



# 6.35%

SIMILARITY OVERALL

SCANNED ON: 7 FEB 2025, 10:48 AM

## Similarity report

Your text is highlighted according to the matched content in the results above.

**IDENTICAL** 0.2%  
**CHANGED TEXT** 6.14%

## Report #24703505

1 BAB I PENDAHULUAN Bagian awal dalam penelitian ini akan menguraikan berbagai sudut pandang yang mendasari akar dari permasalahan yang diteliti. Pemaparan dari akar permasalahan mencakup identifikasi masalah, tujuan penelitian, manfaat penelitian, batasan masalah, aspek kebaruan, serta kerangka penulisan. 1.1 Latar Belakang Dalam bisnis asuransi, menilai kelayakan produk merupakan aspek penting yang harus dipertimbangkan. Pemegang keputusan perlu menentukan apakah suatu produk asuransi layak dilayani berdasarkan nilai loss ratio dan faktor-faktor tambahan, seperti discount rate, expense rate, dan risk adjustment. Nilai loss ratio dihitung dari selisih antara premi, yaitu nominal uang yang diterima perusahaan, dan klaim, yakni nominal uang yang dibayarkan kepada pemegang polis yang mengajukan klaim. Faktor-faktor tambahan ini digunakan untuk menilai Contract Service Margin (CSM) yang mencerminkan potensi keuntungan atau kerugian perusahaan. Semua data yang diperlukan, diperoleh dari laporan keuangan perusahaan. **12** Hal ini merupakan standar operasional umum dalam industri asuransi untuk menilai kelayakan produk sebelum mempertimbangkan faktor eksternal seperti regulasi Pernyataan Standar Akuntansi Keuangan (PSAK) 117 yang diadaptasi dari International Financial Reporting Standards (IFRS) 17. Penilaian kelayakan ini penting karena produk yang ditawarkan harus memiliki loss ratio yang diproyeksikan tidak melebihi 100% dan nilai CSM yang positif. **37** Oleh karena itu, diperlukan proses

identifikasi, analisis, dan prediksi untuk menentukan kelayakan produk asuransi. Namun, hingga saat ini, proses pengidentifikasian tersebut masih dilakukan dengan metode konvensional. Penerapan metode konvensional merupakan sebuah upaya dalam menjawab kebutuhan dalam mengidentifikasi kelayakan produk asuransi saat ini. Perolehan informasi didapatkan dari sumber daya yaitu aktuaria yang berperan untuk melakukan perhitungan dan analisis asumsi dari loss ratio di masa mendatang dalam memperoleh tren. Kebutuhan akan informasi tersebut digunakan saat pemegang keputusan menentukan atau menyesuaikan perolehan manfaat dan tarif premi dari produk asuransi yang dilayani oleh perusahaan. 2 Sehingga, pemegang keputusan juga mampu memberikan gagasan terkait kelayakan produk tersebut dalam proses perencanaan strategi, manajemen risiko, dan hal-hal lainnya. Penerapan metode konvensional masih digunakan lantaran kebutuhan akan sumber daya manusia sudah memadai. Namun terdapat beberapa hambatan diantaranya adalah volume data yang semakin besar, kompleksitas kebutuhan informasi, konsumsi waktu, dan konsumsi sumber daya teknologi yang tinggi. Meskipun demikian, metode konvensional masih mampu dalam mengolah dan menganalisis dengan keterbatasan yang sebelumnya disebutkan. Perangkat lunak yang digunakan yaitu, Microsoft Excel dan visualisasi hasil menggunakan Tableau dalam mengidentifikasi kelayakan produk asuransi. Menelaah fenomena yang terjadi pada metode konvensional dapat dileraikan menggunakan bantuan teknologi dalam membantu proses analisis untuk

mengidentifikasi kelayakan produk asuransi. Teknologi yang diterapkan adalah machine learning. Penerapan machine learning dapat mengolah data dengan volume yang cukup besar, menangani kompleksitas kebutuhan informasi, mempersingkat konsumsi waktu analisa, dan efisiensi sumber daya teknologi. Machine learning dapat diterapkan pada perusahaan asuransi untuk meleraikan hambatan pada metode konvensional, ketika perusahaan asuransi sudah mempunyai volume data yang cukup besar. Penerapan model machine learning bisa dilakukan untuk memperoleh informasi tambahan berupa prediksi, klasifikasi, identifikasi dari data yang diolah. Menurut (Alfat et al., 2022) data dapat diolah untuk mendapatkan informasi tambahan melalui analisis prediktif, seperti penggunaan machine learning untuk memprediksi tren keuangan. Dengan model yang tepat, perusahaan dapat meningkatkan akurasi prediksi, mengurangi risiko keuangan, dan mendukung pengambilan keputusan berbasis data. Dalam meleraikan hambatan, penerapan machine learning akan mampu menangkap dan mempelajari pola dari data laporan keuangan perusahaan yang meliputi, tanggal transaksi, Type of Coverage (TOC), nilai loss ratio, expenses, disconto rate, dan risk adjustment dapat mengidentifikasi kelayakan produk asuransi. Penerapan metode machine learning dalam memperoleh informasi dapat dilakukan dengan beberapa metode. Penerapan berbagai metode dapat diterapkan dalam mengidentifikasi kelayakan produk asuransi, seperti Gated Recurrent Unit 3 (GRU), Temporal Fusion,

Autoregressive Models with Neural Networks), Echo State Networks (ESNs), dan Long Short-Term Memory (LSTM). Dalam melakukan proses identifikasi kelayakan produk asuransi berdasarkan parameter yang telah disebutkan sebelumnya, LSTM dipilih dibandingkan dengan metode lain karena kemampuan dalam menangkap hubungan jangka panjang dalam data bersifat time-series. **19 34 LSTM** juga mempunyai struktur mekanisme berbeda dari metode lain yaitu gates (input gate, output gate, dan forget gate) dan cell state. Struktur mekanisme tersebut mendukung metode ini dalam mempertahankan informasi dari hasil data sebelumnya atau mengabaikan informasi yang sudah tidak lagi relevan dengan input data saat ini. Metode LSTM dapat diterapkan ketika perusahaan mempunyai parameter data dan jumlah besar data yang memadai ataupun sudah berjalan setidaknya tiga tahun. Metode LSTM dapat diterapkan dalam bentuk model yang dapat di deployment ke perangkat lunak sebagai mesin yang mampu mempelajari dan mengelola masukan dari pengguna, sehingga menghasilkan identifikasi kelayakan produk asuransi. Sementara itu, GRU lebih sederhana dan cepat dalam pelatihan, tetapi LSTM unggul dalam menangani pola data yang kompleks dengan ketergantungan jangka panjang seperti hubungan antara loss ratio, discount rate, expenses, dan risk adjustment dalam data. Metode seperti Temporal Fusion atau Autoregressive Models cocok untuk data multivariate atau forecasting, sedangkan Echo State Networks (ESNs) kurang fleksibel untuk data berskala besar. Oleh karena itu, secara garis besar LSTM dipilih untuk melakukan identifikasi kelayakan produk asuransi dari data laporan keuangan perusahaan. LSTM lebih unggul dibandingkan GRU karena kemampuannya mempelajari pola relevansi jangka panjang dalam data time-series melalui struktur gates yang lebih bervariasi, serta memiliki fleksibilitas tinggi dibandingkan Temporal Fusion, Autoregressive Models, dan ESNs dalam menangani pola data yang kompleks, berukuran besar, dan multivariate dengan ketergantungan temporal yang kuat.

### 1.2 Identifikasi Masalah Hambatan dalam mengidentifikasi kelayakan produk asuransi ditemukan pada metode konvensional, yang mencakup peningkatan volume data yang memerlukan sumber daya teknologi lebih untuk mengelola

data, kebutuhan dalam perolehan informasi yang tersusun dari beberapa parameter seperti loss ratio, 4 discount rate, expenses, risk adjustment, serta keterbatasan perangkat lunak seperti Microsoft Excel dan Tableau dalam menangani data dengan volume data besar. Selain itu, tantangan regulasi eksternal, yaitu kewajiban penerapan PSAK 117, memengaruhi proses evaluasi terhadap kelompok produk asuransi. Oleh karena itu, dalam melerai habatan yang dijelaskan metode LSTM digunakan sebagai solusi untuk meningkatkan akurasi dan efisiensi dalam mengidentifikasi kelayakan produk asuransi melalui analisis pola jangka panjang dan hubungan antar parameter dalam data yang bersifat time-series di perusahaan asuransi. 1.2.1

Rumusan Masalah Berlandaskan tentang hal yang telah diterburai sebelumnya, bahwa penelitian ini merumusan masalah yaitu “Bagaimana parameter loss ratio, disconto rate, expenses, risk adjustment berpengaruh dalam menentukan nilai Contract Service Margin (CSM) sebagai indikator dalam mengidentifikasi

kelayakan produk asuransi menggunakan metode LSTM? . 1.2 **43** 2 Batasan Masalah  
Batasan masalah yang ditentukan dalam mendukung tujuan penelitian sebagai berikut. 1)

Informasi data hanya mencakup periode 2017 hingga 2023. 2) Parameter yang digunakan terbatas pada faktor utama dan faktor lainnya dalam menentukan nilai CSM. serta informasi tambahan seperti tanggal transaksi, TOC, gross premi dan gross claim. 3) Pengembangan model yang digunakan terbatas pada penerapan metode LSTM dalam mengidentifikasi kelayakan produk asuransi. 4) Penelitian tidak membahas secara spesifik terkait faktor eksternal. Hanya terfokus pada faktor internal dalam penentuan kelayakan produk asuransi. 1.3 Tujuan Penelitian ini bertujuan untuk mengembangkan model machine learning berbasis LSTM yang mampu mengidentifikasi nilai kelayakan produk asuransi. Model ini dirancang untuk menganalisis hubungan faktor utama yaitu loss ratio dan faktor tambahan yaitu discount rate, expenses, dan risk adjustment dalam 5 menentukan nilai CSM, serta mempelajari pola nilai CSM dan loss ratio dalam data. Hasilnya akan diimplementasikan dalam aplikasi berbasis web yang mendukung pemegang keputusan perusahaan dalam menyesuaikan strategi bisnis, mengelola risiko,

dan mengembangkan produk asuransi. Aplikasi ini dapat diakses melalui internet untuk meningkatkan efisiensi analisis data dan pengambilan keputusan keuangan oleh perusahaan asuransi. 25 1.4 Manfaat Berikut adalah segelintir manfaat yang diharapkan dalam penelitian ini, yakni manfaat bagi peneliti dan perusahaan antara lain sebagai berikut. 1.4.1 Manfaat bagi Peneliti Manfaat yang termuat bagi peneliti berupa kontribusi ilmiah dalam mengintegrasikan ilmu informatika dan analisis keuangan, khususnya melalui pengembangan aplikasi yang menggunakan model LSTM. Penelitian ini memungkinkan untuk mengembangkan suatu aplikasi yang mampu mengidentifikasi kelayakan produk asuransi. 1.4.2 Manfaat bagi Perusahaan Manfaat yang termuat bagi perusahaan meliputi meningkatnya efisiensi waktu dan sumber daya teknologi dalam proses menilai kelayakan produk asuransi. Identifikasi yang dihasilkan dapat dijadikan informasi tambahan dan mendukung keputusan perusahaan di masa mendatang. 1.5 Kebaruan Penelitian ini menghadirkan kebaruan dalam penerapan metode LSTM untuk mengidentifikasi kelayakan produk asuransi dari data laporan keuangan perusahaan. Metode ini diharapkan dapat mengatasi hambatan pada metode konvensional dan meningkatkan efisiensi melalui pengujian model menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE) untuk menganalisis hubungan antara loss ratio, discount rate, expenses, dan risk adjustment dalam menentukan nilai CSM sebagai indikator kelayakan produk asuransi. LSTM digunakan karena kemampuannya mengolah informasi, memastikan bahwa setiap faktor yang digunakan untuk pembelajaran pola menjadi 6 pertimbangan sehingga menghasilkan identifikasi kelayakan produk yang yang tepat. 1.6 Kerangka Penulisan Kerangka penulisan pada penelitian Tugas Akhir ini merujuk pada kaidah penulisan dari Fakultas Teknologi dan Desain Universitas Pembangunan Jaya yang terdiri dari enam bab dan tersusun secara berurut antara lain sebagai berikut.

4 8 15 BAB I PENDAHULUAN Bagian ini menyelubungi beberapa sub bab di antaranya adalah latar belakang masalah, identifikasi masalah, rumusan masalah, batasan masalah, tujuan masalah, manfaat penelitian, kebaruan, serta kerangka penulisan. 18 BAB II TINJAUAN PUSTAKA Bagian ini mencakup

sub-bab yang berisi pencapaian yang telah diperoleh dalam penelitian sebelumnya serta tinjauan teoritis yang relevan sebagai dasar pendukung penelitian. BAB III TAHAPAN PELAKSANAAN Bagian ini memaparkan beberapa tahapan berurut yang dilaksanakan dalam penelitian hingga selesai. Selain itu, bab ini menjelaskan secara rinci metode penelitian yang digunakan. 5 8 10 BAB IV ANALISIS DAN PERANCANGAN Bagian ini membahas proses analisis dan perancangan yang dilakukan dalam penelitian atau proyek. Di dalamnya dijelaskan tentang bagaimana sistem, aplikasi, atau metode yang digunakan dirancang dari awal. BAB V HASIL DAN PEMBAHASAN Bagian ini menyajikan temuan yang didapat dari rangkaian tahap penelitian atau pengujian yang telah dilaksanakan. Bagian ini juga menjelaskan analisis hasil, yang bisa berupa data kuantitatif atau kualitatif. Pada sub bab pembahasan, hasil yang diperoleh dibandingkan dengan teori atau penelitian sebelumnya, serta 7 diuraikan secara mendalam mengenai apa yang menyebabkan hasil tersebut muncul dan bagaimana kaitannya dengan tujuan penelitian. BAB VI PENUTUP Bagian ini mencantumkan penutup dari seluruh penelitian yang telah dilakukan, hal tersebut menyelubungi hal pokok temuan penelitian serta rekomendasi atau anjuran untuk penelitian berikutnya. 8 BAB II TINJAUAN PUSTAKA Bab tinjauan pustaka ditujukan untuk mengklarifikasi dan memperkuat gagasan berdasarkan teori dan penelitian-penelitian sebelumnya. Tinjauan Pustaka akan membahas penelusuran literatur, pencapaian terdahulu, serta tinjauan teoritis. 2.1 Pencapaian Terdahulu Pada penelitian ini, referensi penelitian sebelumnya digunakan sebagai bahan rujukan, landasan, dan penguat argumen. Oleh Karena itu, referensi yang mencangkup topik relevan ditinjau mengenai penerapan model LSTM dengan studi kasus yang berbeda-beda. Lihat Tabel 2.1 Pencapaian Terdahulu Tabel 2. 1 Pencapaian Terdahulu Literatur ke-1 Nama Penulis U. M. Butt, S. Letchmunan, M. Ali, F. H. Hassan, A. Baqir, dan H. H. R. Sherazi (2021) Judul Machine Learning Based Diabetes Classification and Prediction for Healthcare Applications Hasil Penelitian ini bertujuan untuk mengembangkan pendekatan berbasis machine learning dalam klasifikasi, deteksi dini, dan prediksi diabetes, guna

meningkatkan efisiensi dan akurasi deteksi sekaligus mencegah komplikasi serius akibat diabetes mellitus. Dengan menggunakan dataset PIMA Indian Diabetes, penelitian ini menguji tiga classifier—Random Forest (RF), Multilayer Perceptron (MLP), dan Logistic Regression (LR)—serta metode prediktif seperti Long Short-Term Memory (LSTM), Moving Averages (MA), dan Linear Regression (LR). Hasil menunjukkan bahwa MLP mencapai akurasi 86,08% dalam klasifikasi, sedangkan LSTM unggul dalam prediksi dengan akurasi 87,26%, menjadikan pendekatan ini efektif untuk aplikasi perawatan kesehatan.

Literatur ke-2 Nama Penulis Nizar Alsharif (2022) Judul Fake opinion detection in an e-commerce business based on a long-short memory algorithm Hasil Penelitian ini mengusulkan penggunaan algoritma Long Short-Term Memory (LSTM) untuk mendeteksi opini palsu dalam bisnis e-commerce, yang sering kali memengaruhi keputusan pembelian konsumen. Model 9 LSTM dilatih menggunakan dataset ulasan produk dari Yelp, dengan menambahkan fitur linguistik untuk membedakan ulasan asli dan palsu. Hasil pengujian menunjukkan bahwa model ini mencapai akurasi dan skor F1 sebesar 98%, membuktikan efektivitasnya dalam mengklasifikasikan ulasan sebagai palsu atau asli. Pendekatan ini memberikan kontribusi penting dalam membantu konsumen membuat keputusan pembelian yang lebih tepat dan mengurangi dampak negatif opini palsu di platform e-commerce.

