Correia, A., dan Colombini, E. L. (2022). Attention, please! a survey of neural attention models in deep learning. *Artificial Intelligence Review*, 55(8), 6037–6124.
- Ermania, A., Elsyah, R. D., dan Tuori, M. A. (2021). Transformation of crm activities into e-crm: The generating e-loyalty and open innovation. *Journal of Open Innovation: Technology, Market, and Complexity*, 7(2), 109.
- Gattermann-Itschert, T., dan Thonemann, U. W. (2022). Proactive customer reten-tion management in a non-contractual b2b setting based on churn prediction with random forests. *Industrial Marketing Management*, 107, 134–147. doi: 10.1016/j.indmarman.2022.09.023
- Ge, H., Li, S., Cheng, R., dan Chen, Z. (2022). Self-attention convlstm for spa-tiotemporal forecasting of short-term online car-hailing demand. *Sustainabil-ity*, 14(12), 7371.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Hason Rudd, D., Huo, H., dan Xu, G. (2022). Causal analysis of customer churn using deep learning. Dalam *2021 international conference on digital society and intelligent systems (dsins)*.
- Ivens, B., Kasper-Brauer, K., Leischnig, A., dan Thornton, S. C. (2024). Implementing customer relationship management successfully: A configurational perspective. *Technological Forecasting and Social Change*, 199, 123083.
- Khan, R. U., Salamzadeh, Y., Iqbal, Q., dan Yang, S. (2022). The impact of customer relationship management and company reputation on customer loyalty: The mediating role of customer satisfaction. *Journal of Relationship Marketing*, 21(1), 1–26.
- Khoh, W. H., Pang, Y. H., Ooi, S. Y., Wang, L.-Y.-K., dan Poh, Q. W. (2023). Predictive churn modeling for sustainable business in the telecommunication industry: optimized weighted ensemble machine learning. *Sustainability*, 15(11), 8631.
- Lages, C. R., Perez-Vega, R., Kadić-Maglajlić, S., dan Borghei-Razavi, N. (2023). A systematic review and bibliometric analysis of the dark side of customer behavior: An integrative customer incivility framework. *Journal of Business Research*, 161, 113779. doi: 10.1016/j.jbusres.2023.113779
- Lalwani, P., Mishra, M. K., Chadha, J. S., dan Sethi, P. (2022). Customer churn prediction system: a machine learning approach. *Computing*, 104(2), 271–294.
- Makhadmeh, S. N., Al-Betar, M. A., Doush, I. A., Awadallah, M. A., Kassaymeh, S., Mirjalili, S., dan Zitar, R. A. (2023). Recent advances in grey wolf optimizer, its versions and applications. *Ieee Access*, 12, 22991–23028.
- Manzoor, A., Qureshi, M. A., Kidney, E., dan Longo, L. (2024). A review on machine learning methods for customer churn prediction and recommendations for business practitioners. *IEEE access*, 12, 70434–70463.
