

BAB I PENDAHULUAN

1.1. Latar Belakang

Listrik adalah salah satu kebutuhan dasar yang sangat penting bagi kehidupan manusia. Kebutuhan akan listrik sudah seperti menjadi kebutuhan dasar manusia. Keunggulan ekonomisnya menjadikan listrik dapat mendukung berbagai macam aktivitas manusia, mulai dari kebutuhan rumah tangga hingga industri. Selain itu, listrik juga memainkan peran penting dalam mendukung perkembangan teknologi yang semakin inovatif. Proyeksi masa depan menunjukkan bahwa permintaan akan energi listrik akan terus meningkat seiring dengan pertumbuhan penduduk dan inovasi teknologi. Peningkatan ini tidak hanya dipicu oleh kebutuhan dasar, tetapi juga oleh meningkatnya standar hidup yang semakin tinggi. Oleh karena itu perencanaan dan pengelolaan sumber daya listrik yang efisien dan andal menjadi penting untuk memenuhi kebutuhan energi yang terus berkembang.

Gangguan pada sistem tenaga listrik merupakan tantangan besar dalam menjaga keandalan energi listrik. Sistem tenaga listrik yang andal sudah menjadi kebutuhan utama bagi kelangsungan aktivitas ekonomi masyarakat. Namun, gangguan pada sistem tenaga listrik dapat terjadi di mana saja dan kapan saja. Pada jaringan transmisi sering kali menghadapi berbagai macam gangguan yang dapat mengganggu pasokan tenaga listrik seperti sambaran petir, hubung singkat (*short circuit*), gangguan isolasi, serta interferensi elektromagnetik lainnya [1]. Gangguan-gangguan ini dapat menyebabkan kerusakan pada peralatan listrik dan juga dapat menurunkan stabilitas sistem secara keseluruhan.

Untuk mengatasi permasalahan tersebut maka dibutuhkan alat yang dapat merekam serta memberitahukan secara *real time* tentang status maupun anomali yang terjadi di lapangan. Penggunaan alat perekam gangguan seperti *Disturbance Fault Recorder* (DFR) menjadi sangat penting. DFR merupakan alat yang dapat merekam data dalam besaran arus dan tegangan secara *real time* sebelum, selama, dan setelah terjadinya gangguan [2]. Kategori data yang direkam oleh DFR adalah data *transient* dan *swing record*. Data *transient* digunakan untuk menganalisis gangguan cepat seperti petir, kegagalan isolator, dan *switching*. Data *swing record*

merekam respons dinamis sistem selama perubahan beban, ayunan daya, dan fluktuasi tegangan [3].

DFR banyak digunakan oleh sektor utilitas karena menawarkan peluang yang baik untuk analisis interferensi gangguan pada sistem tenaga listrik [4]. Data yang dihasilkan oleh DFR sangat penting untuk analisis lebih lanjut, karena dari data ini dapat diketahui penyebab utama spesifik dari setiap gangguan, serta menentukan lokasi gangguan dengan akurasi tinggi. Proses klasifikasi data dari DFR sering kali menghadapi tantangan besar. Kompleksitas data yang tinggi, volume data yang besar, serta kebutuhan akan metode analisis yang cepat dan akurat menjadi kendala utama dalam pengolahan data gangguan.

Pada beberapa tahun terakhir, perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*) telah membuka kesempatan baru dalam pengolahan data. Metode yang berbasis jaringan saraf tiruan, khususnya *Recurrent Neural Network* (RNN) telah terbukti efektif menangani data sekuensial yang dihasilkan oleh DFR [5]. *Recurrent Neural Network* (RNN) merupakan salah satu model kecerdasan buatan yang memang dirancang untuk mengolah data berurutan atau *time-series*, seperti data yang dihasilkan oleh DFR. RNN memiliki kemampuan untuk menangkap pola temporal dan hubungan antar data dalam suatu urutan waktu, yang menjadikannya untuk klasifikasi data gangguan pada sistem tenaga listrik yang direkam oleh DFR. RNN bekerja berdasarkan mekanisme umpan balik, yang memungkinkan sistem belajar dari data sebelumnya untuk memengaruhi keputusan [6].