Literatur ke-3 Nama Penulis Jiang Han (2024) Judul Prediction Model of User Investment Behavior Based on Deep Learning Hasil Penelitian ini mengembangkan model prediksi perilaku investasi pengguna menggunakan algoritma Long Short-Term Memory (LSTM) yang telah dioptimalkan untuk meningkatkan akurasi dan efisiensi dalam memprediksi perilaku investasi di pasar saham. Dengan menganalisis dataset yang mencakup 5120 pengguna dan 231497 catatan perilaku investasi dari indeks saham Shanghai, model ini mengatasi keterbatasan metode tradisional seperti RNN melalui penyesuaian struktur jaringan, parameter, dan mekanisme dropout untuk mengurangi overfitting. Hasil penelitian menunjukkan bahwa model ini mampu memberikan analisis perilaku investasi yang akurat, memprediksi tren pasar saham, serta

menghasilkan prediksi harga opsi yang lebih baik dibandingkan metode tradisional. Model ini juga dapat memberikan wawasan yang lebih baik terkait tren investasi jangka panjang dan membantu menstabilkan harga opsi serta keseimbangan pasar. Literatur ke-4 Nama Penulis E. Lee, D. Kim, dan H. Bae (2021) Judul Container Volume Prediction Using Time-Series Decomposition with a Long Short-Term Memory Models Hasil Penelitian ini mengusulkan model prediksi volume kontainer di Pelabuhan Busan dengan menggabungkan dekomposisi deret waktu dan variabel eksternal ke dalam model deep learning berbasis Long Short-Term Memory (LSTM). Model ini dirancang untuk meningkatkan akurasi prediksi volume kontainer, yang sebelumnya menggunakan metode statistik tradisional seperti ARIMA dan regresi namun tidak cukup efektif dalam menangkap kompleksitas dan variabilitas data akibat pengaruh lingkungan eksternal. Dengan pendekatan multivariat yang mempertimbangkan dekomposisi deret waktu dan variabel eksternal, model ini menunjukkan kinerja lebih 10 baik dibandingkan LSTM tradisional, serta mampu mengikuti tren volume kontainer secara lebih akurat. Penelitian ini memberikan kontribusi signifikan bagi perencanaan dan operasi pelabuhan yang lebih efisien. Literatur ke-5 Nama Penulis Y. Wang, M. A. bin Abdullah, dan J. Y. T. Hwang (2024) Judul Time Series Analysis and Optimization of the Prediction Model of Agricultural Insurance Loss Ratio Hasil Penelitian ini bertujuan untuk mengembangkan pendekatan berbasis machine learning dalam klasifikasi, deteksi dini, dan prediksi diabetes, guna meningkatkan efisiensi dan akurasi deteksi sekaligus mencegah komplikasi serius akibat diabetes mellitus. Dengan menggunakan dataset PIMA Indian Diabetes, penelitian ini menguji tiga classifier—Random Forest (RF), Multilayer Perceptron (MLP), dan Logistic Regression (LR)—serta metode prediktif seperti Long Short-Term Memory (LSTM), Moving Averages (MA), dan Linear Regression (LR). Hasil menunjukkan bahwa MLP mencapai akurasi 86,08% dalam klasifikasi, sedangkan LSTM unggul dalam prediksi dengan akurasi 87,26%, menjadikan pendekatan ini efektif untuk aplikasi perawatan kesehatan. Literatur ke-6 Nama Penulis S. Banik, N.

Sharma, M. Mangla, S. N. Mohanty, S. Shitharth (2022) Judul LSTM Based Decision Support System for Swing Trading in Stock Market Hasil Penelitian ini mengembangkan sistem pendukung keputusan berbasis Long Short-Term Memory (LSTM) untuk membantu trader melakukan swing trading di pasar saham. Model LSTM digunakan untuk memprediksi harga saham di masa depan berdasarkan data historis, dengan mempertimbangkan indikator teknis seperti Money Flow Index (MFI), Relative Strength Index (RSI), level Support dan Resistance, serta analisis Moving Average Convergence Divergence (MACD) dan garis sinyal. Hasil penelitian menunjukkan bahwa model LSTM yang diusulkan memiliki kinerja yang lebih baik dibandingkan model tradisional, dengan nilai Root Mean Squared Error (RMSE) yang lebih rendah pada prediksi harga pembukaan, harga penutupan, harga tertinggi, harga terendah, dan volume perdagangan saham. Sistem ini juga menyediakan laporan analisis investasi yang mencakup skor kesuksesan investasi, membantu trader membuat keputusan yang lebih tepat dan mengurangi risiko investasi di pasar saham. Literatur ke-7 11 Nama Penulis S. Kumar, R. Sharma, T. Tsunoda, T. Kumarevel, dan A. Sharma.(2021) Judul Forecasting the spread of COVID-19 using LSTM network Hasil Penelitian ini mengembangkan model prediksi berbasis Long Short-Term Memory (LSTM) untuk meramalkan penyebaran COVID-19. Model ini divalidasi menggunakan data dari Selandia Baru, yang berhasil menekan jumlah kasus harian COVID-19 hingga nol, dan menunjukkan bahwa LSTM mampu memprediksi dengan akurat periode waktu pengendalian penyebaran COVID-19. Selain itu, model ini digunakan untuk meramalkan tanggal perkiraan pengendalian di negara lain. Meskipun prediksi bersifat estimasi berdasarkan data saat ini, hasil ini diharapkan dapat membantu pemerintah dan pembuat kebijakan dalam merancang strategi untuk mengendalikan pandemi. Penelitian ini juga menekankan perlunya pembatasan tambahan di banyak negara, karena tanpa intervensi lebih lanjut, diperlukan waktu lebih dari tiga bulan untuk mengendalikan penyebaran COVID-19.. 2.2 Tinjauan Teoritis Pada bagian ini menguraikan teori-teori yang mendasari dalam penelitian. Penguraian setiap teori akan disampaikan

secara rinci untuk memberikan landasan konseptual yang jelas bagi penelitian, sebagaimana dijabarkan berikut. 2.2 **13** **1** Prediksi Prediksi atau forecasting adalah proses memperkirakan nilai atau kejadian di masa depan berdasarkan analisis data historis. Prediksi digunakan oleh berbagai pihak, termasuk organisasi, perusahaan, pemerintah, dan individu, untuk mendukung pengambilan keputusan strategis. Proses ini dilakukan dalam berbagai rentang waktu bergantung pada kebutuhan, mulai dari harian hingga tahunan. Senapati et al. (2023) Prediksi merupakan tugas mendasar dalam ilmu pengetahuan dan rekayasa yang dilakukan dengan menggunakan model matematika untuk meramalkan peristiwa atau hasil di masa depan melalui analisis pola dari pengamatan masa lalu, sehingga pada dasarnya menjawab apa yang kemungkinan besar akan terjadi berdasarkan perilaku yang telah diketahui sebelumnya. Penerapan prediksi telah dilakukan di berbagai sektor seperti pasar keuangan, kesehatan, bisnis, dan teknologi, baik pada skala lokal maupun global. Tujuan 12 utama prediksi adalah untuk mengurangi ketidakpastian dan memberikan wawasan yang mendukung perencanaan dan pengelolaan risiko. Savadatti et al. (2022) Prediksi dalam machine learning merujuk pada proses penggunaan algoritma untuk menganalisis data historis dan meramalkan hasil di masa depan. Proses ini melibatkan pengidentifikasian pola dan tren dalam data untuk mendukung pengambilan keputusan yang terinformasi di berbagai bidang, seperti bisnis, kedokteran, dan pendidikan. Proses prediksi dilakukan dengan menggunakan metode berbasis machine learning seperti Long Short-Term Memory (LSTM), yang mampu menangani data kompleks dan menghasilkan prediksi yang lebih akurat. Menurut (Oak et al., 2024) Model LSTM multivariat mampu menangani beberapa deret waktu secara bersamaan, sehingga dapat menangkap interaksi antar variabel. Pendekatan ini meningkatkan akurasi peramalan dengan mengintegrasikan hubungan yang kompleks. LSTM mampu melakukan prediksi dengan memanfaatkan mekanisme gates (input, forget, dan output) serta cell state untuk menangkap hubungan temporal dan pola jangka panjang dalam data berurutan, sehingga menghasilkan prediksi yang akurat. 2.2 **2** **3** **9** **20** **2** Machine

Learning Machine learning adalah cabang kecerdasan buatan (AI) yang memungkinkan sistem untuk belajar dan meningkatkan kinerjanya dari data tanpa diprogram secara eksplisit. **2 3** Saini et al. (2024a) Algoritma machine learning merupakan bagian dari kecerdasan buatan yang memungkinkan komputer untuk belajar dan membuat prediksi atau keputusan tanpa pemrograman eksplisit, dengan menggunakan teknik statistik untuk mengidentifikasi pola dalam data guna melakukan prediksi atau klasifikasi di berbagai aplikasi. **2 7 28** Machine learning terbagi menjadi beberapa jenis, seperti supervised learning, unsupervised learning, reinforcement learning, dan semi-supervised learning. **7** Menurut (Saini et al., 2024b) Algoritma machine learning terbagi menjadi tiga kategori utama: pembelajaran terawasi (supervised learning), pembelajaran tak terawasi (unsupervised learning), dan pembelajaran penguatan (reinforcement learning). Setiap kategori menggunakan teknik yang berbeda untuk belajar dari data, memungkinkan berbagai aplikasi di berbagai bidang seperti pertanian, kesehatan, dan keuangan. Proses pembuatan machine learning mencakup pengumpulan dan preprocessing data, 13 pelatihan model, evaluasi kinerja menggunakan metrik seperti RMSE dan MAE, serta penerapan pada data baru. Menurut (Scutari & Malvestio, 2023) Proses pengembangan machine learning melibatkan pembuatan infrastruktur perangkat lunak dan pelaksanaan langkah-langkah analisis data. Alur kerja yang bersifat iteratif ini menggabungkan praktik rekayasa perangkat lunak dengan ilmu data, dengan fokus pada pembangunan dan pengoperasian model serta persiapan dan analisis data secara efisien. **9** Machine learning diterapkan di berbagai bidang, termasuk pengenalan wajah, deteksi penipuan, analisis pasar, dan penilaian kelayakan produk asuransi. **2.2 22** **3** Pengumpulan Data Pengumpulan data adalah tahap awal dalam proses analisis yang bertujuan untuk memperoleh informasi relevan yang diperlukan untuk mendukung penelitian atau pengembangan model. Menurut (Salmia, 2023) Proses pengumpulan data melibatkan penggunaan berbagai instrumen penelitian untuk mengumpulkan field data yang kemudian diolah baik secara kuantitatif maupun kualitatif. Pengaturan sistematis ini membantu menjawab pertanyaan penelitian atau

menguji hipotesis, memastikan validitas dan keandalan data. Dalam konteks ini, proses pengumpulan data dilakukan dari perusahaan asuransi swasta yang memperizinkan penggunaan data internal yaitu laporan keuangan yang berisikan informasi sensitif. Pengumpulan data berlangsung pada tahap awal proyek untuk memastikan ketersediaan data yang dibutuhkan sebelum proses analisis dan pengembangan model dilakukan. Data diperoleh dari sistem informasi operasional harian perusahaan. Tujuan utama pengumpulan data adalah untuk memastikan bahwa dataset yang digunakan mencerminkan kondisi aktual perusahaan, relevan dengan kebutuhan analisis, dan cukup representatif untuk mendukung pelatihan model atau pengambilan keputusan perusahaan. Menurut (Geburu et al., 2022) Dataset dalam machine learning berfungsi sebagai elemen dasar untuk melatih dan mengevaluasi model. Karakteristiknya memengaruhi perilaku model secara signifikan, sehingga pemilihan dan pemahaman dataset menjadi krusial untuk mencapai transparansi, akuntabilitas, dan reproduktifitas dalam hasil machine learning. Proses pengumpulan data melibatkan akses ke sistem internal perusahaan, penyaringan dokumen digital, serta pengumpulan data di dalam perusahaan.

#### 14.2.2.4 Preprocessing Data

Preprocessing data adalah tahap penting yang bertujuan untuk mempersiapkan dataset agar layak digunakan oleh model machine learning. Menurut (Bala & Behal, 2024) Preproses data mencakup berbagai teknik, seperti pembersihan data, normalisasi, pemilihan fitur, dan pengurangan dimensi. Langkah-langkah ini bertujuan untuk meningkatkan kualitas data sekaligus mengoptimalkan kinerja model pembelajaran mesin dan pembelajaran mendalam, sehingga mendukung analisis yang lebih akurat terhadap data mentah dan tidak terstruktur dari beragam bidang. Tahap ini dilakukan dengan memanfaatkan data yang telah dikumpulkan dari perusahaan sebelumnya. Preprocessing dilakukan setelah data dikumpulkan dan sebelum pelatihan model dimulai. Tahap ini diterapkan menggunakan perangkat lunak alat machine learning. Tujuan preprocessing adalah untuk memastikan kualitas data dapat ditingkatkan melalui proses pembersihan, penyusunan, dan penyesuaian format data agar sesuai untuk analisis, sehingga akurasi

hasil dapat ditingkatkan. Langkah-langkah preprocessing mencakup penanganan data hilang, penghapusan duplikasi, normalisasi, penghapusan outlier, dan pembagian data menjadi set pelatihan, pengujian, dan validasi untuk memastikan model dapat bekerja secara optimal.

### 2.2.5 Split Data

Split data adalah proses membagi dataset menjadi beberapa subset untuk mendukung pelatihan dan evaluasi model machine learning. Menurut (Oktafiani et al., 2023) Penelitian ini mengkaji rasio pembagian data train-test dari 60:40 hingga 95:05, yang menunjukkan variasi signifikan dalam kinerja model. Penelitian ini menekankan pentingnya memilih rasio yang optimal untuk menyeimbangkan overfitting dan underfitting. Tujuan penggunaan metode pembagian data dalam machine learning adalah untuk mengevaluasi kinerja model dengan membagi data menjadi set pelatihan dan pengujian, sehingga menghasilkan identifikasi yang akurat. Pendekatan ini membantu menentukan komposisi data terbaik untuk mencapai prediksi yang optimal. Proses ini dilakukan sebelum pelatihan model dimulai untuk memastikan bahwa model dapat dievaluasi secara objektif dan menghasilkan generalisasi yang baik. Pembagian data diterapkan pada dataset yang telah diproses. Tujuan dari split data adalah untuk memastikan bahwa model dapat diuji pada data yang tidak pernah digunakan selama pelatihan, sehingga meminimalkan risiko overfitting dan meningkatkan keakuratan hasil. Menurut (Sivakumar et al., 2024) Proses pembagian data biasanya dilakukan dengan membagi dataset menjadi tiga subset utama: set pelatihan, validasi, dan pengujian, menggunakan rasio umum seperti 70:20:10 atau 80:20:10. Rasio ini mengalokasikan sebagian besar data untuk pelatihan, sementara data validasi digunakan untuk memastikan model dapat menggeneralisasi dengan baik, dan data pengujian digunakan untuk mengevaluasi kinerja akhir model secara objektif pada data yang belum pernah dilihat sebelumnya.

