

## BAB V HASIL DAN PEMBAHASAN

Pada bab ini mencantumkan penyajian hasil dari pengembangan sistem yang telah dilaksanakan oleh peneliti dan membahas terkait hal tersebut dalam dua cantuman sub bab yaitu hasil dan pembahasan.

### 5.1 Hasil

Aplikasi web yang dikembangkan untuk mengidentifikasi kelayakan produk asuransi dari laporan keuangan telah berhasil dikembangkan dengan menggunakan data laporan keuangan yang diperoleh dari perusahaan asuransi. Model LSTM yang dikembangkan berhasil mempelajari pola dari komponen nilai *Contract Service Margin* (CSM). CSM adalah salah satu metode konvensional yang digunakan perusahaan dalam menentukan kelayakan produk asuransi. Model *machine learning* berhasil mengidentifikasi kelayakan produk asuransi pada fase pelatihan dengan perolehan nilai RMSE dan MAE pada setiap produk (109, 121, 122, 211, 1004, 1006) berturut-urut yaitu RMSE (0.07), MAE (0.06), RMSE (0.17), MAE (0.13), RMSE (0.15), MAE (0.08), RMSE (0.24), MAE (0.22), RMSE (0.04), MAE (0.04), RMSE (0.10), MAE (0.08). Perolehan nilai-nilai akurasi tersebut dari hasil pembelajaran dengan perbandingan dataset pada ratio 80:10:10 yang terbagi menjadi tiga subset pelatihan, test, dan validasi. Hasilnya Nilai pengolahan data CSM secara konvensional dan *machine learning* berhasil memberikan hasil yang mempunyai akurasi baik. Kontribusi *machine learning* berhasil meleraikan permasalahan dalam hambatan pengolahan konvensional yaitu volume data, kompleksitas kebutuhan informasi, konsumsi waktu, dan konsumsi sumber daya teknologi.

#### 5.1.1 Hasil Perancangan

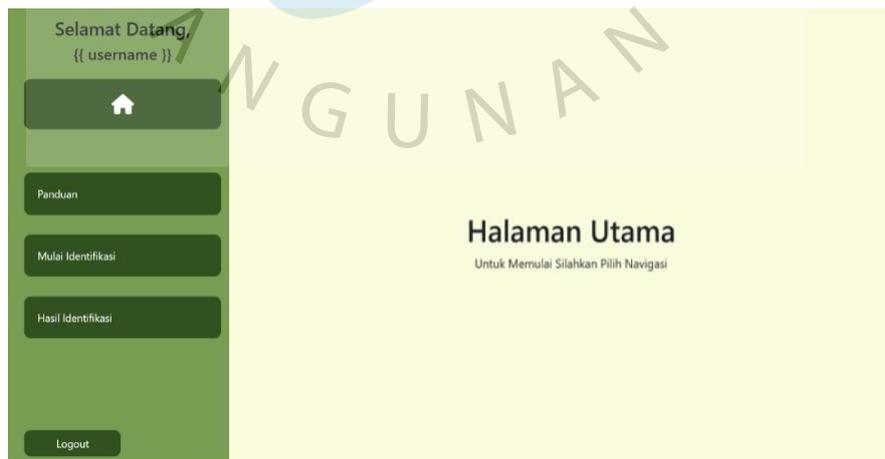
Perancangan antarmuka pengguna pada aplikasi web untuk memprediksi *loss ratio* dalam mengukur kelayakan produk asuransi. Perancangan antarmuka diadaptasi dari susunan sederhana aplikasi, sehingga pengguna dapat mudah memahami dan digunakan untuk menjalankan fungsi aplikasi. Berikut adalah hasil perancangan antarmuka pengguna. Gambar 5.1 adalah tampilan halaman login aplikasi, sistem akan membutuhkan pengguna untuk memasukkan *username dan*

*password* dari akun yang sudah terdaftar. Halaman login mempunyai sistem validasi pada *routing*. Ketika akses menuju halaman berikutnya, tanpa mempunyai token yang terdaftar pengguna tidak dapat menuju halaman tersebut dan dialihkan untuk login terlebih dahulu.