Namun RNN mempunyai masalah utama yaitu *gradien vanishing*, hal ini menyebabkan pembelajaran model menjadi sangat lambat atau bahkan dapat berhenti. Masalah ini muncul disebabkan oleh gradien yang dihitung oleh model dapat mengecil seiring dengan banyaknya data [7]. Untuk mengatasi masalah ini, *Long Short-Term Memory* (LSTM) dirancang untuk mengatasi masalah *gradien vanishing* dan memungkinkan model untuk memproses data sekuensial dengan memori jangka panjang. LSTM unggul dalam mengenali pola yang tidak teratur, asimetris dan bersifat intermiten seperti data yang dikeluarkan oleh DFR [7].

Akan tetapi data keluaran dari DFR sering kali terdapat *noise*, tidak teratur dan

tidak lengkap. Jika data ini langsung digunakan oleh LSTM, model akan mengalami kesulitan untuk mengenali pola dan juga hubungan temporal, sehingga efek dari hal tersebut dapat mengurangi akurasi dan efektivitas model. Sebelum data DFR dapat diolah menggunakan LSTM, diperlukan tahapan pra-pemrosesan untuk memastikan bahwa data dalam kondisi optimal. *Akima Interpolation* digunakan untuk mengisi kekosongan data atau memperbaiki ketidakteraturan dalam sinyal. *Akima Interpolation* memiliki kelebihan yaitu tahan terhadap *noise* dengan menghasilkan sinyal yang lebih konsisten dan menghindari osilasi yang tidak wajar. Hal ini memungkinkan *akima interpolation* untuk mendekomposisi sinyal non linear dengan lebih akurat [8].

Pada penelitian ini bertujuan untuk mengembangkan model yang mengintegrasikan antara *akima interpolation* dan *long short-term memory* untuk mengklasifikasi gangguan pada data DFR. Kombinasi ini diharapkan dapat memberikan dampak peningkatan akurasi serta percepatan proses analisis gangguan. Pada penelitian ini *akima interpolation* digunakan untuk memperbaiki representasi data sinyal tegangan dan arus yang direkam oleh DFR, sehingga data yang dihasilkan dapat terhindar dari osilasi dan *noise* yang tidak diinginkan [8]. Kemudian, RNN digunakan sebagai alat klasifikasi yang unggul dalam memahami pola temporal. RNN, khususnya *Long Short-Term Memory* (LSTM) memiliki kemampuan untuk mempelajari hubungan jangka panjang dalam data yang dinamis dan kompleks.

Pendekatan ini menawarkan solusi yang lebih adaptif dalam menghadapi variasi jenis dan karakteristik gangguan, tetapi juga lebih efisien dalam hal pemrosesan data [4]. Pengembangan dan implementasi sistem ini memerlukan pemahaman yang mendalam tentang masalah yang dihadapi dengan teknik yang sesuai [2]. Pada penelitian ini dilakukan pemodelan *akima interpolation* dan *long short-term memory* pada data *disturbance fault recorder*. Pada tiap gangguan yang terjadi pada sistem transmisi tenaga listrik mempunyai karakteristiknya masing-masing, maka metode tersebut digunakan untuk mengklasifikasikan jenis gangguan atau anomali yang terjadi pada sistem tenaga listrik sehingga dapat mempercepat analisis serta penanganan perbaikan yang dibutuhkan.

Penelitian ini melibatkan beberapa tahap, mulai dengan studi literatur, kemudian pengumpulan data gangguan DFR dari ULTG Cigereleng. Data tersebut dilakukan pra-pemrosesan menggunakan *Akima Interpolation* untuk menghaluskan dan mengurangi *noise*. Selanjutnya model LSTM dilatih dan diuji menggunakan data yang telah diolah. Kinerja akhir dari model dievaluasi berdasarkan metrik seperti akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix* untuk mengukur performa klasifikasinya.

1.2. Tinjauan Peneliti Terdahulu

Dalam memeriksa penelitian sebelumnya untuk memvalidasi validitas penelitian yang dilakukan dan membantu meningkatkan literasi diskusi, Tabel 1.1 merupakan cantuman referensi utama dengan penelitian terkait.

Tabel 1. 1 Rujukan Utama.

