

BAB I

PENDAHULUAN

1.1 Latar Belakang

PT. Telekomunikasi Selular (Telkomsel) merupakan salah satu penyedia layanan telekomunikasi seluler yang ada di Indonesia. Perusahaan ini merupakan pemimpin pasar industri telekomunikasi di Indonesia yang saat ini sudah melayani lebih dari 159,3 juta pelanggan per tahun 2023 dengan pendapatan Rp102.371 Miliar (Laporan Keberlanjutan Telkomsel, 2023). Perusahaan ini sudah menggelar lebih dari 54.000 infrastruktur *Base Transceiver Station* (BTS) yang menjangkau sekitar 97% wilayah populasi di Indonesia yang dimanfaatkan untuk menghadirkan layanan telekomunikasi yang dapat diakses oleh para penggunanya (Sartika & Rachmat, 2023).

BTS merupakan alat yang berfungsi untuk menempatkan antena pemancar sinyal (jaringan akses) untuk memberikan layanan kepada pelanggan di sekitar tower (Kuswara, 2020). Keandalan dan ketersediaan BTS menjadi faktor utama dalam menjaga kualitas layanan komunikasi, mulai dari panggilan suara hingga akses data. Di tingkat daerah, seperti pada PT. Telkomsel *branch* Padang terkhususnya wilayah Kota Padang dan Kota Solok, stabilitas jaringan menjadi tantangan tersendiri seiring dengan jumlah BTS yang terus bertambah dan penyebarannya yang luas.

Gangguan terhadap jaringan BTS, yang menyebabkan terjadinya *downtime*, dapat menurunkan tingkat *availability* jaringan dan berdampak langsung pada kepuasan pelanggan serta potensi kerugian finansial. *Downtime* BTS dapat berdampak signifikan terhadap kualitas jaringan, menurunkan pengalaman pengguna dalam menggunakan layanan telekomunikasi yang akan berimbas pada timbulnya konsekuensi yang serius pada *potential revenue* perusahaan (Esmariani, 2021). Mantan Menteri Komunikasi dan Informatika, Rudiantara memperkirakan penyedia layanan telekomunikasi seluler memperoleh setidaknya Rp200 Miliar per hari jika BTS aktif sepanjang hari, dan mengalami kerugian hingga Rp100 Miliar apabila BTS mati selama 12 jam di wilayah Jabodetabek (CNN Indonesia, 2019). Selain itu,

gangguan jaringan Telkomsel yang terjadi di Solok Selatan pada 10 Februari 2022 disebabkan oleh kerusakan perangkat BTS menghambat aktivitas warga, termasuk Weni (33), yang kesulitan memasarkan dagangannya secara daring. Telkomsel adalah satu-satunya operator di daerah tersebut dan pemulihan layanan membutuhkan waktu dua hari (Akbar, 2022).

Saat ini, pemantauan performa jaringan BTS dilakukan menggunakan sistem internal *Ericsson Network Integrated Data* (ENID), yang bekerja secara *real-time* dengan melakukan *mirroring* data dari perangkat *baseband* pada BTS. Meskipun sistem ini sudah mendukung visualisasi performa jaringan, pendekatan yang digunakan masih bersifat pasif dan tidak memiliki kemampuan untuk melakukan prediksi atau klasifikasi tingkat risiko gangguan. Selain itu, ENID tidak menyediakan pemantauan berbasis klasifikasi risiko atau fitur analitik lanjutan. Untuk memperoleh informasi terkait performa BTS, petugas harus mengeksport data dari ENID dalam bentuk *file* CSV. Data tersebut kemudian diolah secara manual untuk berbagai keperluan pelaporan dan analisis, yang sering kali memerlukan waktu dan proses tambahan agar informasi yang ditampilkan sesuai kebutuhan pengguna.