### 2.2.6 Metode LSTM

Long Short-Term Memory (LSTM) adalah sebuah jenis model deep learning dari kelompok jaringan syaraf tiruan (Neural Network). **19 47** LSTM merupakan hasil modifikasi dari Recurrent Neural Network (RNN). Model LSTM dirancang untuk mengelolah data berurutan seperti time series, teks, dan suara. Menurut Ravikumar

(2023) LSTM merupakan jenis khusus dari RNN yang dirancang untuk secara efisien menangkap ketergantungan jangka panjang dalam data berurutan. 6 13 38 LSTM mampu mengatasi masalah vanishing gradient dan exploding gradient yang sering menjadi kendala pada RNN konvensional. Keterbatasan RNN yang dimodifikasi menjadi LSTM terletak pada arsitektur jaringan dan mekanisme penyimpanan informasi. RNN menggunakan looping sederhana, dimana informasi dari langkah sebelumnya langsung diteruskan ke langkah berikutnya. Sehingga, menyebabkan kehilangan dependensi data dalam jangka panjang. Sedangkan kelebihan LSTM menggunakan mekanisme gerbang (gates) untuk mengelola informasi, menggunakan informasi, dan melupakan informasi yang disimpan sebelumnya untuk proses selanjutnya. Oleh karena itu, LSTM lebih umum digunakan untuk mengolah data yang lebih kompleks seperti prediksi time series, pemrosesan bahasa alami, dan pengenalan suara. Lihat Gambar 2.1 Arsitektur LSTM. 16 Gambar 2. 1 24 1 Arsitektur LSTM Berdasarkan arsitektur LSTM pada gambar terbagi menjadi tiga jenis gerbang utama yaitu forget gates, input gates, output gates. Gerbang-gerbang tersebut dapat direpresentasikan dalam bentuk matematis sebagai berikut.

a) Forget Gate Forget gate berperan untuk melupakan informasi yang tidak relevan dari data sebelumnya atau sudah berada di memori lama. Sehingga dapat direpresentasikan dalam bentuk matematis sebagai berikut.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$
 (2.1) Keterangan, •  $f_t$  = Output forget gate •  $[h_{t-1}, x_t]$  = Hidden state sebelumnya •  $x_t$  = Input saat ini •  $W_f, b_f$  = Bobot dan bias forget gate

b) Input Gate Input gate merupakan gerbang yang memutuskan informasi baru apa saja yang perlu ditambahkan ke cell state. Sehingga representasi matematis dari input gate sebagai berikut.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$
 (2.2) 
$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$
 (2.4) 
$$C_t = i_t \cdot c_t$$
 (2.5) Keterangan, •  $C_t$  = Cell state (Menyimpan Jangka Panjang) •  $f_t$  = Output forget gate •  $[h_{t-1}, x_t]$  = Hidden state sebelumnya •  $i_t$  = Inp

ut gate c) Output Gate Output gate merupakan gerbang akhir yang menghasilkan nilai prediksi dari hidden state berdasarkan cell state saat ini. Sehingga Representasi matematis dari output gate sebagai berikut.  $\sigma$

$$\sigma = \sigma(x_{t-1}, h_t) + \sigma(x_t)$$

$$(2.6) \sigma = \sigma(x_t, h_t) \quad (2.7) \text{ Keterangan}$$

gan, •  $C_t$  = Cell state •  $h_t$  = Hidden state Dalam penelitian

ini LSTM akan diterapkan untuk mengelola data laporan keuangan untuk mengidentifikasi kelayakan produk asuransi. Gerbang-gerbang LSTM seperti forget gate akan melupakan informasi historis yang tidak relevan, seperti informasi nilai loss ratio, disconto rate, expenses, risk adjustment, dan nilai CSM yang tidak berpengaruh pada tren selanjutnya. Input gate yang menambah informasi baru dari data laporan keuangan di periode berikutnya.

Lalu, output gate yang menghasilkan prediksi loss ratio dan komponen nilai CSM berdasarkan pola yang telah dipelajari. Sehingga menghasilkan tambahan informasi untuk membantu perusahaan dalam mengelola risiko perusahaan dan menilai kelayakan dari produk asuransi. 18 2.2.7 Pelatihan Model Pelatihan model adalah tahapan krusial dalam machine learning, dimana model dilatih menggunakan sub data pelatihan dan validasi untuk mempelajari pola dan hubungan dalam dataset. Proses ini dilakukan dengan algoritma machine learning. Pelatihan dilakukan setelah preprocessing data selesai dan sebelum pengujian model dilakukan. Menurut (Munde, 2024) Proses pelatihan dalam pembelajaran mesin melibatkan penggunaan data berlabel pada pembelajaran terawasi untuk membangun model prediktif, sedangkan pembelajaran tak terawasi bertujuan mengidentifikasi pola dalam data tanpa label. Langkah-langkah utama meliputi praproses data, rekayasa fitur, dan pemilihan model. Tujuan utama pelatihan model adalah untuk menemukan parameter optimal yang meminimalkan kesalahan prediksi, sehingga menghasilkan model dengan performa yang baik dan mampu memprediksi secara akurat. Proses pelatihan melibatkan input data pelatihan ke dalam model, perhitungan output prediksi, penghitungan error antara prediksi dan nilai sebenarnya. Proses ini diulang secara iteratif hingga model mencapai tingkat

akurasi yang diinginkan atau memenuhi kriteria penghentian tertentu. Dalam metode LSTM, pelatihan model melibatkan pengolahan data deret waktu secara berurutan, memanfaatkan mekanisme gates untuk menangkap pola temporal yang kompleks dan menghasilkan prediksi yang lebih akurat.

### 2.2.8 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah sebuah metrik pengujian yang telah umum digunakan untuk menguji tingkat hasil akurasi model prediksi atau identifikasi kelayakan produk asuransi. Prinsip mekanisme RMSE adalah dengan menghitung nilai akar rata-rata dari error antara selisih nilai prediksi dengan nilai aktual dalam data, sehingga menciptakan hasil pengujian performa model yang jelas. RMSE efektif digunakan untuk kesalahan yang terdistribusi secara normal, menjadikannya pilihan utama dalam berbagai aplikasi, termasuk peramalan dan analisis regresi. Menurut (Hodson, 2022) Root Mean Squared Error (RMSE) adalah akar kuadrat dari Mean Squared Error (MSE), yang mewakili kesalahan tipikal untuk kesalahan yang terdistribusi normal. RMSE memberikan metrik dengan satuan yang sama dengan nilai yang diamati, sehingga memudahkan interpretasi. Perolehan nilai RMSE dapat direpresentasikan dalam bentuk matematika melalui persamaan sebagai berikut.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

(2.8) Keterangan,  $y_i$  =

Nilai aktual  $\hat{y}_i$  = Nilai prediksi dari model  $n$  = Jumlah data

### 2.2.9 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah metrik pengujian yang mengukur rata-rata selisih absolut antara nilai prediksi dan nilai sebenarnya, memberikan gambaran tentang seberapa besar kesalahan model secara keseluruhan tanpa memperhitungkan arah kesalahan. Menurut (Robeson & Willmott, 2023) MAE adalah ukuran statistik yang digunakan untuk mengevaluasi akurasi model dengan mengukur rata-rata besar kesalahan dalam serangkaian prediksi, tanpa memperhitungkan arah kesalahan. MAE dihitung sebagai rata-rata dari selisih absolut antara nilai prediksi dan nilai sebenarnya. MAE berguna karena memberikan interpretasi yang jelas tentang besar kesalahan, sehingga lebih mudah dipahami dibandingkan dengan metrik lain seperti Mean Squared Error (MSE) atau Root Mean Squared

Error (RMSE). Perolehan nilai MAE dapat direpresentasikan dalam bentuk matematika melalui persamaan sebagai berikut.  $MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$

Keterangan,  $y_i =$  Nilai

aktual  $\hat{y}_i =$  Nilai prediksi dari model  $n =$  Jumlah

data

### 2.2.10 Deployment Model

Deployment model adalah tahap akhir dalam siklus pengembangan model machine learning, di mana model yang telah diuji dan disempurnakan diimplementasikan ke dalam aplikasi. Proses ini berlangsung dalam tahap pengembangan interaksi pengguna untuk memastikan bahwa model dapat memproses data dan memberikan hasil yang sesuai. Deployment dilakukan setelah model berhasil melalui tahap pengujian prototyping, dan siap untuk diintegrasikan ke dalam sistem operasional perusahaan. Tujuan utama dari deployment model adalah untuk menyediakan solusi berbasis machine learning yang dapat mendukung identifikasi kelayakan produk asuransi dan memastikan model menghasilkan output yang sesuai. Dalam konteks identifikasi kelayakan produk asuransi, deployment model mencakup integrasi model Long Short-Term Memory (LSTM) ke dalam bentuk aplikasi website dan memungkinkan model memproses data seperti loss ratio, discount rate, expenses, dan risk adjustment untuk memberikan rekomendasi kelayakan produk. Proses deployment melibatkan pengemasan model ke dalam aplikasi website yang mampu mengidentifikasi kelayakan produk asuransi. Dengan deployment yang berhasil, perusahaan asuransi dapat menggunakan model ini untuk meningkatkan efisiensi operasional, membuat keputusan yang lebih tepat, dan memaksimalkan keuntungan melalui pengelolaan produk asuransi yang lebih baik.

### 2.2.11 Metode Konvensional

Metode konvensional merujuk pada pendekatan manual dalam analisis data, seperti penggunaan Microsoft Excel atau Tableau untuk pengolahan dan visualisasi data. Proses ini umumnya dilakukan oleh analis data atau staf keuangan di perusahaan asuransi. Metode ini digunakan sejak lama dalam aktivitas operasional dan pelaporan. Penggunaannya masih lazim di berbagai sektor dan diterapkan di sistem lokal perusahaan. Tujuan utama metode konvensional adalah menyediakan solusi sederhana untuk analisis dasar atau

pelaporan. Namun, metode konvensional mempunyai keterbatasan yaitu memakan waktu, sumber daya teknologi yang cukup tinggi, dan proses yang dilakukan secara manual lainnya. Hal tersebut yang menjadi kelemahan saat menganalisis kelayakan produk asuransi dengan analisa konvensional. 2.1 2.2.12

Data Laporan Keuangan Perusahaan Data laporan keuangan perusahaan mencakup informasi operasional seperti pendapatan premi, klaim yang dibayarkan, biaya operasional, dan laba bersih, yang digunakan untuk analisis kelayakan produk asuransi. Data ini disediakan oleh pihak perusahaan asuransi.

Pengumpulan dan analisis data dilakukan secara berkala sesuai dengan operasional yang ditentukan **36** oleh perusahaan. Data ini diambil dari

sistem internal perusahaan, seperti sistem akuntansi atau basis data keuangan. Tujuan utamanya adalah untuk menyediakan informasi yang akurat dan relevan bagi

analisis dan pengambilan keputusan. Prosesnya melibatkan ekstraksi data, pengolahan, dan integrasi dengan model analitik untuk mendukung penilaian

kelayakan produk asuransi. 2.2.13 Faktor-faktor penentu Kelayakan Produk Asuransi Faktor-faktor penentu kelayakan produk asuransi mencakup elemen-elemen seperti loss ratio, discount rate, expenses, risk adjustment yang menjadi indikator utama dalam menilai kelayakan suatu produk.

Faktor-faktor ini umumnya dianalisis oleh tim aktuaria. Evaluasi dilakukan secara berkala untuk penyesuaian atau selama fase pengembangan produk

baru. Data yang digunakan diambil dari laporan keuangan perusahaan asuransi. Tujuannya adalah untuk memastikan bahwa produk asuransi

memberikan manfaat optimal bagi nasabah sekaligus menguntungkan bagi perusahaan. Analisis faktor-faktor ini melibatkan pendekatan statistik dan

machine learning, seperti model berbasis LSTM, untuk mengidentifikasi pola dan hubungan antarparameter untuk menentukan kelayakan produk asuransi.

2.2.14 Contract Service Margin (CSM) Contract Service Margin (CSM) adalah margin keuntungan yang belum direalisasikan dari kontrak asuransi, dihitung saat pengakuan awal kontrak dan diakui secara bertahap selama masa

layanan. CSM penting untuk menjaga transparansi dan sistematisasi pengakuan pendapatan, memastikan kepatuhan terhadap standar akuntansi seperti IFRS 17

atau PSAK 117. CSM dihitung dengan rumus:  $CSM = (K - (R \times K + O + E)) \times (1 - \alpha)$

$CSM = (K - (R \times K + O + E)) \times (1 - \alpha)$

$CSM = (K - (R \times K + O + E)) \times (1 - \alpha)$

(2.10) 22 Contoh perolehan nilai CSM dapat ditentukan

melalui nilai klaim saat ini yang diperoleh dari diskonto arus kas masa depan, risk adjustment dihitung sebagai persentase dari klaim, dan

expenses dihitung dari persentase premi. Sebagai contoh, jika premi Rp

1.000.000, nilai kini klaim Rp 614.000, risk adjustment Rp 36.840, dan

biaya operasional Rp 150.000, maka CSM sebesar Rp 199.160. CSM

digunakan oleh perusahaan asuransi untuk menilai profitabilitas produk dan

memastikan kelayakan berdasarkan nilai ekonomi masa depan. 2.2.15

Identifikasi Kelayakan Produk Asuransi Identifikasi kelayakan produk asuransi

adalah proses evaluasi untuk menentukan apakah suatu produk asuransi

layak ditawarkan kepada pasar berdasarkan analisis parameter tertentu

seperti risiko, profitabilitas, dan kesesuaian dengan kebutuhan konsumen.

Proses ini dilakukan oleh perusahaan asuransi, aktuaria, dan analis risiko

untuk memastikan produk yang ditawarkan memberikan nilai tambah bagi

perusahaan dan nasabah. Evaluasi dilakukan pada tahap pengembangan produk

atau secara berkala selama siklus hidup produk, sesuai dengan kebutuhan

perusahaan atau perubahan kondisi dunia bisnis asuransi salah satunya

adalah regulasi. Analisis ini diterapkan pada produk asuransi di berbagai

sektor, seperti kesehatan, kendaraan, jiwa, dan properti, baik di tingkat

lokal maupun global. Tujuan utama identifikasi ini adalah untuk

memastikan bahwa produk yang ditawarkan dapat memenuhi kebutuhan pasar,

memberikan keuntungan finansial, serta mematuhi regulasi yang berlaku.

Prosesnya melibatkan analisis data historis, penggunaan model prediksi

risiko, dan penilaian parameter seperti loss ratio, discount rate, dan

expenses, dengan memanfaatkan teknologi seperti machine learning untuk

melerai hambatan pada metode konvensional. 2.2.17 PSAK 117 Pernyataan

Standar Akuntansi Keuangan (PSAK) 117 adalah standar akuntansi **44** keuangan yang

mengatur perlakuan akuntansi untuk kontrak asuransi, bertujuan untuk meningkatkan transpar

nsi, akuntabilitas, dan konsistensi laporan keuangan perusahaan asuransi. Standar ini berlaku bagi perusahaan asuransi dan diatur oleh Otoritas Jasa Keuangan (OJK) di Indonesia. Implementasinya dimulai sejak PSAK ini diberlakukan secara resmi untuk laporan keuangan tahun berjalan. PSAK 117 diterapkan dalam seluruh aspek pelaporan keuangan perusahaan 23 asuransi di Indonesia. Tujuan utama standar ini adalah untuk memastikan laporan keuangan perusahaan asuransi memberikan gambaran yang wajar mengenai posisi keuangan dan kinerja operasionalnya. Proses penerapannya mencakup perubahan metode **35** encatatan, pengukuran, dan pengungkapan yang sesuai dengan ketentuan yang diatur dalam PSAK 117, termasuk perlakuan terhadap aset dan liabilitas kontrak asuransi.

### 2.2.18 Bahasa Pemrograman Python Dalam melakukan penelitian digunakan bahasa pemrograman Python sebagai bahasa pengembangan aplikasi. Bahasa pemrograman Python mempunyai beberapa keunggulan yaitu open source, kode skrip yang lebih sederhana dan high language, dan kumpulan fungsi library yang tersedia, siap pakai, dan dapat disesuaikan dengan kebutuhan sistem. Sintaks kode didukung oleh berbagai fungsionalitas **40** dari perpustakaan yang luas dan komprehensif. Selain itu, tersedia banyak perpustakaan tambahan yang mempermudah pen guna dalam menulis kode sumber. (Justica et al., 2022).

#### 2.2.18.1 Library Numpy

Numpy merupakan salah satu pustaka yang umum digunakan dalam bahasa pemrograman Python. Pustaka ini menyediakan beragam fungsi matematis untuk pengolahan angka, dan termasuk bilangan bulat, matriks (Nofiyanti & Oki Nur Haryanto, 2021). Numpy sering digunakan sebagai alat untuk melakukan komputasi ilmiah yang melibatkan manipulasi data dalam skala besar. Dikenal karena kemampuannya dalam perhitungan matriks dan pengolahan data yang efisien. Sehingga Numpy berkontribusi dalam proses pengembangan model machine learning untuk memprediksi keuangan perusahaan di masa depan.