No.	Judul	Peneliti	Tahun
1.	<i>LSTM Recurrent Neural Network Classifier for High Impedance Fault Detection in Solar PV Integrated Power System [7].</i>	Veerapandiyan Veerasamy, dkk	2021
2.	<i>Analisa Disturbance Fault Recorder (DFR) Sebagai Alat Perekam Anomali Pada Gardu Induk Rangka Baru [2].</i>	Desmira, Ahmad Denny Listiyawan	2021
3.	<i>Pemodelan Hybrid Decomposition Neural Network Untuk Klasifikasi Gangguan Sistem Tenaga Listrik Pada Disturbance Fault Recorder (DFR) [4].</i>	At-Thariq Ramadhan, Unit Three Kartini	2023
4.	<i>A New Approach to Empirical Mode Decomposition Based on Akima Spline Interpolation Model [8].</i>	Muhamad Ali, dkk	2024

Penelitian [7] menggunakan metode RNN yang berbasis LSTM untuk mengklasifikasikan dalam pendeteksian HIF pada model 13 bus IEEE yang terintegrasi dengan PV surya 300 kW. Pemodelan yang dilakukan adalah ketika

konduktor listrik menyentuh permukaan dengan resistansi yang tinggi parameter yang divariasikan adalah V_p , V_n , R_n , R_p . Pada penelitian ini dilakukan *Discrete Wavelet Transform* (DWT). Penggunaan DWT dimaksudkan sebagai langkah pra-pemrosesan sebelum klasifikasi sinyal. DWT dapat berfungsi memecah sinyal asli menjadi komponen frekuensi yang berbeda, hal ini memungkinkan analisis sinyal pada beberapa level frekuensi. DWT juga dapat mengurangi *noise* dalam sinyal. Setelah dilakukan pra-pemrosesan, sinyal dapat diklasifikasikan dengan model. Pada penelitian ini model yang digunakan adalah LSTM, KNN J48, SVM, dan NB. Namun di antara kelima model tersebut LSTM yang paling unggul. LSTM memiliki *data error rate* hanya sebesar 8,79%. LSTM unggul dalam mengenali pola yang tidak teratur, asimetris dan bersifat *intermiten* seperti sinyal arus dan tegangan.

Penelitian [2] mengamati dan menganalisis penggunaan DFR sebagai alat perekam gangguan atau anomali yang merekam besaran arus dan tegangan. Metode yang dilakukan yaitu observasi, wawancara dan pengambilan data yang berkaitan dengan DFR. DFR yang dilakukan analisa adalah Qualitrol IDM+. DFR merekam data sebelum, pada saat terjadi dan sesudah gangguan. Pada penelitian ini didapatkan data sebelum dan pada saat terjadi. Pada data ini menunjukkan bahwa DFR dapat merekam data dengan baik ketika terjadi anomali atau gangguan. Data ini juga menunjukkan bahwa ketika tidak ada gangguan sinyal yang dihasilkan adalah sinyal sinusoidal sempurna, dan ketika terjadi gangguan maka sinyal tersebut tidak stabil dan harus dianalisis kesalahan apa yang terjadi. Data selanjutnya adalah data pada saat dan setelah gangguan. Pada data ini menunjukkan sinyal yang berangsur-angsur stabil ketika gangguan tersebut sudah berhasil diperbaiki. Selanjutnya DFR perlu dilakukan pengaturan toleransi agar DFR dapat memberikan alarm sebagai tanda peringatan gangguan. Pada DFR Qualitrol IDM+ toleransi batas bawah 80% dan batas atas 120%.

Penelitian [4] mengatakan bahwa alat DFR merekam bentuk gelombang tegangan sampel dari sinyal arus, status relai dan besaran digital lainnya yang berkaitan dengan gardu induk, Data yang diperoleh dari DFR dianalisis dan diklasifikasikan penyebab terjadinya anomali yang dimodelkan dengan *hybrid decomposition neural network* atau jaringan syaraf terurai. Sistem ini memecah