- Meidani, K., Hemmasian, A., Mirjalili, S., dan Barati Farimani, A. (2022). Adaptive grey wolf optimizer. *Neural Computing and Applications*, 34(10), 7711–7731.
- Mena, J., Hidalgo, C., Estay-Olea, D., Sallaberry-Pincheira, N., Bacigalupo, A., Rubio, A. V., ... others (2023). Molecular surveillance of potential sars-cov-2 reservoir hosts in wildlife rehabilitation centers. *Veterinary Quarterly*, 43(1), 1–10.
- Ngai, E. W. T., dan Wu, Y. (2022). Machine learning in marketing: A literature review, conceptual framework, and research agenda. *Journal of Business*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Pascalău, S.-V., Popescu, F.-A., Bîrlădeanu, G.-L., dan Gigauri, I. (2024). The effects of a digital marketing orientation on business performance. *Sustainability*, 16(15), 6685.
- Perez-Vega, R., Hopkinson, P., Singhal, A., dan Mariani, M. M. (2022). From crm to social crm: A bibliometric review and research agenda for consumer research. *Journal of Business Research*, 151, 1–16.
- Saha, L., Tripathy, H. K., Gaber, T., El-Gohary, H., dan El-kenawy, E.-S. M. (2023). Deep churn prediction method for telecommunication industry. *Sustainability*, 15(5), 4543.
- Saha, S., Saha, C., Haque, M. M., Alam, M. G. R., dan Talukder, A. (2024). Churn-net: Deep learning enhanced customer churn prediction in telecommunication industry. *IEEE access*, 12, 4471–4484.
- Shi, B., Ge, C., Lin, H., Xu, Y., Tan, Q., Peng, Y., dan He, H. (2024). Sea surface temperature prediction using convlstm-based model with deformable attention. *Remote Sensing*, 16(22), 4126.
- Shidik, G. F., Pramunendar, R. A., Purwanto, P., Hasibuan, Z. A., Dolphina, E., Kusumawati, Y., dan Sriwinarsih, N. A. (2024). Optimizing parameters for earthquake prediction using bi-lstm and grey wolf optimization on seismic data. *Journal of Robotics and Control (JRC)*, 5(4), 1117–1127.
- Wang, C., Rao, C., Hu, F., Xiao, X., dan Goh, M. (2024). Risk assessment of customer churn in telco using fclcn-lstm model. *Expert Systems with Applications*, 248, 123352.
- Yadav, S. K., Tiwari, K., Pandey, H. M., dan Akbar, S. A. (2022). Skeleton-based human activity recognition using convlstm and guided feature learning. *Soft Computing*, 26(2), 877–890.
- Yang, C., Xia, G., Zheng, L., Zhang, X., dan Yu, C. (2025). Customer churn prediction based on coordinate attention mechanism with cnn-bilstm. *Electronics*, 14(10), 1916.
- Zhang, H., dan Zhang, W. (2024). Application of gwo-attention-convlstm model in customer churn prediction and satisfaction analysis in customer relationship management. *Heliyon*, 10(17).
- Zhu, B., Pan, X., vanden Broucke, S., dan Xiao, J. (2022). A gan-based hybrid sampling method for imbalanced customer classification. *Information Sciences*, 609, 1397–1411.