#### 2.2.18.2 Library Matplotlib

Matplotlib merupakan sekumpulan berbagai fungsi yang dibuat untuk mendukung penggambaran data dalam dua dimensi atau tiga dimensi. (Reynaldi et al., 2021). Matplotlib mendukung program Python untuk melakukan yang berkaitan dengan gambar, plot, dan format penyimpanan. Matplotlib dapat memberikan

visualisasi berdasarkan hasil dari prediksi model machine learning. Hal tersebut dapat memudahkan pengguna aplikasi menarik simpulan dari hasil prediksi yang didapatk **23** n. 2.2.18.3 Library Pandas Pandas merupakan perpustakaan Python yang menawarkan struktur data serta alat analisis data yang mudah digunakan dan memiliki kinerja tinggi. Pustaka ini banyak digunakan untuk tugas-tugas manipulasi data seperti pembersihan, analisis, dan persiapan data untuk mengembangkan machine learning. Pandas mempunyai dua komponen utama yaitu series dan data frame. Sebuah series adalah array berlabel satu dimensi yang mampu menyimpan data dari jenis apa pun, sementara data frame adalah struktur data dua dimensi berlabel yang menyerupai tabel atau lembar kerja, terdiri dari baris dan kolom.

2.2.18.4 Library Flask Flask merupakan sebuah framework yang dikembangkan dengan bahasa dasar yaitu python dalam menjawab keperluan pengembangan aplikasi web. Framework ini terkenal karena kesederhanaannya dan kemudahan dalam melakukan integrasi model yang telah dikembangkan. Menurut Aryudha Hattu et al. (2024) Flask menawarkan keunggulan dalam hal kesederhanaan, fleksibilitas, dan skalabilitas, sehingga menjadi kerangka kerja yang ideal untuk pengembangan sistem aplikasi operasional. Dengan sifatnya yang ringan, Flask memungkinkan kustomisasi yang mudah serta mendukung implementasi konsep seperti Flask Overriding, yang berkontribusi pada peningkatan fungsionalitas dan adaptabilitas sesuai dengan kebutuhan spesifik dalam **17** konteks bisnis. Dalam penelitian ini Flask digunakan untuk media pengembangan website yang akan berinteraksi dengan model machine learning yang telah dikembangkan. 2.2.19 Website Website adalah sekumpulan halaman yang tersedia di internet dan berfungsi untuk menyajikan informasi, konten, atau layanan dalam berbagai format, seperti teks, gambar, video, atau elemen interaktif lainnya. Tujuan utama website adalah mempermudah **27** penyampaian informasi dan mendukung kolaborasi atau layanan. Website dibangun menggunakan HTML sebagai kerangka, CSS untuk estetika, dan JavaScript untuk membuatnya interaktif. Website dapat diakses melalui berbagai perangkat, seperti desktop, tablet, dan ponsel, namun penelitian ini berfokus pada optimalisasi penggunaan di

desktop. 2.2.2.20 Flowchart Flowchart merupakan gambaran visual dari proses kegiatan yang saling berhubungan.. Menurut Gomes et al., (2020), diagram alir sering digunakan untuk merepresentasikan aliran sebuah proses algoritma. Sedangkan Menurut Hermawan et al., (2019), diagram ini dapat memberikan solusi secara bertahap yang terdapat dalam suatu prosedur atau algoritma. Diagram tersebut dapat menggambarkan solusi yang terstruktur mengikuti proses yang terdapat pada sistem. Flowchart mempunyai beragam simbol dan masing-masing mempunyai kegunaan yang berbeda tergantung proses alur informasi yang ingin dibuat. Kegunaan lain dari diagram alur adalah untuk mendokumentasikan tahapan dan rencana dalam sebuah penelitian. Berikut adalah beberapa jenis flowchart dan penjelasannya yang digunakan. Lihat Tabel 2.2 Flowchart. Tabel 2. 2 Flowchart Simbol Keterangan Simbol Terminator Simbol yang menandakan permulaan atau penutupan dari suatu fase atau aktivitas sistem. Simbol Processing Simbol yang merepresentasikan bahwa sebuah proses sudah usai atau telah dilaksanakan dalam sistem. Simbol Decision Berfungsi untuk menentukan pilihan berdasarkan kondisi-kondisi yang tersedia. Simbol Input-Output Simbol Input-Output merupakan representasi visual yang diartikan sebagai proses penerimaan data yang masuk serta pengeluaran data pada sistem. 2.2.21 Unified Modelling Language (UML) Diagram Unified Modeling Language (UML) merupakan suatu pendekatan atau kerangka kerja dalam proses perancangan sistem berbasis komputer atau objek. Hal ini memberikan kejelasan terkait informasi, mendokumentasikan, dan memahami 26 susunan serta karakteristik yang dikembangkan (Anwar et al., 2020). UML umumnya digunakan sebagai alat bantu untuk mempermudah pengembangan perangkat lunak secara sistematis, terstruktur, dan efektif. Dalam penelitian ini, beberapa langkah penerapan UML dilakukan sebagai berikut. a) Use Case Diagram Penggunaan diagram usecase bertujuan untuk merepresentasi bentuk visual dari sebuah informasi dengan menggambarkan bagaimana aplikasi dapat berinteraksi dengan pengguna. Menurut Setiyati et al. (2021) Diagram ini membantu dalam tahap pengembangan perangkat lunak. b) Activity Diagram Activity dia 29 ram adalah representasi pemodelan sistem

yang dirancang untuk menunjukkan alur sistematis dari aktivitas yang terjadi antara pengguna dan aplikasi dalam bentuk diagram. Diagram ini sering digunakan dalam pengembangan sistem aplikasi untuk menggambarkan urutan proses atau alur kerja aplikasi secara keseluruhan. Menurut Nistrina et al. (2022) beberapa simbol dalam Activity diagram digunakan untuk melihat sistem, dengan penjelasan sebagai berikut. Lihat Tabel 2.3 Activity Diagram.

Tabel 2. 3 Activity Diagram Simbol Keterangan Simbol Status Awal Simbol bulat berwarna hitam ini menandakan dimulainya suatu kegiatan. Simbol Decision Simbol yang berfungsi untuk pemilihan dari keadaan yang ada. Simbol Proses Simbol tersebut digunakan untuk menjalin komunikasi antara sistem- sistem yang terlibat. 27 Simbol Panah Simbol tersebut digunakan untuk menunjukkan arah dari proses yang berlangsung. Simbol Association Simbol yang menandakan akhir dari hubungan komunikasi antar objek pada suatu aktivitas. c) Sequence Diagram Sequence diagram merupakan tipe diagram dalam Unified Modeling Language (UML) yang ditujukan untuk memvisualisasikan dan menjelaskan keterlibatan antara komponen yang terdapat pada sistem aplikasi dan 42 masih dikembangkan. Diagram ini menunjukkan hubungan antara objek-objek tersebut selama proses si 42 tem berl ngsung, yang digambarkan melalui berbagai simbol dan elemen visual. Penjelasan mengenai simbol-simbol yang diterapkan dilihat pada tabel 2.4 Sequence Diagram.

Tabel 2. 4 Sequence Diagram Simbol Keterangan Simbol Actor Simbol yang menunjukkan partisipasi dalam interaksi dengan sistem. Simbol Lifeline Simbol yang digunakan untuk mengartikan pelaksanaan dalam suatu eksekusi dalam objek. Simbol Time Active Simbol yang memungkinkan untuk menandai suatu interaksi sebagai aktif. Simbol Message 28 Simbol ini berguna untuk m 33 nunjukkan aktivitas yang terjadi di antara objek dalam suatu interaksi. Simbol Return Message Simbol ini berguna untuk mengembalikan pesan o jek yang akan menerimanya. 29 BAB III TAHAPAN PELAKSANAAN Pada tahap pelaksanaan penelitian ini, akan mencakup tentang bagaimana peneliti menyelesaikan tugas akhirnya. Tahapan tersebut akan terdiri dari serangkaian langkah pelaksanaan dan metode pengujian yang digunakan oleh peneliti. 3.1

Langkah-langkah Pelaksanaan Berikut ini adalah tahap berurut yang direncanakan untuk dilalui dalam pelaksanaan penelitian ini, yaitu sebagai berikut.

Lihat pada Diagram 3.1 Langkah- langkah Pelaksanaan. Diagram 3. 1

Langkah-langkah Pelaksanaan Penjelasan mendalam pada langkah-langkah pelaksanaan

antara lain sebagai berikut. 1. Studi Literatur Dilakukan penelaahan terhadap teori, konsep, dan penelitian sebelumnya yang terkait dengan machine learning, model LSTM, dan analisis kelayakan produk asuransi.

Langkah ini bertujuan untuk memahami pendekatan yang telah ada dan

mengidentifikasi celah penelitian. 2. Analisis Sistem Terdahulu Mengevaluasi

sistem atau metode yang sudah ada dalam menentukan kelayakan produk asuransi, termasuk pendekatan manual maupun berbasis teknologi. Hasil analisis digunakan sebagai acuan untuk merancang model yang lebih baik.

30 3. Rumusan Masalah Merumuskan masalah utama yang hendak diatasi oleh

penelitian, seperti keterbatasan metode saat ini dalam menganalisis faktor

loss ratio dan variabel pendukung lainnya untuk menentukan kelayakan

produk asuransi. 4. Pengumpulan Data Mengumpulkan data historis yang

relevan, seperti data premi, klaim, loss ratio, dan faktor pendukung

lainnya dari perusahaan asuransi untuk digunakan sebagai dataset pelatihan

dan pengujian model. 5. Perancangan Sistem Mendesain arsitektur model

LSTM, termasuk struktur jaringan, fitur yang digunakan, dan proses

input-output sistem. Selain itu, alur kerja sistem yang mencakup

pengolahan data, pelatihan model, dan evaluasi juga dirancang pada tahap

ini. 6. Pengembangan Sistem Melakukan implementasi model LSTM menggunakan

alat dan bahasa pemrograman yang sesuai (misalnya Python dengan pustaka

TensorFlow atau PyTorch). Sistem dikembangkan secara iteratif berdasarkan

desain yang telah dibuat. 7. Pengujian sistem Menguji kinerja model

dengan menggunakan data uji untuk mengevaluasi akurasi, presisi, dan

kemampuan prediksi sistem dalam menentukan nilai kelayakan produk asuransi.

Hasil pengujian digunakan untuk melakukan perbaikan atau optimasi model

jika diperlukan. 8. Pengambilan Kesimpulan Menyimpulkan hasil penelitian

berdasarkan performa model dan kontribusinya dalam meningkatkan akurasi dan

efisiensi analisis kelayakan produk asuransi. 9. Penyusunan Laporan Menyusun laporan akhir yang mencakup seluruh tahapan penelitian, hasil pengujian, analisis, dan kesimpulan, sebagai dokumentasi resmi dari hasil penelitian dan pengembangan model machine learning berbasis LSTM. 31 3.2

Langkah-langkah Penerapan Algoritma Berikut adalah kumpulan langkah untuk penerapan LSTM dalam pengembangan model machine learning pada penelitian ini. Kumpulan langkah tersebut meliputi proses pengumpulan data, pembersihan data, pengolahan data, hingga tahapan lebih lanjut yang meliputi pengujian hasil prediksi model. Lihat pada Diagram 3.2 Tahapan Penerapan Algoritma LSTM. Diagram 3. 2 Tahapan Penerapan Algoritma LSTM Penjelasan lugas terkait hal-hal yang tercantum pada Diagram 3.2 Tahapan penerapan Algoritma LSTM sebagai berikut.

1. Import Library Langkah pertama adalah mengimpor pustaka yang diperlukan untuk membangun, melatih, dan mengevaluasi model machine learning berbasis LSTM. Pustaka yang digunakan mencakup NumPy dan Pandas untuk manipulasi data, Matplotlib dan Seaborn untuk visualisasi data, TensorFlow atau PyTorch untuk membangun model LSTM, serta Scikit-learn untuk preprocessing data dan evaluasi.
2. Data Laporan Keuangan Data laporan keuangan yang digunakan mencakup informasi seperti premi, klaim, loss ratio, dan faktor pendukung lainnya dari produk asuransi. Data ini disiapkan sebagai sumber informasi utama untuk melatih dan menguji model.
3. Preprocessing dan Split Data 32 Proses preprocessing dan pembagian data dilakukan untuk membersihkan dataset, seperti mengisi nilai kosong, normalisasi data, dan encoding variabel kategorikal. Data kemudian dibagi menjadi data pelatihan, validasi, dan pengujian untuk memastikan evaluasi yang adil terhadap performa model.
4. Model Architecture Arsitektur model dirancang dengan membangun lapisan LSTM yang mampu menganalisis pola temporal dari data sekuensial, dilengkapi dengan lapisan dense untuk menghasilkan output. Struktur jaringan, jumlah neuron, dan fungsi aktivasi dirancang sesuai kebutuhan untuk memastikan kinerja optimal.
5. Prediction Prediksi dilakukan setelah model selesai dilatih. Data pengujian dimasukkan ke dalam model untuk menghasilkan

output yang mewakili nilai kelayakan produk asuransi berdasarkan variabel yang dianalisis. 6. Inspect Model Inspeksi model dilakukan untuk memeriksa struktur, jumlah parameter, dan distribusi bobot dalam model. Analisis tambahan, seperti visualisasi kurva loss atau analisis error, dilakukan untuk mengevaluasi performa dan potensi perbaikan. 7. Compile Model Model dikompilasi dengan menetapkan fungsi loss, optimizer, dan metrik evaluasi. Fungsi loss seperti Mean Squared Error (MSE) atau Binary Crossentropy digunakan sesuai dengan tipe output, sementara optimizer seperti Adam dipilih untuk mempercepat konvergensi. 8. Model Training Model dilatih menggunakan data pelatihan dengan sejumlah iterasi (epochs) dan batch size tertentu. Selama pelatihan, performa model dipantau melalui metrik seperti akurasi atau loss untuk memastikan peningkatan kinerja. 9. Evaluate Model Evaluasi model dilakukan menggunakan data pengujian untuk mengukur seberapa baik model dapat memprediksi nilai kelayakan. Metrik seperti MSE, akurasi, atau F1-Score digunakan untuk menilai efektivitas model dalam tugas yang diberikan. 33 10. Save Model Model yang telah selesai dilatih dan diuji disimpan dalam format yang dapat diakses kembali, seperti HDF5 atau SavedModel, untuk memastikan penggunaannya tanpa perlu melatih ulang di masa mendatang. 11. Model Fine-tuning Model kemudian disempurnakan melalui proses fine-tuning, dengan menyesuaikan hyperparameter seperti learning rate atau struktur lapisan. Fine-tuning juga dapat melibatkan pelatihan ulang model dengan dataset yang lebih luas atau berkualitas untuk meningkatkan kinerja dan keandalannya. 16

### 3.3 Metode Pengembangan Perangkat Lunak

Metode pengembangan perangkat lunak merupakan acuan untuk merancang sistem secara sistematis dan terstruktur. Salah satu metode yang digunakan adalah Metode Waterfall, yaitu pendekatan pengembangan perangkat lunak yang bersifat sekuensial, di mana setiap tahapan harus diselesaikan terlebih dahulu sebelum melanjutkan ke tahap berikutnya. Metode ini umum digunakan saat pengembangan aplikasi sudah memiliki kejelasan dan tidak terdapat perubahan signifikan. Penerapan metode Waterfall cocok untuk penelitian dengan lingkup kerja tetap atau yang

memiliki standar prosedur umum yang telah terdokumentasi dengan jelas. Metode ini sering diterapkan di berbagai industri, seperti industri bisnis asuransi, karena menciptakan dokumentasi aplikasi yang lebih jelas dan terstruktur pada setiap tahap pengembangan. Setiap tahap, mulai dari analisis kebutuhan hingga pemeliharaan, menghasilkan dokumen mendetail yang menjadi panduan dan referensi, terutama dalam menghadapi perubahan regulasi. Dokumentasi ini mempermudah tim untuk memahami sistem secara menyeluruh dan melakukan penyesuaian secara terorganisir. Dibandingkan dengan Agile, yang lebih menekankan iterasi cepat dan komunikasi langsung, Waterfall memberikan dasar dokumentasi yang kuat sehingga pengembangan tetap berjalan sesuai kerangka yang dirancang. Dokumentasi yang terstruktur ini memungkinkan tim melacak perubahan dan dampaknya pada keseluruhan sistem, menjadikan pengembangan lebih terkendali, bahkan dalam kondisi yang kompleks. Secara garis besar, mekanisme kerja metode Waterfall dilakukan dengan menyelesaikan tahapan-tahapan berurutan: 34 perencanaan, analisis kebutuhan, desain aplikasi, penerapan, pengujian, peluncuran, dan pemeliharaan. Lihat Diagram 3.3 Waterfall. Diagram 3. 3 Metode Waterfall

Penjelasan lugas terkait hal-hal yang tercantum pada Diagram 3.3 Waterfall sebagai berikut. a) Planning Tahap perencanaan (planning) dimulai dengan menentukan tujuan utama penelitian, yaitu mengembangkan model berbasis LSTM untuk menganalisis kelayakan produk asuransi. Pada tahap ini, ruang lingkup penelitian ditentukan, termasuk data yang akan digunakan, alat dan teknologi yang dibutuhkan, serta risiko yang mungkin muncul selama pengembangan. b) Analysis Tahap analisis (analysis) dilakukan untuk memahami kebutuhan sistem, seperti data yang relevan (laporan keuangan, premi, klaim, dan loss ratio) dan variabel lain yang memengaruhi kelayakan produk asuransi. Analisis ini juga mencakup evaluasi sistem atau metode yang telah ada untuk memastikan bahwa model LSTM yang dikembangkan dapat memberikan hasil yang lebih baik. c) Design 35 Tahap desain (design) bertujuan untuk merancang arsitektur model LSTM yang akan digunakan. Ini meliputi perancangan struktur jaringan, pemilihan fitur

input, alur kerja sistem, dan parameter model yang akan digunakan. Pada tahap ini, desain diagram dan prototipe model juga dibuat untuk memberikan gambaran teknis yang jelas. d) Development Tahap pengembangan (development) melibatkan implementasi desain model ke dalam kode menggunakan alat seperti TensorFlow atau PyTorch. Data yang telah diproses dimasukkan ke dalam sistem, dan model LSTM dibangun untuk mempelajari pola dari data tersebut. Pengkodean dan pengujian unit dilakukan untuk memastikan model berfungsi sesuai dengan spesifikasi. e) Testing Tahap pengujian (testing) dilakukan untuk mengevaluasi performa model dalam memprediksi kelayakan produk asuransi. Data pengujian digunakan untuk mengukur akurasi model, sementara metrik seperti MSE atau precision digunakan untuk menilai keefektifan model. Hasil pengujian ini akan menentukan apakah model perlu disempurnakan. f) Realese Tahap rilis (release) adalah penyebaran model LSTM yang telah diuji ke lingkungan produksi atau simulasi untuk penggunaannya dalam analisis kelayakan produk asuransi. Sebelum rilis, model difinalisasi, didokumentasikan, dan, jika diperlukan, pelatihan pengguna dilakukan agar sistem dapat dioperasikan dengan baik.