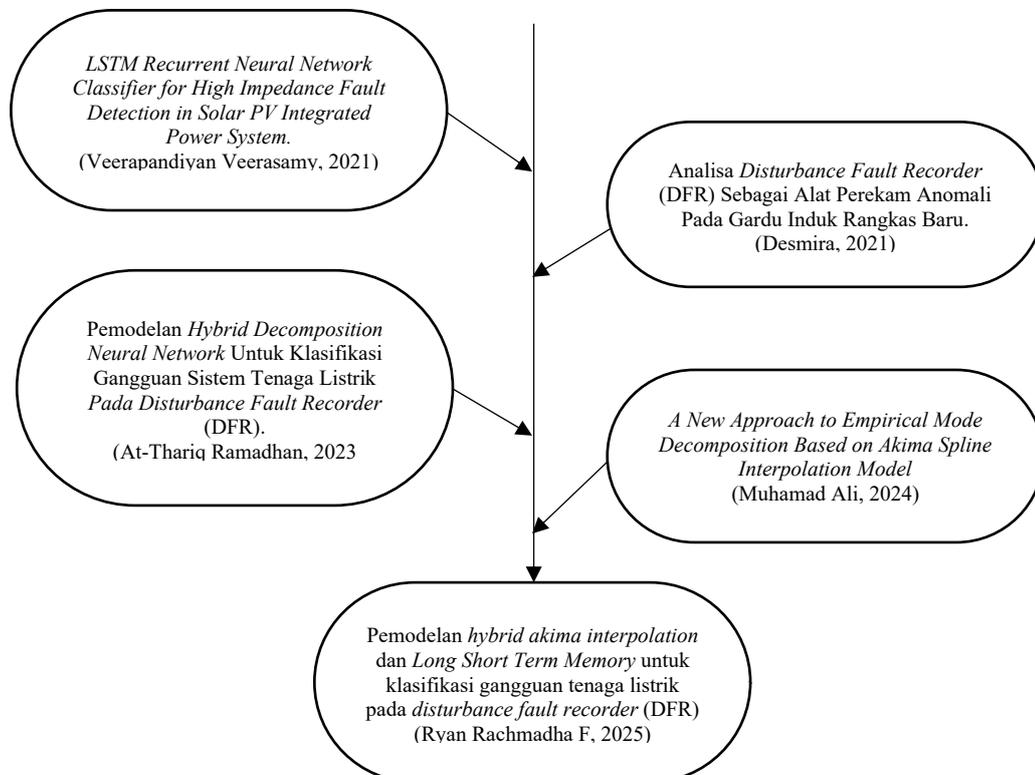
masalah yang rumit menjadi masalah-masalah kecil yang sederhana agar model dapat mempelajari data penyebab gangguan. Untuk melakukan pemodelan dekomposisi yaitu mengatur parameter masukan untuk jaringan. Setelah parameter tersebut diatur maka selanjutnya adalah pembagian data *train*, *test* dan *validation*. Pada penelitian ini 80% digunakan sebagai data latih dan 20% data digunakan sebagai data uji. Pemodelan ini menghasilkan data latih yang memiliki akurasi 0,83 dan nilai *loss* sebesar 0,46. Hasil dari penelitian ini menunjukkan bahwa metode *decomposition neural network* cocok digunakan untuk klasifikasi gangguan yang direkam oleh DFR.

Penelitian [8] menunjukkan bahwa *akima spline interpolation* memiliki ketahanan terhadap *noise* yang baik, stabilitas pada batas data serta hasil dekomposisi yang lebih akurat. Pada penelitian mereka, *akima spline interpolation* lebih mampu menangani data yang tidak teratur bahkan terdapat *noise* yang tinggi. Perbandingan yang dilakukan adalah dengan metode EMD yang konvensional. Terdapat berbagai macam metode EMD yang dibandingkan yaitu, *Empirical Mode Decomposition* (EMD), *Ensemble Empirical Mode Decomposition* (EEMD), *Statistical Empirical Mode Decomposition* (SEMD), *Complementary Ensemble Empirical Mode Decomposition With Adaptive Noise* (CEEMDAN), *Variational Mode Decomposition* (VMD). Setelah dilakukan simulasi kemudian dibandingkan menggunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MEA), dan *Mean Absolute Percentage Error* (MAPE) menunjukkan bahwa *akima spline interpolation* jauh lebih unggul dibandingkan dengan metode EMD konvensional. Hal ini semakin memperkuat argumen bahwa *akima spline interpolation* memastikan bahwa data yang digunakan untuk pelatihan dan pengujian model tidak hanya akurat namun juga representasi dari kondisi nyata yang terdapat di lapangan.