Gambar 5. 1 Login Page

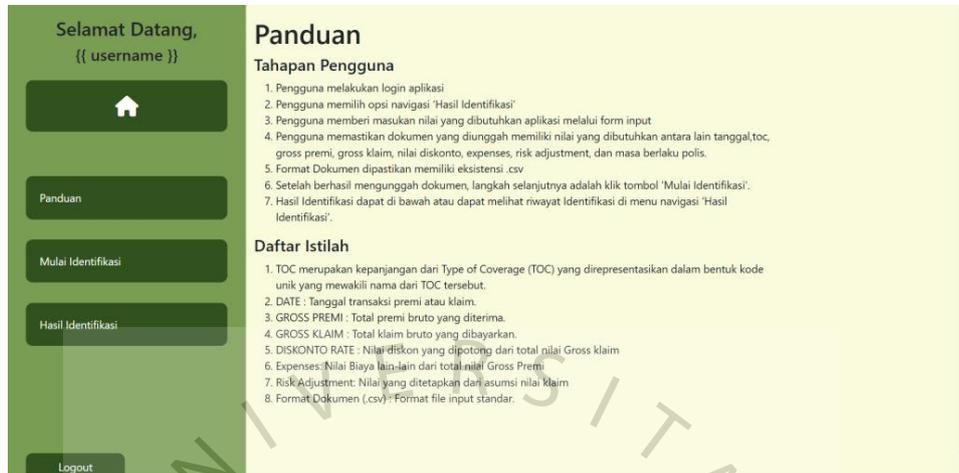
Gambar 5.2 merupakan halaman utama saat login dinyatakan telah berhasil. Halaman utama mempunyai menu navigasi untuk menjalankan fitur aplikasi yaitu *home* ditandai dengan simbol bergambar rumah, tata cara penggunaan, mulai prediksi, hasil prediksi, dan tombol untuk melakukan *logout*.



Gambar 5. 2 Halaman Utama

Gambar 5.3 menunjukkan halaman yang mencakup detail informasi panduan penggunaan aplikasi serta daftar istilah yang digunakan dalam aplikasi.

Tata cara penggunaan mencakup tahapan yang harus dilalui oleh pengguna sebelum melakukan fungsi utama aplikasi yaitu memulai proses identifikasi kelayakan produk asuransi.



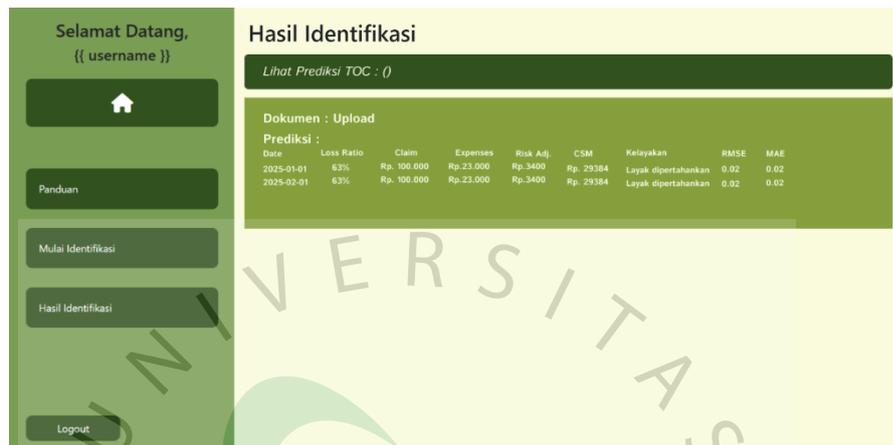
Gambar 5. 3 Halaman Panduan

Gambar 5. 4 menunjukkan halaman untuk memulai proses identifikasi kelayakan produk berdasarkan kode *type of coverage* (TOC) yang dipilih. Halaman ini menampilkan daftar TOC yang dapat dipilih oleh pengguna sesuai kebutuhan untuk memperoleh informasi kelayakan produk. Setelah memilih TOC, sistem membutuhkan unggahan dokumen dengan format dan ekstensi .csv dan berisikan data laporan keuangan. Setelah seluruh kebutuhan sistem terpenuhi, pengguna dapat menekan tombol ‘mulai identifikasi’ untuk memulai proses identifikasi. Hasil dapat dilihat melalui *log program* yang muncul di bawah tombol ‘mulai identifikasi’.