### 3.4 Metode Pengujian Dalam pengujian model dan sistem yang mampu melakukan identifikasi kelayakan bisnis perusahaan berdasarkan data laporan keuangan menggunakan pendekatan Research and Development (RnD) dan Prototyping.

#### 3.4.1 Research and Development (RnD) Pengujian Research and Development (R&D) adalah proses evaluasi yang dilakukan untuk menguji kelayakan konsep, model, atau sistem dalam mendukung pengembangan inovasi. Proses ini bertujuan untuk mengidentifikasi kekuatan dan kelemahan model, menguji fungsionalitas dan performa, serta memastikan relevansi terhadap kebutuhan pengguna atau pasar. Dalam pengujian R&D, data dan analisis digunakan untuk mengevaluasi efektivitas sistem dan memberikan dasar untuk pengembangan lebih lanjut. Keunggulan utama pengujian R&D adalah kemampuannya untuk mengurangi risiko pengembangan, meningkatkan akurasi desain, dan memastikan bahwa inovasi yang dihasilkan sesuai dengan tujuan. Meskipun demikian, metode ini memerlukan sumber daya yang besar dan

waktu yang cukup untuk mendapatkan hasil yang optimal. 3.5.2 Prototyping

Pengujian prototyping adalah proses evaluasi model awal atau prototipe sistem untuk memastikan bahwa desain, fungsionalitas, dan kebutuhan pengguna dapat terpenuhi sebelum pengembangan penuh dilakukan. Proses ini melibatkan pembuatan prototipe sederhana yang diuji oleh pengguna untuk mengumpulkan umpan balik, yang kemudian digunakan untuk memperbaiki dan menyempurnakan desain melalui siklus iterasi. Pengujian prototyping bertujuan untuk mengidentifikasi masalah sejak awal, memvalidasi kebutuhan, dan mengurangi risiko pengembangan. Keuntungan utama metode ini adalah memastikan sistem lebih relevan dengan kebutuhan pengguna, meskipun ada kekurangan seperti ketergantungan p

32 da kualitas umpan balik dan lingkup prototipe yang terbatas. Metode ini efektif untuk proyek yang membutuhkan fleksibilitas dan penyesuaian ber 10 asis kebutuhan pengguna. 3.5.2 RMSE Root Mean Squared Error (RMSE) adalah sebuah indikator dala mengukur keakuratan model prediksi dalam memreplikasi nilai aktual.

Nilai RMSE yang diperoleh digunakan sebagai acuan untuk menilai kualitas model yang dikembangkan. Pengujian Nilai RMSE akan dihitung ketika pengembangan model telah mampu mengidentifikasi kelayakan produk asuransi.

RMSE dilakukan bersamaan ketika model machine learning sedang berjalan atau tereksekusi bersamaan dengan data yang diolah. RMSE telah umum diterapkan dalam pengujian model lantaran memberikan ukuran k 26 salahan prediksi yang dikomperasikan dengan nilai aktual, sehingga membantu mengidentifikasi seberapa 37 berbeda antara selisih nilai aktual de gan nilai prediksi. Dalam

proses mengevaluasi nilai RMSE, semakin kecil nilai maka model prediksi mendekati keakuratan yang baik dengan nilai aktual dan sebaliknya. RMSE dilakukan Perhitungan RMSE dapat direpresentasikan dalam bentuk matematis sebagai be 4 6

11 21 ikut. 
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

2 (3.1) Keterangan, •  $y_i$  = Nilai aktual •  $\hat{y}_i$  = Nilai

prediksi dari model •  $n$  = Jumlah data 3.5 2 MAE Mean Absolute Error (MAE) adalah metrik evaluasi yang digunakan untuk mengukur rata-rata kesalahan nilai absolut antara nilai prediksi dan nilai aktual dalam model machine learning. MAE adalah ukuran sederhana dari tingkat kesalahan

prediksi yang dihitung dengan rata-rata nilai absolute selisih antara nilai prediksi dengan nilai aktual. MAE memberikan gambaran langsung tentang seberapa besar kesalahan prediksi tanpa memberikan bobot tambahan sehingga mudah untuk diinterpretasikan. MAE umum digunakan untuk mengevaluasi model machine learning, ketika semua kesalahan diperlukan secara sama. Dalam penerapan MAE pada model umum digunakan pada proses prediksi dan identifikasi kelayakan produk. MAE dapat direpresentasikan dalam bentuk matematis sebagai berikut.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.2)$$

Keterangan,  $y_i$  = Nilai aktual,  $\hat{y}_i$  = Nilai prediksi dari model,  $n$  = Jumlah data

**39 BAB IV ANALISIS DAN PERANCANGAN** Pada bab ini, penelitian yang dilakukan akan menjelaskan spesifikasi sistem yang dibutuhkan, metode kerja sistem, desain antarmuka pengguna, serta rencana pengujian terhadap sistem yang telah dikembangkan.

**4.1 Analisis Sistem Terdahulu** Dalam proses pengidentifikasian kelayakan produk asuransi diawali dengan mempertimbangan dua faktor, yaitu faktor utama dan faktor tambahan. Faktor utama merupakan ketersediaan nilai loss ratio pada setiap produk asuransi yang dilayani oleh perusahaan. Nilai loss ratio diperoleh dari selisih total nilai gross premi dan gross claim dalam periode tertentu. Sedangkan perolehan faktor nilai tambahan seperti disconto rate, expenses, dan risk adjustment dalam perusahaan tempat penelitian telah ditetapkan dengan masing-masing nilai secara berurut adalah tujuh persen, lima belas persen, dan enam persen. Nilai tersebut ditentukan oleh divisi aktuarial dan peraturan regulasi yang dijadikan acuan oleh perusahaan sebagai asumsi yang paling tepat. Penyesuaian nilai tersebut akan menentukan untuk penetapan asumsi pada masa yang mendatang untuk mengidentifikasi kelayakan produk asuransi. Sehingga, nilai-nilai dapat berubah kembali tergantung pada kondisi saat itu. Perubahan nilai tersebut terjadi ketika perusahaan asuransi sedang menentukan nilai-nilai asumsi dan meninjau perancangan produk asuransi. Sehingga, perusahaan terus melakukan analisis dan identifikasi hal tersebut untuk mengupayakan peningkatan kualitas produk

asuransi, menjaga keseimbangan antara profitabilitas dan perolehan manfaat asuransi, serta memastikan keberlanjutan bisnis dengan penyesuaian regulasi yang terus berkembang. Proses perhitungan kelayakan produk asuransi secara metode konvensional dapat dijelaskan melalui contoh perhitungan dari identifikasi kelayakan produk asuransi. Nilai gross premi diperoleh perusahaan sebesar Rp.1.000.000, Lalu terdapat pengajuan gross klaim sebesar Rp.670.280. Jangka waktu polis berlaku selama tiga tahun. Maka selisih antara dua parameter tersebut memperoleh nilai loss ratio sebesar 67,28 %. Sedangkan nilai klaim yang telah diperoleh akan terbagi menjadi tiga tenor yang disesuaikan dengan jangka panjang polis dengan presentase disconto rate sebesar 7%, yaitu  $(223.426 \times (7\% \ 1) + 223.426 \times (7\% \ 2) + 223.426 \times 40 (7\% \ 3))$ . Hasil perhitungan yang memperoleh nilai sebesar Rp. 16.804 yang merupakan nilai disconto rate. Setelah itu nilai gross klaim akan dikurangi dengan nilai disconto rate, Sehingga menghasilkan estimasi nilai klaim dimasa depan adalah Rp. 653.576 dengan nilai loss ratio 65,35%. Sementara itu, nilai expenses diperoleh dari total gross premi sebesar 15%, sehingga menghasilkan nilai Rp. 150.000. Nilai risk adjustment sebesar 6% akan diperoleh dari estimasi nilai klaim sebesar Rp.39.208. Sehingga Contract Service Margin (CSM) diperoleh dari gross premi dikurangi dengan estimasi nilai klaim, expenses, dan risk adjustment diperoleh nilai Rp. 157.216. Dalam proses penentuan kelayakan produk asuransi terdapat beberapa kepastian, yaitu selama nilai klaim tidak lebih dari nilai premi, maka produk tersebut dinyatakan layak untuk dilayani oleh perusahaan. Sedangkan nilai CSM yang diperoleh jika negatif maka, produk tersebut tidak menghasilkan margin keuntungan dan sebaliknya. Dalam contoh perhitungan secara manual diperoleh nilai CSM sebesar Rp. 157.216 sehingga menunjukkan bahwa produk asuransi yang dilayani tersebut layak dan memberikan keuntungan bagi perusahaan. Dalam penggunaan hasil identifikasi kelakan produk dapat memperjelas kelayakan dan profitabilitas produk asuransi, pengembangan model prediktif yang akurat untuk estimasi klaim dan pengelolaan risiko dapat difokuskan

oleh perusahaan, serta tarif premi yang kompetitif berdasarkan analisis loss ratio dapat disesuaikan. Pengendalian biaya operasional juga perlu dioptimalkan. Selain itu, evaluasi secara berkala terhadap asumsi seperti discount rate, expenses, dan risk adjustment perlu dilakukan agar relevansinya dengan kondisi pasar dan regulasi yang berlaku dapat dipastikan. Diversifikasi portofolio produk untuk menjangkau segmen pasar yang lebih luas, inovasi produk berbasis kebutuhan pelanggan, dan peningkatan efisiensi proses underwriting melalui adopsi teknologi juga dapat diterapkan. Dengan strategi ini, daya saing perusahaan diharapkan dapat ditingkatkan, serta keberlanjutan bisnis dalam jangka panjang dapat dipastikan.

#### 4.2 Spesifikasi Kebutuhan Sistem Baru Pengembangan model yang dikembangkan akan digunakan untuk mengidentifikasi kelayakan produk asuransi dalam melihat pengaruh nilai loss ratio dan CSM dalam menilai kelayakan produk asuransi. Pengembangan aplikasi dan 41 model memerlukan spesifikasi sistem yang mencakup proses, data pengguna, dan kebutuhan perangkat lunak ataupun keras.

##### 4.2.1 Spesifikasi Perangkat Lunak

Dalam penelitian ini, perangkat lunak digunakan sebagai alat bantu untuk memfasilitasi proses pengembangan dan penerapan desain perangkat lunak sesuai dengan sistem yang telah dirancang. Sistem operasi, spesifikasi perangkat lunak, dan lingkungan pengembangan termasuk dalam perangkat lunak yang diterapkan. Berikut disajikan spesifikasi perangkat lunak yang digunakan. Lihat Tabel 4.1 Spesifikasi Kebutuhan Perangkat Lunak.

No.	Spesifikasi Kebutuhan Perangkat Lunak
1	Windows 1 (64 Bit) Persyaratan minimum untuk sistem operasi yang harus dipenuhi oleh pengguna.
2	Visual Studio Code Aplikasi editor kode untuk lingkungan utama dalam pengembangan aplikasi dalam penelitian ini.
3	Google Colab Code editor berbasis cloud yang digunakan untuk percobaan, pengembangan, dan pelatihan model.
4	Xampp Aplikasi untuk menjalankan localhost dan menghubungkan koneksi database ke aplikasi.
5	PhpMyAdmin Aplikasi database yang dibangun berbasis web dengan bahasa MySQL.
6	Chrome Perangkat lunak untuk mengakses internet dan menjalankan aplikasi yang telah dikembangkan.

Berdasarkan Tabel 4.1, telah melihatkan

kumpulan kebutuhan perangkat lunak yang dipakai dalam mengembangkan sistem.

Berikut adalah penjelasan lebih terperinci tentang fungsi dari setiap

perangkat lunak sebagai berikut. a) Windows 11 Windows 11 adalah sistem operasi yang digunakan sebagai platform untuk menjalankan berbagai perangkat lunak, seperti Visual Studio Code, Google Colab, XAMPP, dan PhpMyAdmin.

Seluruh perangkat lunak mempunyai fungsi masing- masing dalam proses pengembangan model LSTM untuk mengidentifikasi kelayakan produk asuransi. 42

b) Visual Studio Code Visual Studio Code (VS code) merupakan alat

pengembangan kode sumber yang digunakan untuk menulis, mengedit, dan mengembangkan model untuk mengidentifikasi kelayakan produk asuransi. Kode pemrograman untuk analisis data keuangan, termasuk pemrosesan data dan pemodelan LSTM, bisa ditulis dan diuji menggunakan VS Code. c) Google

Collab Google Collab merupakan platform berbasis cloud yang mendukung pengembangan dan pelatihan model machine learning LSTM untuk mengidentifikasi kelayakan produk. Google Colab menyediakan akses ke GPU

yang mempercepat pelatihan model prediktif, terutama ketika dataset laporan keuangan cukup besar. d) Xamapp Xamapp merupakan perangkat lunak yang digunakan untuk menjalankan server lokal serta mengelola database. XAMPP

memungkinkan pengembangan aplikasi web secara lokal yang menampilkan hasil identifikasi kelayakan produk. e) PhpMyAdmin PhpMyAdmin merupakan aplikasi berbasis website yang digunakan untuk mengatur database MySQL melalui UI

(User Interface). Dalam proyek prediksi loss ratio, PhpMyAdmin

memfasilitasi penyimpanan dan pengelolaan data laporan keuangan perusahaan

dalam database. f) Chrome Chrome merupakan browser web yang dapat

digunakan untuk mengakses berbagai platform berbasis web seperti Google Colab, PhpMyAdm 1