Penelitian ini memiliki kesamaan dengan kajian sebelumnya dalam penerapan *machine learning* dan metode dekomposisi untuk klasifikasi gangguan pada sistem tenaga listrik. Sebuah penelitian sebelumnya juga menggunakan LSTM untuk mendeteksi gangguan, namun dengan metode *Discrete Wavelet Transform* (DWT) untuk *High Impedance Fault* (HIF) [7], sedangkan penelitian ini menggunakan Interpolasi Akima untuk data DFR. Penggunaan DFR sebagai alat utama

pengumpulan data juga relevan dengan penelitian lain di bidang ini [2]. Selain itu, studi perbandingan telah menunjukkan bahwa *preprocessing Akima* memiliki keunggulan dalam menangani *noise* [8]. Konsep penting lainnya yang diadopsi dari riset terdahulu adalah proses dekomposisi sinyal untuk menyederhanakan analisis [4].

Penelitian *akima interpolation* dan LSTM menggabungkan dua konsep yang belum pernah dilakukan sebelumnya. Melalui pendekatan ini, data hasil rekaman gangguan DFR dapat diolah lebih akurat dengan *akima interpolation* dalam menstabilkan sinyal yang tidak beraturan serta keunggulan LSTM dalam klasifikasi data adalah dapat menangkap pola sekuensial yang cocok untuk data keluaran DFR. Elemen kebaruan terletak pada sinergi kedua konsep tersebut yang belum banyak dibahas dalam studi-studi terdahulu, sehingga mampu menghasilkan pemodelan yang lebih andal untuk mendeteksi dan mengklasifikasikan gangguan listrik. Gambar 1.1 merupakan hubungan penelitian yang dibuat berdasarkan kesempatan yang telah diberikan kepada peneliti.



Gambar 1. 1 Hubungan Penelitian.

1.3. Rumusan Masalah

Berdasarkan latar belakang permasalahan yang telah dijelaskan, rumusan masalah yang diangkat pada penelitian ini adalah :

1. Bagaimana mengimplementasikan *preprocessing Akima Intepolation* dan model *Long Short-Term Memory* (LSTM) untuk klasifikasi gangguan tenaga listrik menggunakan data yang direkam oleh DFR?
2. Bagaimana kinerja *preprocessing Akima Intepolation* dan model *Long Short-Term Memory* (LSTM) dalam klasifikasi gangguan tenaga listrik menggunakan data yang direkam oleh DFR?

1.4. Tujuan dan Manfaat

1.4.1. Tujuan

Berdasarkan rumusan masalah yang telah dijabarkan, tujuan dari penelitian ini adalah sebagai berikut :

1. Mengimplementasikan *preprocessing Akima Interpolation* dan model *Long Short-Term Memory* (LSTM) untuk klasifikasi gangguan tenaga listrik data yang direkam oleh DFR .
2. Menganalisis kinerja *preprocessing Akima Interpolation* dan model *Long Short-Term Memory* (LSTM) dalam mengklasifikasikan gangguan tenaga listrik berdasarkan data yang direkam oleh DFR.

1.4.2. Manfaat

Pada penelitian ini diharapkan dapat memperoleh manfaat berupa :

1. Manfaat Akademis

Secara akademis, penelitian ini diharapkan dapat membantu perkembangan ilmu pengetahuan di bidang pemrosesan sinyal, interpolasi data, dan penerapan pembelajaran mesin, khususnya dalam sistem tenaga listrik. Selain itu, penelitian ini dapat berfungsi sebagai referensi ilmiah tentang bagaimana *preprocessing Akima Intepolation* dan model *Long Short-Term Memory* (LSTM) diintegrasikan untuk mengklasifikasikan gangguan tenaga listrik. Ini dapat digunakan sebagai referensi untuk penelitian lebih lanjut. Penelitian ini juga meningkatkan pemahaman kita

tentang bagaimana menggunakan data pencatat gangguan (DFR) sebagai sumber informasi untuk analisis dan klasifikasi gangguan yang akurat.