Gambar 5. 4 Halaman Mulai Identifikasi Kelayakan Produk

Gambar 5.5 menunjukkan halaman hasil identifikasi kelayakan produk asuransi dari TOC yang telah dipilih sebelumnya. Saat pengguna memilih TOC dan melihat detail prediksi, halaman ini menampilkan hasil prediksi pada setiap bulan, beserta hasil dari komponen penilaian *Contract Service Margin* (CSM) beserta nilai RMSE dan MAE untuk memastikan data yang terolah cukup akurat.



Gambar 5. 5 Halaman Hasil Identifikasi

### 5.1.2 Hasil Pengujian

Pengujian aplikasi dilaksanakan untuk meyakini bahwa proses implementasi model dan kode sumber tereksekusi sesuai dengan perancangan yang sudah dianalisa.

Tabel 5. 1 Hasil Pengujian RnD

Aspek	Deskripsi	Hasil
<b>Tujuan</b>	Mengembangkan Model <i>machine learning</i> yang mampu mengidentifikasi kelayakan produk asuransi.	Hasil pengujian menunjukkan bahwa model <i>machine learning</i> yang dikembangkan mampu mengidentifikasi kelayakan produk asuransi berdasarkan faktor nilai <i>Contract Service Margin</i> (CSM) dan nilai <i>loss ratio</i> dengan evaluasi menggunakan RMSE dan MAE, serta telah berhasil diimplementasikan dalam perangkat lunak yang memungkinkan prediksi kelayakan produk secara efisien melalui antarmuka pengguna berbasis web.
<b>Fokus</b>	Bagaimana parameter <i>loss ratio</i> , <i>disconto rate</i> , <i>expenses</i> , <i>risk adjustment</i> berpengaruh dalam menentukan nilai <i>Contract Service Margin</i> (CSM) sebagai indikator dalam mengidentifikasi kelayakan produk asuransi?.”	
<b>Langkah-Langkah</b>		
<b>Eksplorasi Konsep</b>	Meneliti dan mengetahui konsep manual yang telah digunakan perusahaan asuransi dalam menentukan kelayakan produk asuransi.	
<b>Pengujian Konsep</b>	Pengujian konsep disesuaikan dengan alur dan proses manual	

	perusahaan sebelum digunakan sebagai data pembelajaran menggunakan metode LSTM.	
<b>Evaluasi Konsep</b>	Membandingkan performa model yang dikembangkan dengan metode terdahulu.	
<b>Metrik Evaluasi</b>	Performa model dalam mengidentifikasi kelayakan produk asuransi diukur berdasarkan nilai RMSE dan MAE.	
<b>Contoh Aplikasi</b>	Pengembangan aplikasi berbasis website dengan mengintegrasikan model <i>machine learning</i> dalam mengidentifikasi kelayakan produk asuransi.	

Tabel 5. 2 Hasil Pengujian Prototyping

Aspek	Deskripsi	Hasil
<b>Tujuan</b>	Mengembangkan perangkat lunak yang mampu untuk mengidentifikasi kelayakan produk asuransi	Hasil pengujian menunjukkan bahwa perangkat lunak yang dikembangkan mampu mengidentifikasi kelayakan produk asuransi dengan memastikan kesesuaian antara kebutuhan pengguna dan hasil prediksi model, serta mengevaluasi waktu prediksi dan akurasi keluaran melalui antarmuka pengguna.
<b>Fokus</b>	Melihat kesesuaian antara kebutuhan pengguna dengan hasil pengembangan perangkat lunak.	
<b>Langkah-Langkah</b>		
<b>Pembuatan Prototipe</b>	Melakukan pelatihan model berdasarkan data laporan keuangan perusahaan.	
<b>Pengujian Fungsi</b>	Memberikan data input untuk melihat apakah model menghasilkan output yang sesuai ekspektasi.	
<b>Identifikasi Kelemahan</b>	Menganalisis kesalahan model atau kekurangan dalam model.	
<b>Metrik Evaluasi</b>	Waktu yang diperlukan untuk melakukan prediksi melalui <i>user interface</i> . Hasil akurasi luaran aplikasi.	
<b>Contoh Aplikasi</b>	Prediksi kelayakan produk asuransi menggunakan data <i>input</i> untuk menguji arsitektur model LSTM awal dengan <i>user interface</i> .	