5 n, 1 5 an aplikasi web yang dikembangkan secara lokal menggunakan

XAMPP. Dalam hal memprediksi loss ratio , Chrome bisa digunakan untuk menguji dan menampilkan

n aplikasi yang di-host di server lokal XAMPP. 4.2.2 Spesifikasi

Perangkat Keras Perangkat keras dibutuhkan sebagai komponen fisik yang

mendukung pengoperasian p 1 rangkat lunak dalam perancangan sistem. Dalam

enelitian ini, perangkat keras yang digunakan terdiri dari processor,

penyimpanan, dan memori. Lihat Tabel 4.2 Spesifikasi Perangkat Keras Minimum. 43 Tabel 4. 2 Spesifikasi Perangkat Keras Minimum No. Perangkat Keras Keterangan 1 Processor 1 Ghz atau lebih 2 Storage 128 GB Hard Disk/SSD 3 Memory 4 GB RAM Tabel 4.2, **1** menunjukkan rincian perangkat keras yang dimanfaatkan dalam merancang dan membangun sistem prediksi Loss Ratio untuk suatu produk asuransi. Lihat Tabel 4.3 Spesifikasi Perangkat Keras Peneliti. Tabel 4. 3 Spesifikasi Perangkat Keras Peneliti No. Perangkat Keras Keterangan 1 Processor 2.6 Gz 2 Storage 512 GB SSD 3 Memory 8 GB RAM a) Processor Processor berperan untuk melakukan perhitungan matematis dan hal lainnya yang tercantum dari model LSTM. Processor akan mendukung dengan baik pemrosesan data dan pelatihan model untuk mengidentifikasi kelayakan produk asuransi . b) Storage Storage berperan sebagai tempat penyimpanan data laporan keuangan yang digunakan sebagai dataset dalam melatih model. Kapasitas storage yang baik dapat memungkinkan akses data lebih baik selama tahap pengembangan dan pengujian model. c) Memory Memory berperan untuk menyimpan data sementara yang diperlukan saat pelatihan model. Memori yang cukup mendukung pengolahan data dalam jumlah besar dan mempercepat proses pelatihan serta prediksi. 44 4.2.3 Spesifikasi Kebutuhan Input Pendefinisian kebutuhan input diperlukan sebagai aspek penting dalam proses perancangan dan analisis sistem. Dalam penelitian ini, spesifikasi kebutuhan input sebagai berikut. Lihat Tabel 4.4 Spesifikasi Kebutuhan Input. Tabel 4. 4 Spesifikasi Kebutuhan Input Nama Input Deskripsi Sumber Format Kondisi Username & Pasword Akun yang telah terdaftar di sistem Database Aplikasi Form Input (text/Varchar) Saat Login Pilih TOC Nama-nama Produk asuransi yang akan diprediksi Database Aplikasi Dropdown Pilihan Saat Prediksi Input Dokumen data laporan keuangan perusahaan Data yang ingin diidentifikasi kelayakan produk asuransi Input Pengguna .csv Saat Prediksi Nilai Gross Premi Nilai Gross Premi yang tercatat Input Pengguna Dokumen Saat Prediksi Nilai Gross Klaim Nilai Gross Klaim yang tercatat Input Pengguna Dokumen Saat Prediksi Jangka Periode Polis Berlaku

Jangka Periode Polis yang ditentukan Input Pengguna Dokumen Saat Prediksi Expenses Nilai Expenses yang tercatat Perusahaan Input Pengguna Dokumen Saat Prediksi Disconto Rate Nilai Disconto rate yang tercatat perusahaan Input Pengguna Dokumen Saat Prediksi Risk Adjustment Nilai Risk Adjustment yang ditentukan perusahaan Input Pengguna Dokumen Saat Prediksi Berdasarkan tabel 4.4, menjelaskan tentang spesifikasi kebutuhan input dari sistem yang dirancang. 45 4.2.4 Spesifikasi Kebutuhan Output Pendefinisian kebutuhan output diperlukan sebagai aspek penting dalam proses perancangan dan analisis sistem. Dalam penelitian ini, spesifikasi kebutuhan output adalah hasil yang diharapkan dari sistem yang direncanakan dalam mendukung pengguna mengambil keputusan. Lihat Tabel 4.5 Spesifikasi Kebutuhan Output.

Tabel 4. 5 Spesifikasi Kebutuhan Output

Nama Output	Deskripsi	Format
Date_forecast	Rentang tanggal forecasting	Tabel
Setiap hasil prediksi	Hasil Prediksi Loss Ratio	Hasil loss ratio yang telah diprediksi berdasarkan TOC yang dipilih
Setiap hasil prediksi	Nilai Klaim masa depan	Hasil klaim masa depan yang telah diprediksi berdasarkan TOC yang dipilih
Setiap hasil prediksi	Nilai Expenses, Disconto Rate, Risk adjustment	Nilai Hasil Perhitungan masing-masing faktor pendukung
Setiap hasil prediksi	Contract Service Margin (CSM)	Hasil analisis nilai CSM
Setiap hasil prediksi	Identifikasi Kelayakan Produk	Hasil identifikasi kelayakan bisnis asuransi
Setiap hasil prediksi	RMSE	Hasil akurasi model dalam melakukan prediksi
Setiap hasil prediksi	MAE	Hasil akurasi model dalam melakukan prediksi

46 4.3 Pembuatan Model Diagram 4. 1 Alur Pembuatan Model Diagram 4.1 menjelaskan tentang tahapan-tahapan yang dilalui dalam proses pengembangan model untuk mengidentifikasi kelayakan produk asuransi. Tahapan tersebut meliputi pengumpulan dataset yang berisikan laporan keuangan perusahaan yang berisikan nilai-nilai yang dibutuhkan yaitu gross premi, gross claim, expenses, disconto rate, dan risk adjustment dan nilai lainnya dalam menentukan nilai komponen Contract Service Margin (CSM) untuk diolah dan diidentifikasi kelayakan produknya. Setelah data

terkumpulkan akan dilakukan tahap preprocessing untuk memastikan data layak untuk digunakan. Split data dilakukan untuk menguji kemampuan model machine learning untuk melakukan pembelajaran dan menguji kemampuan model dalam mengenal pola. Setelah dataset terbagi menjadi beberapa bagian, data akan dihitung secara scripted code (kode tertulis) untuk dilakukan perhitungan manual dengan konsep CSM. Perolehan Nilai CSM pada data akan digunakan sebagai nilai input model LSTM dalam mengenal pola sehingga dapat melakukan prediksi kelayakan produk pada masa depan. Ketika Model LSTM telah mampu memprediksi dan mengidentifikasi kelayakan produk akan diuji, jika model mempunyai nilai RMSE dan MAE yang layak. Model akan diuji dengan data pengujian untuk melakukan identifikasi kelayakan produk.

#### 4.3.1 Dataset Diagram 4.2 Alur Perolehan Dataset Diagram 4.2

merepresentasikan alur perolehan dataset yang digunakan dalam model. Alur tersebut dilakukan untuk memperoleh data laporan keuangan perusahaan. Tahapan pertama yaitu mengajukan izin ke perusahaan asuransi swasta yang dijadikan tempat penelitian. Lalu, perusahaan mengetahui tujuan dan maksud dalam penggunaan data laporan keuangan perusahaan. Setelah memperoleh izin dari perusahaan terkait, data tersebut dapat digunakan dalam penelitian. Data laporan keuangan yang diperoleh berasal dari perusahaan. Sumber komponen nilai-nilai data diperoleh dari operasional harian perusahaan. Periode dataset yang diperoleh mempunyai rentang dari tahun 2017 hingga 2023. Berisikan 15.232 baris data yang diperoleh dari setiap transaksi yang berlangsung. Dataset tersebut berisikan komponen yang dibutuhkan yaitu nilai gross premi, gross claim, risk adjustment, disconto rate, expenses, masa berlaku polis, date, TOC\_id.

#### 4.3.2 Preprocessing Data Diagram 4.3

Alur Preprocessing Diagram 4.3 menjelaskan tentang tahap preprocessing data untuk model LSTM dalam mengidentifikasi kelayakan produk asuransi melibatkan beberapa 48 langkah penting. Pertama, data dibaca untuk memastikan format dan struktur sesuai dengan kebutuhan model. Kemudian, outlier ditangani agar data yang ekstrem tidak mengganggu proses pelatihan. Selanjutnya, jangkauan data ditangkap dengan merapikan

distribusinya untuk meningkatkan akurasi interpretasi model. Pola tren yang tidak relevan dihapus agar model fokus pada pola temporal yang signifikan. Selanjutnya, data di scale (normalisasi) untuk memastikan semua fitur memiliki skala yang seragam, memudahkan LSTM dalam memproses data secara efisien dan meningkatkan performa model.

#### 4.3.4 Split Data Diagram

4.4 Pembagian Data (Split Data) Diagram 4.4 merepresentasikan data laporan keuangan yang telah melalui tahap preprocessing dalam penelitian, dilakukan pembagian menjadi tiga susunan komponen pembagian yaitu pelatihan, pengujian, dan pembuktian secara berurut. Pembagian dataset yang berbeda-beda dilakukan untuk melihat kemampuan terbaik model dalam mengolah dataset yang berbeda. Secara garis besar, semakin tinggi ratio data pelatihan, maka model lebih baik dalam mengenal variasi data yang digunakan. Dataset yang telah terbagi menjadi tiga bagian akan dilakukan analisa perolehan nilai CSM secara scripted code (kode tertulis) dengan mengadaptasi konsep CSM.

#### 4.3.3 Menghitung CSM Diagram 4.5 Alur Menghitung CSM Berdasarkan Diagram 4.5

Diagram 4.5 merepresentasikan perhitungan nilai Contractual Service Margin (CSM) dimulai dengan data awal seperti nilai gross premi, gross claim, risk adjustment (6%), discount rate (7%), expenses (15%), jangka masa berlaku polis, tanggal, dan jenis cakupan TOC dari data laporan keuangan. Pertama, dihitung nilai Loss Ratio dengan membandingkan gross claim terhadap gross premi. Selanjutnya, komponen-komponen seperti risk adjustment, discount rate, dan expenses dihitung dan digabungkan untuk menentukan CSM menggunakan rumus yang menyesuaikan nilai premi setelah dikurangi klaim dan biaya terkait. Hasil CSM ini kemudian diakumulasi per bulan berdasarkan tanggal transaksi yang tercatat untuk menghasilkan data CSM bulanan yang digunakan dalam analisis kelayakan produk asuransi.

#### 4.3.5 Training Model Diagram 4.6 Alur Training Model Berdasarkan Diagram 4.6

Diagram 4.6 merepresentasikan hasil perolehan nilai CSM yang terdiri dari komponen nilai disconto rate, nilai klaim masa depan, rasio klaim masa depan, expenses, risk adjustment, nilai CSM, kelayakan produk asuransi, tanggal transaksi, dan TOC. Akan digunakan

sebagai input nilai model LSTM untuk mempelajari dan memprediksi nilai CSM untuk melakukan forecasting dan mengidentifikasi kelayakan produk asuransi dengan menerapkan konsep CSM yang serupa. Setelah model berhasil dilatih, model akan diuji menggunakan indikator RMSE dan MAE, setelah dinyatakan layak model akan disimpan. 4.3.6 Testing Model LSTM 51

Diagram 4. 7 Alur Testing Model LSTM Berdasarkan Diagram 4.7, model yang telah disimpan akan diuji menggunakan data baru yang belum pernah diolah sebelumnya untuk memprediksi nilai CSM. Proses pengujian ini bertujuan untuk menghasilkan prediksi komponen nilai CSM secara akurat serta memberikan analisis terhadap kelayakan produk asuransi. Evaluasi kinerja model dilakukan menggunakan metrik RMSE dan MAE untuk menilai seberapa baik model mempelajari pola data dan meminimalkan kesalahan prediksi, sehingga dapat memastikan model memiliki performa yang andal dalam mengolah data baru. 4.3.7 Sistem Mengidentifikasi Kelayakan Produk Asuransi Diagram 4. 8 Parameter Penentu Kelayakan Berdasarkan Diagram 4.8

Penentuan kelayakan produk asuransi didasarkan pada tiga pertimbangan utama yaitu nilai loss ratio masa depan tidak melebihi 100%, perolehan nilai CSM memiliki hasil positif, dan penetapan nilai CSM pada periode sebelumnya. Ketiga faktor ini digunakan secara bersamaan untuk mengevaluasi dan menentukan apakah sebuah produk asuransi dapat dinyatakan layak atau tidak. 4.4 Perancangan Sistem Proses pengembangan sistem dalam penelitian ini diperlukan perancangan yang terstruktur mengenai hal-hal utama sistem dalam mengidentifikasi kelayakan produk asuransi. Proses enjabaran hal tersebut dapat direpresentasikan dalam bentuk Unified Modelling Language (UML). Representasi hal tersebut dapat berupa flowchart, usecase diagram, activity diagram, dan perancangan database. 52 4.4.1 Flowchart Proses Bisnis Aplikasi Diagram 4. 9 Flowchart Alur Bisnis Aplikasi Berdasarkan Diagram 4.9 Flowchart Penggunaan Aplikasi merepresentasikan rangkaian proses sistem dalam mengidentifikasi kelayakan produk asuransi berdasarkan data laporan keuangan yang telah diunggah oleh pengguna. Tahapan awal yang harus terpenuhi oleh pengguna adalah tipe TOC yang ingin diprediksi. Setelah

kedua hal terpenuhi, selanjutnya sistem mengharuskan user untuk mengunggah data yang akan dilakukan prediksi. Setelah data diunggah dan berhasil diidentifikasi dengan model LSTM sistem akan menyimpan hasil dan dapat dilihat pada aplikasi.

#### 4.4.2 Use Case Diagram

4.10 Usecase Berdasarkan diagram 4.10, mempresentasikan susunan rancangan aplikasi berupa use case diagram untuk sistem dalam mengidentifikasi kelayakan produk asuransi. Pada diagram tersebut telah dijelaskan bahwa User merupakan aktor yang dapat melakukan Login, melakukan identifikasi, dan melihat hasil identifikasi. Adapun penjelasan terperinci mengenai setiap hal-hal yang dijabarkan sebagai berikut. Lihat Tabel 4.6 Skenario Use Case Login.

No	Use Case	Deskripsi
1	49	User melakukan Login
2	45	User melakukan identifikasi
3	14	User melihat hasil identifikasi

53 Tabel 4.6 Skenario Use Case Login

No	Use Case	Deskripsi
1	45	User melakukan Login Aplikasi
2	45	User memasukkan Akun yang telah terdaftar
3	14	User berhasil masuk ke halaman utama

Berdasarkan Tabel 4.6, menggambarkan rangkaian tahapan yang dilakukan pengguna saat menjalankan aplikasi. Akun pengguna yang sudah terdaftar dapat digunakan untuk melakukan login terlebih dahulu. Lihat Tabel 4.7 Skenario Melakukan identifikasi.

No	Use Case	Deskripsi
1	45	User melakukan identifikasi Nama Use Case
2	14	User melakukan identifikasi Aktor User
3	14	User melakukan prediksi loss ratio dari dokumen

Tahapan 1. User masuk ke halaman prediksi setelah login. 2. User memasukkan data yang diperlukan untuk prediksi. 3. Sistem memproses data dan memberikan hasil prediksi. Berdasarkan Tabel 4.7, menggambarkan alur proses yang dilalui pengguna untuk melakukan identifikasi dari data laporan keuangan yang diinput. Setelah itu, sistem akan memproses data tersebut dan menampilkan hasil prediksi dan identifikasi kelayakan produk asuransi. Lihat Tabel 4.8 Skenario Melihat Hasil identifikasi.