2. Manfaat Praktis

Secara praktis, temuan penelitian ini dapat membantu industri tenaga listrik, seperti PLN, meningkatkan efisiensi, akurasi, dan kecepatan dalam menemukan dan mengklasifikasikan gangguan jaringan. Dengan menggunakan pendekatan berbasis teknologi cerdas, penelitian ini menawarkan solusi untuk meningkatkan sistem pengawasan dan analisis gangguan jaringan. Sistem ini dapat diterapkan pada jaringan listrik pintar, atau *smart grid*. Selain itu, manfaat praktis ini juga dirasakan oleh masyarakat karena dapat membantu mengurangi efek gangguan sistem tenaga listrik, seperti pemadaman listrik, dengan mempercepat proses pemulihan dan meningkatkan keandalan sistem tenaga listrik.

1.5. Batasan Masalah

Pada penelitian ini, untuk memastikan fokus penelitian yang jelas dan terukur, batasan masalah yang ditetapkan adalah sebagai berikut :

1. Data rekaman : Penelitian ini hanya menggunakan data rekaman gangguan yang diperoleh dari alat *Disturbance Fault Recorder (DFR) ULTG* Cigereleng. Data yang digunakan meliputi parameter arus, tegangan dan frekuensi pada kondisi sebelum, sesaat, dan sesudah gangguan.
2. Jenis gangguan : Penelitian ini hanya mengklasifikasikan dua jenis gangguan utama, yaitu gangguan dikarenakan petir dan gangguan benda lain.
3. Metode Pemodelan : Penelitian ini mengintegrasikan *preprocessing Akima Interpolation* dan model *Long Short Term Memory (LSTM)* sebagai pendekatan untuk meningkatkan akurasi dan efisiensi klasifikasi. Penelitian ini tidak membandingkan sistem ini dengan lainnya secara mendalam.
4. Cakupan evaluasi : Evaluasi kinerja model dilakukan berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score*. Penelitian ini tidak membahas secara mendalam tentang aspek implementasi perangkat keras atau integrasi

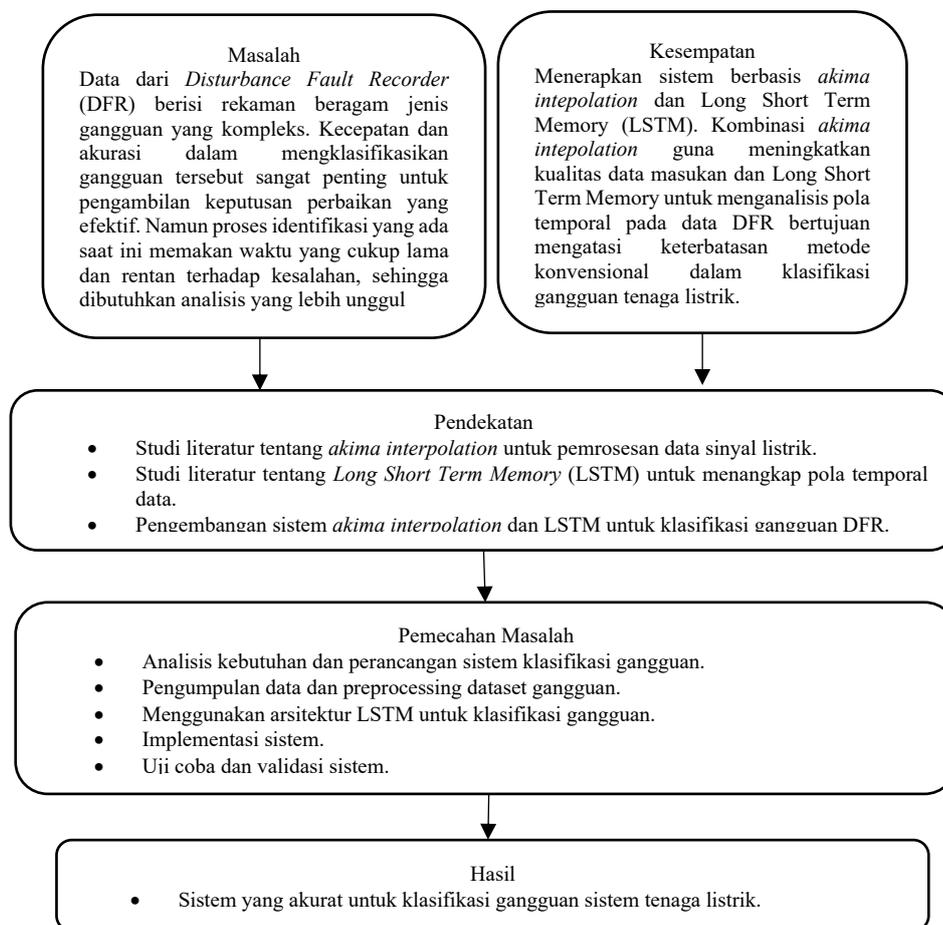
sistem secara penuh ke dalam lingkungan operasional industri.