Keterbatasan sistem *monitoring* saat ini yang bersifat pasif menunjukkan adanya kesenjangan terhadap kebutuhan akan sistem prediktif yang mampu memberikan peringatan dini atas potensi gangguan jaringan. Hal ini menjadi penting mengingat ketersediaan BTS berperan krusial dalam menjaga kualitas layanan dan pendapatan perusahaan. Permasalahan ini diperkuat oleh beberapa penelitian sebelumnya Miranda et al. (2021), Basikolo & Basikolo (2023), dan Chakraborty et al. (2021), yang menyebutkan bahwa metode tradisional dalam mendeteksi dan pemulihan pada sistem jaringan cenderung lambat dan tidak cukup efektif untuk mencegah gangguan secara proaktif. Kompleksitas sistem jaringan modern menuntut penggunaan metode yang lebih adaptif, salah satunya melalui implementasi model prediktif berbasis data menggunakan algoritma *machine learning*.

Di antara berbagai algoritma *machine learning* untuk membangun model *forecasting*, terdapat *Random Forest* dan *Support Vector Machine* (SVM). Algoritma *Random Forest* cocok digunakan untuk masalah klasifikasi multi kelas dan bekerja dengan baik dengan *dataset* dalam jumlah besar (Adrian et al., 2021) . Algoritma ini juga dapat bekerja dengan baik untuk menangani *dataset* besar dengan banyak fitur dan kompleks, seperti data *availability* jaringan BTS. Sedangkan SVM merupakan algoritma yang memiliki kemampuan untuk menangani data non-linear dan berdimensi tinggi. Namun, SVM memiliki beberapa kekurangan, di antaranya sensitif terhadap pemilihan parameter yang dapat mempengaruhi performa model secara signifikan (Amintoosi, 2025), dan performa SVM cenderung menurun pada *dataset* besar karena kompleksitas komputasi yang tinggi (Khoong, 2021).

Dalam penelitian oleh Nurkhaliza dan Wijayanto, algoritma *Random Forest* memiliki akurasi yang lebih tinggi dibandingkan dengan SVM dalam memprediksi status Indeks Mitigasi dan Kesiapsiagaan Bencana (IMKB) dengan nilai akurasi *Random Forest* sebesar 78,22% dan SVM sebesar 76% (Arumnisa & Wijayanto, 2023) . Pada penelitian yang bertujuan untuk membangun model prediksi *downtime* BTS dengan menggunakan *dataset* yang terdiri dari lebih dari 15.000 *records* dan mencakup fitur yang cukup kompleks seperti nilai ketersediaan jaringan BTS dan pola terjadinya *downtime* secara historis. *Random Forest* dipilih karena mampu menangani data berukuran besar dan kompleks tersebut. Penggunaan algoritma ini diharapkan dapat membantu PT. Telkomsel *branch* Padang dalam mengidentifikasi potensi *downtime* jaringan secara lebih tepat.

Selain memprediksi potensi terjadinya *downtime* jaringan, mengklasifikasikan tingkat risikonya juga penting untuk menentukan prioritas penanganan. Algoritma yang dapat digunakan dalam pengembangan model klasifikasi di antaranya, *Naïve Bayes* dan *K-Nearest Neighbors* (KNN). *Naïve Bayes* merupakan algoritma klasifikasi yang memiliki keunggulan dalam menangani *dataset* dengan asumsi independensi antar fitur atau kasus di mana fitur pada *dataset* saling bebas. Namun, kelemahan algoritma ini disebabkan asumsi tersebut jarang dapat terpenuhi pada kasus nyata dan algoritma *Naïve Bayes* memiliki sensitivitas terhadap data yang tidak

seimbang (Devita et al., 2018). Sementara itu, algoritma KNN mampu menangani data non-linear dan tidak bergantung pada asumsi distribusi data (Acito, 2023). Namun, algoritma ini memiliki kompleksitas komputasi tinggi pada proses klasifikasi karena harus menghitung jarak ke seluruh data pelatihan (Halder et al., 2024).