No	Use Case	Deskripsi
1	14	User melihat Hasil identifikasi Nama Use Case
2	14	User melihat Hasil Identifikasi Aktor User
3	14	User melihat riwayat hasil identifikasi kelayakan produk

Tahapan 1. User masuk ke halaman hasil prediksi setelah login. 2. User memilih data hasil prediksi tertentu. 3. Sistem menampilkan hasil prediksi kepada user. Berdasarkan Tabel 4.8, melihat hasil prediksi merepresentasikan rangkaian tahapan yang dilakukan pengguna untuk melihat hasil prediksi. Sistem akan

menampilkan hasil prediksi berdasarkan nilai TOC yang diberikan. 54 4.4.3 Flowchart Diagram 4. 11 Flowchart Aplikasi Berdasarkan diagram 4.11, menjelaskan alur keseluruhan proses dari sistem yang direpresentasikan dalam bentuk visual. Proses awal dimulai dengan tampilan halaman login untuk melakukan validasi pengguna. Jika validasi berhasil, sistem menampilkan menu navigasi dan halaman utama dengan beberapa pilihan, yaitu Home, Panduan, Mulai identifikasi, Hasil identifikasi, dan Logout. Pada pilihan Home, pengguna diarahkan kembali ke halaman utama. Jika memilih Panduan, sistem akan menampilkan informasi panduan kepada pengguna. Pada pilihan Mulai identifikasi, pengguna diarahkan ke form input untuk memilih TOC (Type of Coverage) dan mengunggah dokumen yang sesuai. Setelah dokumen diunggah, sistem memvalidasi format file .csv, dan jika valid, proses prediksi dimulai. Pilihan Hasil identifikasi memungkinkan pengguna melihat riwayat identifikasi sebelumnya dengan opsi untuk menampilkan detail hasil. Lalu, jika pengguna memilih Logout, sistem akan keluar dan mengakhiri sesi pengguna. 55 4.4.4 Activity Diagram Diagram 4. 12 Activity Diagram Berdasarkan Diagram 4.12, menjelaskan tentang aktivitas yang terjadi antara objek-objek di dalam aplikasi. Interaksi antar objek meliputi sisi user, sistem, model, database. Interaksi dimulai dari user saat melakukan login ke aplikasi, lalu sistem akan melakukan validasi dan membandingkan kecocokan antara nilai yang tersimpan di dalam database dengan nilai input. Selanjutnya jika nilai cocok maka sistem akan mengarahkan pengguna ke halaman dashboard untuk memilih mulai identifikasi kelayakan produk asuransi. Sistem akan membuka halaman mulai identifikasi dan user akan melengkapi form input. Jika kebutuhan nilai belum terpenuhi, maka user akan diminta untuk mengisi ulang. Selanjutnya jika nilai input sudah diterima maka sistem akan melanjutkan nilai input ke model LSTM untuk melakukan identifikasi kelayakan produk. Setelah berhasil sistem akan menampilkan dan menyimpan hasil. 56 4.4.5 Sequence Diagram Diagram 4. 13 Sequence Diagram Berdasarkan diagram 4.13, merepresentasikan dalam bentuk visual antara User, Sistem, Model, dan Database dalam proses kerja

aplikasi. Tahapan dimulai dengan pengguna melakukan login, yang kemudian divalidasi oleh sistem dengan memeriksa kesesuaian data pengguna di database. Setelah login berhasil, akan menampilkan halaman dashboard yang menampilkan menu navigasi yaitu tata cara pengguna, mulai prediksi, hasil prediksi. Setiap menu navigasi mempunyai interaksi yang berbeda. Saat, pengguna memilih tata cara penggunaan sistem akan menampilkan informasi panduan dari aplikasi. Sedangkan jika pengguna memilih mulai prediksi, sistem akan menampilkan form input, setelah pengguna mengisi kebutuhan input sistem akan melakukan validasi terlebih dahulu sebelum meneruskan pada model prediksi. Setelah proses prediksi berhasil, informasi akan disimpan ke database dan ditampilkan kembali ke sisi pengguna. Lalu, jika 57 pengguna memilih untuk lihat prediksi, sistem akan menampilkan daftar riwayat TOC yang pernah diprediksi. Jika pengguna memilih salah satu daftar, sistem mengirim permintaan ke database untuk kode TOC yang dipilih dan menampilkan detail informasi TOC tersebut kepada pengguna.

4.4.6 Perancangan Database Pembuatan aplikasi memerlukan perancangan database untuk penyimpanan dan pengelolaan data secara terstruktur. Dalam sub bab ini, akan dibahas proses perancangan yang mencakup tabel-tabel database yang diperlukan berdasarkan diagram UML yang telah dijelaskan sebelumnya, guna membangun sistem yang terstruktur. Berikut nama-nama tabel database yang dirancang dalam penelitian ini.

Tabel 4. 9 Rancangan Tabel User

Nama Tabel	user	Nama Field	Tipe data	Hubungan	Keterangan
user_id	INT	Primary Key	ID		yang dibuat secara otomatis berdasarkan data pengguna masuk.
username	VARCHAR	(16)			Nama Pengguna.
password	VARCHAR	(255)			Kata sandi akun pengguna
timestamp	TIMESTAMP				Tanggal akun dibuat

Tabel 4. 10 Rancangan Tabel User Nama

Nama Tabel	user	Nama Field	Tipe data	Hubungan	Keterangan
user_id	INT	Primary Key	ID		yang dibuat secara otomatis berdasarkan data pengguna masuk.
username	VARCHAR	(16)			Nama Pengguna.
password	VARCHAR	(255)			Kata sandi akun pengguna
timestamp	TIMESTAMP				Tanggal akun dibuat

Tabel 4. 11 Rancangan Tabel Loginattempts

Nama Tabel	loginattempts	Nama Field	Tipe
------------	---------------	------------	------

data Hubungan Keterangan attempt\_id INT Primary Key Auto Increment id yang terbuat. 58 user\_id INT Foreign Key ID pengguna yang mencoba login. timestamp\_login Timestamp - Waktu login dicatat status\_log Boolean - Status Login (Berhasil/gagal) Tabel 4. 12 Rancangan Tabel Identifikasi Machine Learning Nama Tabel : dataentry Nama Field Tipe data Hubungan Keterangan Identifikasi\_id INT Primary Key ID unik untuk setiap Identifikasi. toc VARCHAR (255) - Toc\_id (Kode Produk) document VARCHAR(255) - Lokasi file unggahan pengguna. entry\_time TIMESTAMP - Waktu prediksi dilakukan. date\_forecast VARCHAR (255) - Prediksi periode CSM rmse\_lstm VARCHAR (255) - Nilai evaluasi pada hasil prediksi mae\_lstm VARCHAR (255) - Nilai evaluasi pada hasil prediksi nilai\_claim VARCHAR (255) - Nilai claim yang diprediksi nilai\_loss ratio VARCHAR (255) - Nilai loss ratio yang diprediksi nilai\_csm VARCHAR (20) - Nilai csm yang diprediksi kelayakan VARCHAR (20) - Hasil kelayakan 59

4.5 Rancangan Antarmuka Gambar 4. 1 Rancangan Halaman Login Berdasarkan Gambar 4.1, menunjukkan hasil rancangan tampilan awal aplikasi, yang digunakan untuk login. Di bagian tengah, terdapat formulir input yang terdiri dari dua kolom, yaitu kolom untuk username dan kolom untuk password. Pengguna perlu memasukkan informasi login mereka ke dalam form ini dan menekan tombol submit untuk melakukan validasi dan melanjutkan skenario aplikasi yaitu halaman utama. Gambar 4. 2 Rancangan Halaman Utama Berdasarkan Gambar 4.2, menunjukkan tampilan halaman utama setelah pengguna berhasil login. Di sisi kiri, terdapat beberapa tombol navigasi seperti panduan, Mulai Identifikasi, Hasil Identifikasi, dan logout yang memandu 60 pengguna dalam mengakses berbagai fitur aplikasi. Di sisi kanan, terdapat area utama dengan pesan selamat datang dan instruksi bagi pengguna untuk memulai dengan memilih salah satu opsi navigasi Gambar 4. 3 Rancangan Halaman Panduan Berdasarkan Gambar 4.3, gambar tersebut menunjukkan rancangan tampilan halaman yang menjelaskan cara pengguna menjalankan fungsi utama aplikasi. Pada sisi kanan, terdapat penjelasan mengenai rangkaian tahapan yang harus dipenuhi oleh pengguna

sebelum dapat menjalankan aplikasi secara penuh. Penjelasan ini membantu pengguna memahami langkah-langkah yang diperlukan untuk menggunakan aplikasi dengan benar. Gambar 4. 4 Rancangan Halaman Mulai Identifikasi Berdasarkan Gambar 4.4, terdapat form input yang harus diisi oleh pengguna, yaitu rentang tahun prediksi, TOC (Type of Coverage) yang ingin diprediksi, serta unggahan dokumen terkait. Setelah semua data diisi, pengguna dapat memulai prediksi dengan menekan tombol yang tersedia. Di sisi paling kanan, 61 ditampilkan log program machine learning (ML) yang menunjukkan proses prediksi serta hasil analisa dari berjalannya sistem, memberikan informasi mengenai status dan hasil prediksi yang dilakukan. Gambar 4. 5 Rancangan Halaman Hasil Berdasarkan Gambar 4.5 Hasil Identifikasi kelayakan produk asuransi menampilkan hasil identifikasi dan riwayat identifikasi sebelumnya. Informasi yang dicantumkan berisi tanggal, loss ratio, nilai klaim masa depan, nilai expenses, nilai risk adjustment, nilai prediksi CSM, kelayakan produk asuransi, dan Nilai RMSE, dan MAE. Data ditampilkan secara terstruktur memudahkan pengguna untuk memahami hasil identifikasi secara rinci. Selain itu, informasi yang ditampilkan akan membantu pemegang keputusan merancang strategi dan mengidentifikasi kelayakan produk asuransi.

#### 4.6 Skenario Pengujian Dalam penelitian ini,

setelah model mampu melakukan identifikasi kelayakan produk asuransi dari laporan keuangan perusahaan yang berhasil diolah. Sistem akan melalui pengujian yang melibatkan dua pendekatan yaitu Research and Development dan Prototyping. Berikut adalah rincian lebih lanjut terkait skenario uji pada aplikasi.

##### 4.6.1 Pengujian RnD

Skenario pengujian ini dibuat untuk menilai kelayakan model machine learning dalam pemrograman dengan mempertimbangkan input dan output yang sudah direncanakan saat perancangan. Skenario pengujian RnD dapat dilihat pada tabel di bawah ini. Lihat Tabel 4.13 Skenario Pengujian RnD.

62 Tabel 4. 13 Skenario Pengujian RnD

Aspek Deskripsi Tujuan Mengembangkan Model machine learning yang mampu mengidentifikasi kelayakan produk asuransi. Fokus Bagaimana parameter loss ratio, disconto rate, expenses, risk adjustment berpengaruh dalam

menentukan nilai Contract Service Margin (CSM) sebagai indikator dalam mengidentifikasi kelayakan produk asuransi?." Langkah-Langkah Eksplorasi Konsep Meneliti dan mengetahui konsep manual yang telah digunakan perusahaan asuransi dalam menentukan kelayakan produk asuransi. Pengujian Konsep Pengujian konsep disesuaikan dengan alur dan proses manual perusahaan sebelum digunakan sebagai data pembelajaran menggunakan metode LSTM. Evaluasi Konsep Membandingkan performa model yang dikembangkan dengan metode terdahulu. Metrik Evaluasi Performa model dalam mengidentifikasi kelayakan produk asuransi diukur berdasarkan nilai RMSE dan MAE. Contoh Aplikasi Pengembangan aplikasi berbasis website dengan mengintegrasikan model machine learning dalam mengidentifikasi kelayakan produk asuransi. 4.6.2 Pengujian Prototyping Skenario pengujian ini dibuat untuk menilai interaksi antara tampilan antar muka dengan model LSTM dalam pemrograman dengan mempertimbangkan input dan output yang sudah direncanakan saat perancangan. Skenario Prototyping dapat dilihat pada tabel di bawah ini. Lihat Tabel 4.13 Skenario Pengujian Prototyping. 63 Tabel 4. 14 Skenario Pengujian Prototyping Aspek Deskripsi Tujuan Mengembangkan perangkat lunak yang mampu mengidentifikasi kelayakan produk asuransi Fokus Melihat kesesuaian antara kebutuhan pengguna dengan hasil pengembangan perangkat lunak. Langkah-Langkah Pembuatan Prototipe Melakukan pelatihan model berdasarkan data laporan keuangan perusahaan. Pengujian Fungsi Memberikan data input untuk melihat apakah model menghasilkan output yang sesuai ekspektasi. Identifikasi Kelemahan Menganalisis kesalahan model atau kekurangan dalam model. Metrik Evaluasi Waktu yang diperlukan untuk melakukan prediksi melalui user interface. Hasil akurasi luaran aplikasi. Contoh Aplikasi Prediksi kelayakan produk asuransi menggunakan data input untuk menguji arsitektur model LSTM awal dengan user interface. 4.6.3 Pengujian RMSE Skenario pengujian RMSE dirancang untuk mengevaluasi tingkat akurasi model prediksi dengan membandingkan nilai yang diprediksi terhadap nilai aktual yang diharapkan. Rincian lebih lanjut mengenai pengujian ini dan hasil RMSE yang dicantumkan pada tabel di bawah ini. Tabel 4. 15 Pengujian

RMSE No. Ketentuan Hasil Uji 1 Nilai RMSE model kurang dari batas toleransi (<1.0) Sesuai/Tidak Sesuai/diperbaiki 4.6.4 Pengujian MAE

Skenario pengujian MAE dirancang untuk mengevaluasi tingkat akurasi model prediksi dengan membandingkan nilai yang diprediksi terhadap nilai aktual 64 yang diharapkan. Rincian lebih lanjut mengenai pengujian ini dan hasil MAE yang dicantumkan pada tabel di bawah ini. Tabel 4. 16

Pengujian MAE No. Ketentuan Hasil Uji 1 Nilai MAE model kurang dari batas toleransi (<1.0) Sesuai/Tidak Sesuai/diperbaiki 65 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 66 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. 67 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 68 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 Tujuan Mengembangkan Model machine Hasil pengujian menunjukkan learning yang mampu bahwa model machine learning mengidentifikasi kelayakan yang dikembangkan mampu produk asuransi. mengidentifikasi kelayakan Fokus Bagaimana parameter loss ratio, produk asuransi berdasarkan disconto rate, expenses, risk faktor nilai Contract Service adjustment berpengaruh dalam Margin (CSM) dan nilai loss menentukan nilai Contract ratio dengan evaluasi Service Margin (CSM) sebagai menggunakan RMSE dan MAE, indikator dalam mengidentifikasi serta telah berhasil kelayakan produk asuransi?." diimplementasikan dalam perangkat lunak yang Langkah-Langkah memungkinkan prediksi kelayakan produk secara efisien melalui antarmuka pengguna berbasis web. Eksplorasi Konsep Meneliti dan mengetahui konsep manual yang telah digunakan perusahaan asuransi dalam menentukan kelayakan produk asuransi. Pengujian Konsep Pengujian konsep disesuaikan dengan alur dan proses manual 69 perusahaan sebelum digunakan sebagai data pembelajaran menggunakan metode LSTM. Evaluasi Konsep Membandingkan performa model yang dikembangkan dengan metode terdahulu. Metrik Evaluasi Performa model dalam mengidentifikasi kelayakan produk asuransi diukur berdasarkan nilai RMSE dan MAE. Contoh Aplikasi Pengembangan aplikasi berbasis website dengan mengintegrasikan model machine learning dalam mengidentifikasi kelayakan produk asuransi. Tabel 5. 2 Hasil Pengujian Prototyping Aspek Deskripsi Hasil Tujuan 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. Fokus Melihat

kesesuaian antara kebutuhan pengguna dengan hasil pengembangan perangkat lunak. Langkah-Langkah Pembuatan Prototipe Melakukan pelatihan model berdasarkan data laporan keuangan perusahaan. Pengujian Fungsi Memberikan data input untuk melihat apakah model menghasilkan output yang sesuai ekspektasi. Identifikasi Kelemahan Menganalisis kesalahan model atau kekurangan dalam model. Metrik Evaluasi Waktu yang diperlukan untuk melakukan prediksi melalui user interface. Hasil akurasi luaran aplikasi. Contoh Aplikasi Prediksi kelayakan produk asuransi menggunakan data input untuk menguji arsitektur model LSTM awal dengan user interface. Tabel 5. 3 Hasil Pengujian RMSE No. Ketentuan Hasil Uji 1 Nilai RMSE model kurang dari batas toleransi ( $<1.0$ ) Sesuai/Tidak Sesuai/diperbaiki 70 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 71 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 72

Gambar 5.6. menunjukkan hasil perhitungan yang diterapkan secara metode konveksional menggunakan persamaan matematika dan sistem adalah sama. Penerapan metode koveksional 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 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. 73 Tabel 5. 8 Hasil Pelatihan Model Training dan Validasi Perbandingan Nilai aktual dan MAE 74 75 BAB VI PENUTUP Bab ini menyajikan kesimpulan dari penelitian yang telah dilakukan, meliputi ringkasan tujuan penelitian, hasil-hasil yang dicapai, serta kaitannya dengan teori-teori yang telah dibahas pada bab sebelumnya. Selain itu, bab ini juga menyampaikan saran dan rekomendasi untuk pengembangan lebih lanjut berdasarkan temuan yang diperoleh. 6.1 Kesimpulan Berikut adalah kesimpulan penelitian yang dijelaskan secara spesifik, termasuk alasan penelitian dilakukan dan identifikasi masalah yang dihadapi perusahaan: 1. Penelitian ini bertujuan untuk mengembangkan aplikasi web untuk mengidentifikasi kelayakan produk asuransi dari komponen nilai Contract Service Margin (CSM) yang meliputi loss ratio, disconto rate, expenses,

dan risk adjustment. Perolehan nilai loss ratio dan nilai CSM menjadi pertimbangan utama dalam menentukan kelayakan produk asuransi. Faktor lainnya seperti disconto rate, expenses, dan risk adjustment akan mempengaruhi perolehan nilai CSM. 2. Proses identifikasi kelayakan produk asuransi dipengaruhi dari dua parameter yaitu nilai loss ratio dan komponen nilai CSM dalam menentukan kelayakan produk asuransi. Disconto rate, expenses, dan risk adjustment berperan dalam proses analisa perolehan nilai CSM yang menjadi faktor penentu kelayakan produk asuransi. 3. Model Long Short-Term Memory (LSTM) yang dikembangkan menjawab hambatan yang ditemui pada metode konvensional yaitu mengatasi volume data besar, kebutuhan informasi, konsumsi waktu, dan konsumsi teknologi. Model LSTM mampu mempelajari pola dan menganalisa hubungan antara CSM dan loss ratio dalam menentukan kelayakan produk asuransi. 4. Pengembangan model untuk mengidentifikasi kelayakan produk asuransi terdiri dari enam produk dengan perolehan nilai perolehan nilai RMSE dan MAE pada setiap produk (109, 121, 122, 211, 1004, 1006) 76 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). Sehingga nilai akurasi dapat dikatakan cukup baik. Setiap parameter penentu akan digunakan dalam proses analisa perolehan nilai CSM. Model akan menggunakan perolehan komponen nilai CSM sebagai nilai input untuk dipelajari. 5. Metode LSTM mempelajari pola dan hubungan setiap variabel dalam data laporan keuangan yang meliputi perolehan nilai loss ratio dan proses analisis komponen penilaian CSM dalam menentukan identifikasi kelayakan produk asuransi secara prediktif. 6.2 Saran Kesempurnaan dalam penelitian masih perlu ditingkatkan agar hasil penelitian ini dapat diimplementasikan dengan optimal, disarankan untuk melakukan uji coba aplikasi dalam lingkungan operasional nyata guna memastikan kompatibilitas dengan sistem yang sudah ada. Penambahan jumlah data sebagai pelatihan model juga disarankan untuk meningkatkan model dalam mempelajari tren data laporan keuangan untuk mengidentifikasi

REPORT #24703505

kelayakan produk asuransi. Selain itu, penelitian lebih lanjut dapat dilakukan dengan menambahkan variabel lain seperti pengaruh dari regulasi pada perusahaan asuransi sec



REPORT #24703505

## Results

Sources that matched your submitted document.