LAMPIRAN A

DATA TRANSAKSI

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

	B	C	D	E	F	G	H	I	J	K	L	M	N
1	event_time	tenure_month	premium_amount	arrears_amount	paid_flag	days_past_due	claims_count	claims_amount	big_claim	complaints_count	complaints_priority_high	escalated_any	product_type
2	05/01/2024	0	644020	0	1	3	0	0	0	0	0	0	0 TERM_LIFE
3	05/02/2024	1	698925	0	1	0	1	183650000	0	0	0	0	0 TERM_LIFE
4	05/03/2024	2	590638	0	1	0	0	0	0	0	0	0	0 TERM_LIFE
5	05/04/2024	3	650651	0	1	0	0	0	0	0	0	0	0 TERM_LIFE
6	05/05/2024	4	647994	647994	0	30	0	0	0	0	0	0	0 TERM_LIFE
7	05/06/2024	5	633628	0	1	0	0	0	0	0	0	0	0 TERM_LIFE
8	05/07/2024	6	665632	0	1	5	0	0	0	0	0	0	0 TERM_LIFE
9	05/08/2024	7	703903	0	1	3	1	283200000	0	0	0	0	0 TERM_LIFE
10	05/09/2024	8	723861	0	1	4	0	0	0	0	0	0	0 TERM_LIFE
11	07/10/2024	9	673664	0	1	0	0	0	0	0	0	0	0 TERM_LIFE
12	05/11/2024	10	641912	0	1	2	0	0	0	0	0	0	0 TERM_LIFE
13	05/12/2024	11	708631	0	1	2	1	186300000	0	0	0	0	0 TERM_LIFE
14	05/01/2024	-1	0	0	0	0	0	0	0	0	0	0	0 UNIT_LINK
15	05/02/2024	-1	0	0	0	0	0	0	0	0	0	0	0 UNIT_LINK
16	05/03/2024	0	1144780	0	1	2	0	0	0	0	0	0	0 UNIT_LINK
17	05/04/2024	1	1281426	0	1	0	0	0	0	0	0	0	0 UNIT_LINK
18	06/05/2024	2	1150619	0	1	1	0	0	0	0	0	0	0 UNIT_LINK
19	05/06/2024	3	1120000	0	1	0	0	0	0	0	0	0	0 UNIT_LINK
20	05/07/2024	4	1173054	0	1	2	0	0	0	0	0	0	0 UNIT_LINK
21	05/08/2024	5	1071173	0	1	3	0	0	0	0	0	0	0 UNIT_LINK
22	05/09/2024	6	1060655	0	1	1	0	0	0	0	0	0	0 UNIT_LINK
23	07/10/2024	7	1179180	0	1	0	0	0	0	0	0	0	0 UNIT_LINK
24	05/11/2024	8	1128223	0	1	0	0	0	0	0	0	0	0 UNIT_LINK
25	05/12/2024	9	1163450	0	1	0	0	0	0	0	0	0	0 UNIT_LINK
26	05/01/2024	-1	0	0	0	0	0	0	0	0	0	0	0 TERM_LIFE
27	05/02/2024	-1	0	0	0	0	0	0	0	0	0	0	0 TERM_LIFE
28	05/03/2024	-1	0	0	0	0	0	0	0	0	0	0	0 TERM_LIFE
29	05/04/2024	-1	0	0	0	0	0	0	0	0	0	0	0 TERM_LIFE
30	06/05/2024	0	1017192	0	1	1	0	0	0	0	0	0	0 TERM_LIFE
31	05/06/2024	1	1331360	0	1	2	0	0	0	0	0	0	0 TERM_LIFE

Gambar A.1. Data Transaksi 12 Bulan

	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC
1	PLAN_CD	sum_assured	premium_freq	CHANNEL	RIDER_CNT	offer_flag	offers_sent	offers_accepted	upseil_any	paperless_flag	auto_debit_flag	churn	satisfaction_score	policy_start_date	arrears_ratio
2	TL-B	254950000	Monthly	Bancassurance	0	1	1	0	0	1	1	0.44	05/01/2024	0.0	
3	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.48	05/01/2024	0.0	
4	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/01/2024	0.0	
5	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/01/2024	0.0	
6	TL-B	254950000	Monthly	Bancassurance	0	1	1	0	0	1	0	0.45	05/01/2024	1.0	
7	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.45	05/01/2024	0.0	
8	TL-B	254950000	Monthly	Bancassurance	0	1	1	0	1	1	1	0.45	05/01/2024	0.0	
9	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.45	05/01/2024	0.0	
10	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/01/2024	0.0	
11	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.48	05/01/2024	0.0	
12	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/01/2024	0.0	
13	TL-B	254950000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.44	05/01/2024	0.0	
14	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.46	05/03/2024	0.0	
15	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.46	05/03/2024	0.0	
16	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.48	05/03/2024	0.0	
17	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/03/2024	0.0	
18	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.45	05/03/2024	0.0	
19	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/03/2024	0.0	
20	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.47	05/03/2024	0.0	
21	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.42	05/03/2024	0.0	
22	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.43	05/03/2024	0.0	
23	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.44	05/03/2024	0.0	
24	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	05/03/2024	0.0	
25	UL-Proteksi	100350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.44	05/03/2024	0.0	
26	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.46	06/05/2024	0.0	
27	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.46	06/05/2024	0.0	
28	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.46	06/05/2024	0.0	
29	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	0	0.46	06/05/2024	0.0	
30	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.44	06/05/2024	0.0	
31	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.47	06/05/2024	0.0	
32	TL-C	202350000	Monthly	Bancassurance	0	0	0	0	0	1	1	0.46	06/05/2024	0.0	