5. *User Interface* : Penelitian ini berfokus pada pemodelan *preprocessing akima interpolation* dan model *Long Short-Term Memory (LSTM)* untuk klasifikasi gangguan tenaga listrik. Pada penelitian ini penulis tidak berfokus mengembangkan aspek antarmuka pengguna, melainkan lebih mengutamakan pengembangan model saja.

1.6. Kerangka Berpikir

Kerangka berpikir adalah suatu alur logis yang menggambarkan hubungan antara konsep-konsep atau variabel yang diteliti, berdasarkan teori atau penelitian terdahulu. Kerangka ini membantu peneliti merumuskan hipotesis atau asumsi dasar yang ingin diuji, serta menunjukkan bagaimana penelitian dilakukan untuk mencapai tujuan yang ditetapkan. Dengan adanya kerangka berpikir, peneliti dapat memastikan bahwa penelitian berjalan sistematis dan fokus pada masalah yang telah dirumuskan. Hal ini menjadi landasan dalam melakukan penulisan ilmiah. Oleh karena itu, dalam menguraikan gagasan-gagasan penelitian, dikembangkan suatu kerangka berpikir. Pada tugas akhir ditunjukkan pada Gambar 1.2.





Gambar 1. 2 Kerangka Berpikir.

1.7. Sistematika Penulisan

Tugas akhir harus ditulis secara metodis dan disusun dalam enam bab, setiap bab mempunyai beberapa subbab. Bab-bab tersebut adalah sebagai berikut:

BAB I PENDAHULUAN

Bab ini berupa pendahuluan menjelaskan mengenai permasalahan berupa latar belakang, penelitian terdahulu, rumusan masalah, tujuan, manfaat akademis dan praktis, batasan masalah, kerangka berpikir dan sistematika penulisan.

BAB II TEORI DASAR

Bab ini memberikan landasan teoretis terkait topik penelitian, yaitu sistem tenaga listrik, teori dasar tentang *Disturbance Fault Recorder* (DFR), dan survei literatur mengenai *preprocessing akima interpolation* serta model *Long Short-Term Memory* (LSTM) Pembahasan juga mencakup jenis gangguan tenaga listrik, seperti

gangguan petir dan hubungan pendek, serta bagaimana pengintegrasian *preprocessing akima intepolation* dan LSTM dapat meningkatkan akurasi klasifikasi data gangguan pada sistem tenaga listrik.

BAB III METODOLOGI

Bab ini menjelaskan metode dan jadwal penelitian yang meliputi tahap-tahap penelitian, seperti pengumpulan data dari rekaman DFR, penggunaan *preprocessing Akima Intepolation* untuk memperbaiki kualitas data, pelatihan *Long Short-Term Memory* untuk klasifikasi gangguan, dan evaluasi kinerja model. Selain itu, bab ini juga menjelaskan teknik pengukuran, analisis data, dan jadwal pelaksanaan penelitian hingga mencapai tujuan penelitian.

BAB IV PERANCANGAN DAN IMPLEMENTASI

Bab ini menjelaskan proses perancangan sistem secara detail, mulai dari perancangan sistem, pra-prosesing data, mengklasifikasikan gangguan, hingga integrasi keseluruhan sistem menggunakan *Akima Interpolation* dan *Long Short-Term Memory*.

BAB V PENGUJIAN DAN ANALISIS

Bab ini memaparkan hasil pengujian dengan berbagai skenario yang telah divariasikan untuk mendapatkan model yang terbaik. Pada bab ini hasil pengujian tersebut dianalisis dan dibandingkan antara model yang menggunakan *Akima Interpolation* dan tidak.

BAB VI PENUTUP

Bab ini berisi kesimpulan dari model yang digunakan serta saran untuk pengembangan lebih lanjut di masa mendatang.