Tabel 5. 3 Hasil Pengujian RMSE

No.	Ketentuan	Hasil Uji
1	Nilai RMSE model kurang dari batas toleransi (<1.0)	Sesuai/Tidak Sesuai/diperbaiki

Tabel 5. 4 Hasil Pengujian MAE

No.	Ketentuan	Hasil Uji
1	Nilai MAE model kurang dari batas toleransi (<1.0)	Sesuai/Tidak Sesuai/diperbaiki

## 5.2 Pembahasan

Hasil RMSE dan MAE pada Tabel 5.5 menunjukkan bahwa model yang digunakan memiliki performa yang baik dalam memprediksi nilai yang diharapkan. Nilai RMSE dan MAE yang relatif rendah di seluruh kategori TOC menunjukkan bahwa selisih antara hasil prediksi dan nilai aktual cukup kecil, menandakan tingkat akurasi yang tinggi. TOC 1004 memiliki performa terbaik dengan RMSE dan MAE sebesar 0.04, sedangkan TOC 211 memiliki nilai kesalahan tertinggi dengan RMSE 0.24 dan MAE 0.22. Secara keseluruhan, hasil ini mengindikasikan bahwa model mampu memberikan estimasi dengan baik dan dapat digunakan untuk mendukung informasi dalam mengidentifikasi kelayakan produk asuransi.

Tabel 5. 5 Hasil RMSE dan MAE

TOC	RMSE	MAE	Kesimpulan
109	0.07	0.06	<1.0
121	0.17	0.13	<1.0
122	0.15	0.08	<1.0
211	0.24	0.22	<1.0
1004	0.04	0.04	<1.0
1006	0.10	0.08	<1.0

Hasil perbandingan rasio dataset pada Tabel 5.6 menunjukkan bahwa variasi proporsi data latih, pengujian, dan validasi memberikan perbedaan kecil dalam performa model, dengan semua skenario tetap menunjukkan tingkat kesalahan yang rendah. Rasio 80:10:10 menghasilkan nilai RMSE dan MAE terendah, masing-masing 0.12 dan 0.10, yang menunjukkan bahwa model memiliki performa paling baik dengan proporsi data latih yang lebih besar. Sementara itu, rasio 60:20:20 dan 70:15:15 memiliki nilai RMSE yang sama, yaitu 0.15, dengan MAE yang sedikit lebih tinggi pada rasio 70:15:15. Hal ini mengindikasikan bahwa

penggunaan data latih yang lebih besar cenderung meningkatkan akurasi model, meskipun perbedaannya tidak terlalu signifikan.

Tabel 5. 6 Hasil Perbandingan Rasio Dataset

Perbandingan	Deskripsi	RMSE	MAE
60:20:20	Dalam proses pelatihan menggunakan 60% latih, 20% pengujian, 20% validasi.	0.15	0.11
70:15:15	Dalam proses pelatihan menggunakan 70% latih, 15% pengujian, 15% validasi.	0.15	0.12
80:10:10	Dalam proses pelatihan menggunakan 80% latih, 10% pengujian, 10% validasi.	0.12	0.10

Tabel 5.7 membandingkan dua metode, yaitu Metode Konveksional dan Metode Machine Learning, berdasarkan beberapa faktor kunci. Kedua metode mengolah data yang sama, yaitu nilai CSM dari tahun 2017 hingga 2023, namun terdapat perbedaan signifikan dalam hal konsumsi waktu dan sumber daya teknologi. Metode Konveksional menggunakan Microsoft Excel dan membutuhkan waktu antara 5 hingga 10 menit untuk memproses data, sementara Metode Machine Learning memanfaatkan Python Code dan Website Programming, yang memungkinkan pemrosesan data dalam waktu kurang dari satu menit. Selain itu, Metode Machine Learning cenderung lebih efisien dalam penggunaan waktu dan sumber daya teknologi dibandingkan dengan Metode Konveksional. Hal ini menunjukkan bahwa meskipun kedua metode mengolah informasi yang sama, metode berbasis machine learning menawarkan keuntungan dalam hal kecepatan dan efisiensi teknologi.