Gambar A.2. Data Transaksi 12 Bulan



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumpukan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LAMPIRAN B CODE PYTHON

Stage 8 – Grey Wolf Optimizer (GWO)

```
import math

HP_BOUNDS = {
    'filters_clstm': (16, 64),
    'filters_conv': (8, 32),
    'dense_units': (16, 64),
    'dropout_rate': (0.1, 0.5),
    'learning_rate': (1e-4, 5e-3),
}

HP_NAMES = list(HP_BOUNDS.keys())
DIM = len(HP_NAMES)
print('HP names:', HP_NAMES)

def decode_position(position):
    params = {}
    for i, name in enumerate(HP_NAMES):
        low, high = HP_BOUNDS[name]
        val = low + position[i] * (high - low)
        if name in ['filters_clstm', 'filters_conv', 'dense_units']:
            val = int(round(val / 8) * 8)
        else:
            val = float(val)
        params[name] = val
    return params

def evaluate_fitness(position, max_epochs=10):
    params = decode_position(position)
    model = build_convLSTM_attention_model(params)
    ...
```

Gambar B.1. Code Python Untuk Pengolahan Data Deep Learning

Stage 7 – ConvLSTM + Attention Model

```
from tensorflow.keras.layers import (
    Input, ConvLSTM2D, BatchNormalization, Dropout,
    TimeDistributed, Conv2D,
    GlobalAveragePooling2D, GlobalAveragePooling1D,
    Dense,
)
from tensorflow.keras.models import Model
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint

T, H, W, C = Xtr_5d.shape[1:]
input_shape = (T, H, W, C)
print('Input shape:', input_shape)

def build_convLSTM_attention_model(params, input_shape=input_shape):
    filters_clstm = int(params['filters_clstm'])
    filters_conv = int(params['filters_conv'])
    dense_units = int(params['dense_units'])
    dropout_rate = float(params['dropout_rate'])
    lr = float(params['learning_rate'])

    inp = Input(shape=input_shape, name='input_5d')
    x = ConvLSTM2D(filters_clstm, (3,3), padding='same', return_sequences=True, activation='tanh')(inp)
    x = BatchNormalization()(x)
    x = Dropout(dropout_rate)(x)
    x = TimeDistributed(Conv2D(filters_conv, (3,3), padding='same', activation='relu'))(x)
    x = TimeDistributed(GlobalAveragePooling2D())(x)
    attn = tf.keras.layers.Attention(name='self_attention')([x, x])
    x = GlobalAveragePooling1D()(attn)
    x = Dense(dense_units, activation='relu')(x)
    ...
```

Gambar B.2. Code Python Untuk Pengolahan Data Deep Learning



DAFTAR RIWAYAT HIDUP



Pedro Masdy lahir di Pekanbaru pada tanggal 10 Desember 2003. Ia merupakan anak ketiga dari tiga bersaudara, putra dari Masdy Dahlan dan Desi Murni. Saat ini bertempat tinggal di Provinsi Riau. Penulis memulai pendidikan formal di TK Mayang dan lulus pada tahun 2010. Pendidikan dasar dilanjutkan di UPTD SD Negeri 01 Pangkalan dan diselesaikan pada tahun 2016. Selanjutnya, penulis melanjutkan pendidikan tingkat Sekolah Menengah Pertama di SMP Negeri 1 Payakumbuh dan lulus pada tahun 2019. Pendidikan Sekolah Menengah Atas ditempuh di SMA Negeri 1 Pangkalan Koto Baru dan diselesaikan pada tahun 2022. Pada jenjang pendidikan tinggi, penulis melanjutkan studi pada Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau. Sebagai syarat untuk memperoleh gelar Sarjana Komputer, penulis menyusun tugas akhir dengan judul “Prediksi Churn Pelanggan Dalam Customer Relationship Management Dengan Model Grey Wolf Optimizer–Attention–ConvLSTM.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

UIN SUSKA RIAU