Penelitian oleh Iqbal et al. (2022) KNN memiliki nilai akurasi sebesar 99,994% dan *Naïve Bayes* sebesar 39,885% dalam mengklasifikasikan serangan jaringan komputer. Oleh karena itu KNN lebih tepat untuk digunakan dalam mengklasifikasikan tingkat risiko *downtime* jaringan karena algoritma ini dapat menangani data tanpa memerlukan independensi fitur, yang lebih sesuai dengan kompleksitas data jaringan. Namun, pemilihan fitur yang relevan dengan penelitian tetap diperlukan untuk mengoptimalkan performa model KNN. Selain itu, berdasarkan penelitian oleh Darryl & Subali (2021) yang membandingkan performa KNN dengan algoritma SVM dalam mengklasifikasikan serangan DDoS dan *benign* pada *dataset* CCIDS, hasilnya menunjukkan bahwa KNN memperoleh *accuracy* sebesar 95,50%, *precision* 99,12%, *recall* 93,84%, dan *F1-score* 96,39%, yang lebih unggul dibandingkan SVM dengan nilai *accuracy* sebesar 90,75%, *precision* 89,33%, *recall* 91,38%, dan *F1-score* 90,27%. Meskipun fokus penelitian tersebut adalah pada deteksi serangan jaringan, kemampuan KNN dalam mengenali pola kompleks dan mencapai nilai evaluasi yang tinggi menunjukkan bahwa KNN juga potensial untuk digunakan dalam klasifikasi tingkat risiko *downtime* jaringan, yang pada dasarnya juga bergantung pada identifikasi pola-pola anomali dan penurunan *availability* jaringan BTS.

Mengintegrasikan model prediksi dan klasifikasi tersebut ke dalam *dashboard* dengan *Business Intelligence* menawarkan pendekatan yang lebih efektif untuk memahami pola dan tren gangguan melalui visualisasi interaktif. Berdasarkan beberapa penelitian sebelumnya, seperti penelitian oleh Miranda et al. (2021) dan Stiawan et al. (2022) yang menyatakan implementasi *Business Intelligence Dashboard* mempermudah pengambilan keputusan dengan memberikan tampilan informasi yang terintegrasi secara *real-time*, memungkinkan manajemen untuk membuat keputusan yang tepat dengan akurasi mencapai 88% yang dapat digunakan

untuk proses identifikasi *downtime* yang lebih cepat. Salah satu *framework open-source* yang dapat digunakan untuk membuat *Business Intelligence Dashboard* adalah *Streamlit*. *Framework* ini memungkinkan pembuatan visualisasi data dan integrasi model *machine learning* secara cepat dan interaktif menggunakan bahasa pemrograman Python, tanpa memerlukan pengetahuan tentang HTML, CSS, atau JavaScript.

Berdasarkan uraian tersebut, penelitian ini mengusulkan pengembangan *dashboard business intelligence* yang terintegrasi dengan model prediksi dan klasifikasi. Penelitian ini mengusung judul “Implementasi *Business Intelligence* untuk Prediksi dan Klasifikasi *Downtime* Jaringan pada Tower Base Transceiver Station PT. Telkomsel Branch Padang Berbasis *Random Forest* dan *K-Nearest Neighbors*”, dengan tujuan untuk membangun sistem yang mampu mengidentifikasi potensi gangguan jaringan secara proaktif, mengelompokkan BTS berdasarkan tingkat risiko *downtime*, serta menyajikan informasi strategis dalam bentuk visualisasi interaktif. Sistem ini diharapkan dapat meningkatkan efisiensi proses *monitoring*, mempercepat pengambilan keputusan, serta mengurangi risiko *downtime* yang berdampak pada kualitas layanan dan pendapatan perusahaan.

1.2 Rumusan Masalah

Berdasarkan latar belakang permasalahan yang sudah diuraikan, dapat dirumuskan permasalahan dalam penelitian ini adalah bagaimana mengimplementasikan *Business Intelligence* untuk prediksi potensi dan klasifikasi tingkat risiko *downtime* jaringan pada BTS PT. Telkomsel Branch Padang berbasis *Random Forest* dan *K-Nearest Neighbors*, serta menyajikannya dalam bentuk visualisasi interaktif melalui *Streamlit* guna meningkatkan efisiensi proses *monitoring*, mempercepat pengambilan keputusan, dan mengurangi risiko *downtime* yang berdampak pada kualitas layanan serta pendapatan perusahaan?