● IDENTICAL ● CHANGED TEXT

INTERNET SOURCE		
1.	<b>1%</b> eprints.upj.ac.id <a href="https://eprints.upj.ac.id/id/eprint/9126/11/BAB%20IV.pdf">https://eprints.upj.ac.id/id/eprint/9126/11/BAB%20IV.pdf</a>	● ●
INTERNET SOURCE		
2.	<b>0.59%</b> rumahcoding.id <a href="https://rumahcoding.id/belajar/machine-learning-with-python/pengenalan-mac..">https://rumahcoding.id/belajar/machine-learning-with-python/pengenalan-mac..</a>	●
INTERNET SOURCE		
3.	<b>0.45%</b> www.puskomedia.id <a href="https://www.puskomedia.id/blog/penerapan-machine-learning-dalam-pengam...">https://www.puskomedia.id/blog/penerapan-machine-learning-dalam-pengam...</a>	●
INTERNET SOURCE		
4.	<b>0.36%</b> repository.uinjkt.ac.id <a href="https://repository.uinjkt.ac.id/dspace/bitstream/123456789/77128/1/ANNISA%2...">https://repository.uinjkt.ac.id/dspace/bitstream/123456789/77128/1/ANNISA%2...</a>	●
INTERNET SOURCE		
5.	<b>0.35%</b> repository.usbypkp.ac.id <a href="https://repository.usbypkp.ac.id/3720/6/SISTEM%20DETEKSI%20OBJEK%20MA...">https://repository.usbypkp.ac.id/3720/6/SISTEM%20DETEKSI%20OBJEK%20MA...</a>	●
INTERNET SOURCE		
6.	<b>0.35%</b> jurnal.kolibi.org <a href="https://jurnal.kolibi.org/index.php/scientica/article/download/1685/1635/6653">https://jurnal.kolibi.org/index.php/scientica/article/download/1685/1635/6653</a>	●
INTERNET SOURCE		
7.	<b>0.34%</b> algorit.ma <a href="https://algorit.ma/blog/model-machine-learning-2022/">https://algorit.ma/blog/model-machine-learning-2022/</a>	●
INTERNET SOURCE		
8.	<b>0.32%</b> e-journal.uajy.ac.id <a href="https://e-journal.uajy.ac.id/1089/2/1TF05432.pdf">https://e-journal.uajy.ac.id/1089/2/1TF05432.pdf</a>	●
INTERNET SOURCE		
9.	<b>0.3%</b> dqlab.id <a href="https://dqlab.id/apa-itu-machine-learning-model-definisi-and-cara-kerjanya">https://dqlab.id/apa-itu-machine-learning-model-definisi-and-cara-kerjanya</a>	●



REPORT #24703505

INTERNET SOURCE		
10. 0.29%	repository.its.ac.id <a href="https://repository.its.ac.id/79621/1/05111640000127-Undergraduate_Thesis.pdf">https://repository.its.ac.id/79621/1/05111640000127-Undergraduate_Thesis.pdf</a>	●
INTERNET SOURCE		
11. 0.25%	blog.algorit.ma <a href="https://blog.algorit.ma/metrik-mengukur-performa-model-machine-learning/">https://blog.algorit.ma/metrik-mengukur-performa-model-machine-learning/</a>	●
INTERNET SOURCE		
12. 0.24%	www.liputan6.com <a href="https://www.liputan6.com/feeds/read/5830060/memahami-tujuan-akuntansi-fu...">https://www.liputan6.com/feeds/read/5830060/memahami-tujuan-akuntansi-fu...</a>	●
INTERNET SOURCE		
13. 0.21%	ejournal.undiksha.ac.id <a href="https://ejournal.undiksha.ac.id/index.php/janapati/article/download/19139/pdf...">https://ejournal.undiksha.ac.id/index.php/janapati/article/download/19139/pdf...</a>	●
INTERNET SOURCE		
14. 0.21%	repo.unikadelasalle.ac.id <a href="https://repo.unikadelasalle.ac.id/396/4/Bab%20IV.pdf">https://repo.unikadelasalle.ac.id/396/4/Bab%20IV.pdf</a>	●
INTERNET SOURCE		
15. 0.2%	www.gramedia.com <a href="https://www.gramedia.com/literasi/contoh-pendahuluan-makalah-dan-struktur...">https://www.gramedia.com/literasi/contoh-pendahuluan-makalah-dan-struktur...</a>	●
INTERNET SOURCE		
16. 0.19%	scaleocean.com <a href="https://scaleocean.com/id/blog/industri/7-metode-kerja-proyek">https://scaleocean.com/id/blog/industri/7-metode-kerja-proyek</a>	●
INTERNET SOURCE		
17. 0.18%	www.liputan6.com <a href="https://www.liputan6.com/hot/read/5780474/website-adalah-fungsi-contoh-jen...">https://www.liputan6.com/hot/read/5780474/website-adalah-fungsi-contoh-jen...</a>	●
INTERNET SOURCE		
18. 0.17%	eprints.upj.ac.id <a href="https://eprints.upj.ac.id/id/eprint/2730/9/9.%20Bab%20II.pdf">https://eprints.upj.ac.id/id/eprint/2730/9/9.%20Bab%20II.pdf</a>	●
INTERNET SOURCE		
19. 0.17%	publikasi.mercubuana.ac.id <a href="https://publikasi.mercubuana.ac.id/index.php/format/article/download/20178/p..">https://publikasi.mercubuana.ac.id/index.php/format/article/download/20178/p..</a>	●
INTERNET SOURCE		
20. 0.16%	rumahcoding.id <a href="https://rumahcoding.id/blog/memahami-jenis-jenis-machine-learning-supervise..">https://rumahcoding.id/blog/memahami-jenis-jenis-machine-learning-supervise..</a>	●



REPORT #24703505

INTERNET SOURCE		
21.	<b>0.16%</b> <a href="https://ejurnal.politeknikpratama.ac.id">ejurnal.politeknikpratama.ac.id</a> <a href="https://ejurnal.politeknikpratama.ac.id/index.php/JUPRIT/article/download/346..">https://ejurnal.politeknikpratama.ac.id/index.php/JUPRIT/article/download/346..</a>	●
INTERNET SOURCE		
22.	<b>0.16%</b> <a href="https://repository-penerbitlitnus.co.id">repository-penerbitlitnus.co.id</a> <a href="https://repository-penerbitlitnus.co.id/80/1/METODOLOGI%20PENELITIAN%20P...">https://repository-penerbitlitnus.co.id/80/1/METODOLOGI%20PENELITIAN%20P...</a>	●
INTERNET SOURCE		
23.	<b>0.13%</b> <a href="https://hafizmrf3.medium.com">hafizmrf3.medium.com</a> <a href="https://hafizmrf3.medium.com/exploratory-data-analysis-sederhana-pada-data...">https://hafizmrf3.medium.com/exploratory-data-analysis-sederhana-pada-data...</a>	●
INTERNET SOURCE		
24.	<b>0.13%</b> <a href="https://ejurnal.umbima.ac.id">ejurnal.umbima.ac.id</a> <a href="https://ejurnal.umbima.ac.id/index.php/scientific/article/download/231/110/">https://ejurnal.umbima.ac.id/index.php/scientific/article/download/231/110/</a>	●
INTERNET SOURCE		
25.	<b>0.13%</b> <a href="https://etd.umy.ac.id">etd.umy.ac.id</a> <a href="https://etd.umy.ac.id/38510/4/Bab%20I.pdf">https://etd.umy.ac.id/38510/4/Bab%20I.pdf</a>	●
INTERNET SOURCE		
26.	<b>0.13%</b> <a href="https://ejurnal.umri.ac.id">ejurnal.umri.ac.id</a> <a href="https://ejurnal.umri.ac.id/index.php/JIK/article/download/7372/3072/">https://ejurnal.umri.ac.id/index.php/JIK/article/download/7372/3072/</a>	●
INTERNET SOURCE		
27.	<b>0.13%</b> <a href="https://www.hartsimagineering.com">www.hartsimagineering.com</a> <a href="https://www.hartsimagineering.com/design-2022/blog/apa-itu-web-based-softw..">https://www.hartsimagineering.com/design-2022/blog/apa-itu-web-based-softw..</a>	●
INTERNET SOURCE		
28.	<b>0.13%</b> <a href="https://journal.eng.unila.ac.id">journal.eng.unila.ac.id</a> <a href="https://journal.eng.unila.ac.id/index.php/jitet/article/download/2646/1260">https://journal.eng.unila.ac.id/index.php/jitet/article/download/2646/1260</a>	●
INTERNET SOURCE		
29.	<b>0.12%</b> <a href="https://asana.com">asana.com</a> <a href="https://asana.com/id/resources/what-is-a-flowchart">https://asana.com/id/resources/what-is-a-flowchart</a>	●
INTERNET SOURCE		
30.	<b>0.12%</b> <a href="https://media.neliti.com">media.neliti.com</a> <a href="https://media.neliti.com/media/publications/280425-penerapan-metode-sdlc-w...">https://media.neliti.com/media/publications/280425-penerapan-metode-sdlc-w...</a>	●
INTERNET SOURCE		
31.	<b>0.12%</b> <a href="https://www.acerid.com">www.acerid.com</a> <a href="https://www.acerid.com/berita-bisnis/memahami-deep-learning">https://www.acerid.com/berita-bisnis/memahami-deep-learning</a>	●



REPORT #24703505

INTERNET SOURCE		
32.	0.12% <a href="https://ejournal.undip.ac.id">ejournal.undip.ac.id</a> <a href="https://ejournal.undip.ac.id/index.php/jsinbis/article/downloadSuppFile/53127/...">https://ejournal.undip.ac.id/index.php/jsinbis/article/downloadSuppFile/53127/...</a>	●
INTERNET SOURCE		
33.	0.12% <a href="https://eprints.upj.ac.id">eprints.upj.ac.id</a> <a href="https://eprints.upj.ac.id/id/eprint/4088/19/BAB%20III.pdf">https://eprints.upj.ac.id/id/eprint/4088/19/BAB%20III.pdf</a>	●
INTERNET SOURCE		
34.	0.11% <a href="https://jurnal.untan.ac.id">jurnal.untan.ac.id</a> <a href="https://jurnal.untan.ac.id/index.php/justin/article/download/57395/75676598293">https://jurnal.untan.ac.id/index.php/justin/article/download/57395/75676598293</a>	●
INTERNET SOURCE		
35.	0.11% <a href="https://jtsiskom.undip.ac.id">jtsiskom.undip.ac.id</a> <a href="https://jtsiskom.undip.ac.id/article/download/4740/4570">https://jtsiskom.undip.ac.id/article/download/4740/4570</a>	●
INTERNET SOURCE		
36.	0.1% <a href="https://www.academia.edu">www.academia.edu</a> <a href="https://www.academia.edu/38477929/LAPORAN_PRAKTIK_KERJA_LAPANGAN_A..">https://www.academia.edu/38477929/LAPORAN_PRAKTIK_KERJA_LAPANGAN_A..</a>	●
INTERNET SOURCE		
37.	0.1% <a href="https://ejournal.poltekharber.ac.id">ejournal.poltekharber.ac.id</a> <a href="https://ejournal.poltekharber.ac.id/index.php/smartcomp/article/download/716..">https://ejournal.poltekharber.ac.id/index.php/smartcomp/article/download/716..</a>	●
INTERNET SOURCE		
38.	0.1% <a href="https://journal.irpi.or.id">journal.irpi.or.id</a> <a href="https://journal.irpi.or.id/index.php/malcom/article/download/1415/728/7903">https://journal.irpi.or.id/index.php/malcom/article/download/1415/728/7903</a>	●
INTERNET SOURCE		
39.	0.1% <a href="https://asani.co.id">asani.co.id</a> <a href="https://asani.co.id/blog/aplikasi-pengolah-data/">https://asani.co.id/blog/aplikasi-pengolah-data/</a>	●
INTERNET SOURCE		
40.	0.09% <a href="https://danacita.co.id">danacita.co.id</a> <a href="https://danacita.co.id/blog/pengertian-manfaat-dan-keunggulan-library-panda/">https://danacita.co.id/blog/pengertian-manfaat-dan-keunggulan-library-panda/</a>	●
INTERNET SOURCE		
41.	0.09% <a href="https://www.trivusi.web.id">www.trivusi.web.id</a> <a href="https://www.trivusi.web.id/2023/03/perbedaan-mae-mse-rmse-dan-mape.html">https://www.trivusi.web.id/2023/03/perbedaan-mae-mse-rmse-dan-mape.html</a>	●
INTERNET SOURCE		
42.	0.09% <a href="http://eprint.unipma.ac.id">eprint.unipma.ac.id</a> <a href="http://eprint.unipma.ac.id/1805/4/BAB%20II.pdf">http://eprint.unipma.ac.id/1805/4/BAB%20II.pdf</a>	●



REPORT #24703505

INTERNET SOURCE		
43.	0.09% repository.its.ac.id <a href="https://repository.its.ac.id/50538/1/5215201204-Master_Thesis.pdf">https://repository.its.ac.id/50538/1/5215201204-Master_Thesis.pdf</a>	●
INTERNET SOURCE		
44.	0.08% sundayinsurance.co.id <a href="https://sundayinsurance.co.id/id/blog/post/?pid=6234">https://sundayinsurance.co.id/id/blog/post/?pid=6234</a>	●
INTERNET SOURCE		
45.	0.08% eprints.upj.ac.id <a href="https://eprints.upj.ac.id/id/eprint/6420/12/BAB%20IV.pdf">https://eprints.upj.ac.id/id/eprint/6420/12/BAB%20IV.pdf</a>	●
INTERNET SOURCE		
46.	0.07% www.academia.edu <a href="https://www.academia.edu/67708046/Software_Design_Document_SDD_Sistem..">https://www.academia.edu/67708046/Software_Design_Document_SDD_Sistem..</a>	●
INTERNET SOURCE		
47.	0.05% medium.com <a href="https://medium.com/@dhea.larasati326/multivariate-long-short-term-memory-...">https://medium.com/@dhea.larasati326/multivariate-long-short-term-memory-...</a>	●
INTERNET SOURCE		
48.	0.04% library.likmi.ac.id <a href="https://library.likmi.ac.id/show/153/pdf">https://library.likmi.ac.id/show/153/pdf</a>	●
INTERNET SOURCE		
49.	0.03% repository.uin-suska.ac.id <a href="https://repository.uin-suska.ac.id/16085/9/9.%20BAB%20IV_201850SIF.pdf">https://repository.uin-suska.ac.id/16085/9/9.%20BAB%20IV_201850SIF.pdf</a>	●