Tabel 5. 7 Hasil Perbandingan antar Metode

Deskripsi	Metode Konveksional	Metode Machine Learning
Volume data	2017-2023	2017-2023
Kompleksitas kebutuhan informasi	Mengolah nilai CSM	Mengolah Nilai CSM
Konsumsi waktu	5 Menit – 10 Menit	< 1 Menit
Konsumsi sumber daya teknologi	Microsoft Excel	Python Code dan Website Programming

Gambar 5.6. menunjukkan hasil perhitungan yang diterapkan secara metode konvensional menggunakan persamaan matematika dan sistem adalah sama. Penerapan metode konvensional dicontohkan pada baris tanggal 2019-10-23, kode TOC: 221 metode CSM konvensional digunakan untuk menghitung CSM yang dihasilkan sebesar Rp. 1,754,796.99, yang menunjukkan bahwa kontrak masih menguntungkan dan layak dipertahankan. Perhitungannya dimulai dari *Gross premi* sebesar Rp. 6,676,312, dikurangi dengan *gross claim* yang telah terjadi Rp, 3,976,535, *future claim* yang diperkirakan Rp. 3,698,177.55, *Expenses* Rp. 1,001,446.80, dan *Risk Adjustment* Rp. 221,890.65 untuk mengantisipasi ketidakpastian klaim. Hasil CSM yang positif menunjukkan profitabilitas kontrak. *Current Loss Ratio* 0.5956 menunjukkan bahwa 59.56% dari premi digunakan untuk membayar klaim, sementara *future loss ratio* 0.5539 menunjukkan bahwa klaim di masa depan diperkirakan akan menurun, yang mendukung kelayakan model dalam mengidentifikasi kelayakan produk asuransi.

Gambar 5. 6 Hasil Perhitungan Sistem

Date	Kode TOC	Gross Premi	Gross Claim	Future Claim	Expenses	Risk Adjustment	CSM	Status	Current Loss Ratio	Future Loss Ratio
23/10/2019	221	6676312	3976535	369817755	10014468000000000	221890653	17547969970000000	Eligible	5956185091409750	5539252135011070
28/02/2022	122	7781534	1315248	122318064	11672301000000000	733908384	53177324216000000	Eligible	16902168646953200	15719016841666400
06/01/2021	121	1952666	4546362	422811666	29289990000000000	2536869996	-28220375596000000	Not Eligible	23282845094860100	2165304593821980
23/07/2017	221	7863108	6396002	594828186	11794662	3568969116	37846302840000000	Eligible	8134190704235530	756479735493904
14/12/2017	121	3619909	3310711	307896123	54298635	1847376738	-18677625380000000	Not Eligible	9145840406485360	8505631578031380
07/12/2022	1004	936702	1704826	158548818	1405053	95129290800000000	-88442077080000000	Not Eligible	18200302764379700	16926281570873100
06/02/2023	122	3614167	930966	86579838	54212505000000000	51947902800000000	21542956672000000	Eligible	2575879863880110	2395568273408510
22/01/2018	1004	4137567	3443270	32022411	62063505000000000	192134466	12255638400000000	Eligible	8321967958464480	7739430201371970
09/08/2018	1004	9144465	2236199	207966507	137166975	1247799042	55683502758	Eligible	2445412607517220	2274233724991020

Tabel 5.9 menunjukkan bahwa hasil pelatihan model menghasilkan nilai yang baik pada setiap produk, yang terlihat dari perbandingan antara nilai aktual dan MAE (*Mean Absolute Error*). Hal ini mengindikasikan bahwa model yang dilatih mampu memberikan prediksi yang cukup akurat dengan selisih yang kecil antara nilai prediksi dan nilai aktual. Meskipun tabel ini tidak menyertakan angka spesifik, kesimpulannya adalah bahwa pelatihan model secara keseluruhan berhasil menghasilkan prediksi yang andal, mencerminkan akurasi yang memadai untuk penggunaan lebih lanjut dalam aplikasi praktis.

Tabel 5. 8 Hasil Pelatihan Model

Training dan Validasi	Perbandingan Nilai aktual dan MAE

