

**PREDIKSI NILAI SUSUT ENERGI LISTRIK PADA PT
PLN (PERSERO) ULP BANGKINANG
MENGUNAKAN METODE MACHINE LEARNING
PROPHET**

LAPORAN TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana S1 Pada
Prodi Teknik Elektro Universitas Islam Sultan Agung



Oleh :

NAMA : RADHITYO GUMELAR

NIM : 30602200223

**PROGRAM STUDI S1 TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG
SEMARANG**

2025

FINAL PROJECT

PREDIKSI NILAI SUSUT ENERGI LISTRIK PADA PT PLN (PERSERO) ULP BANGKINANG MENGGUNAKAN METODE MACHINE LEARNING PROPHET

*Suggested As One of the Requirements to Get a Bachelor's Degree in a Study Program
Electrical Engineering at Universitas Islam Sultan Agung.*



Arranged By :

RADHITYO GUMELAR

30602200223

ELECTRICAL ENGINEERING STUDY PROGRAM

FACULTY OF INDUSTRIAL TECHNOLOGY

UNIVERSITAS ISLAM SULTAN AGUNG

SEMARANG

2025

LEMBAR PENGESAHAN PEMBIMBING

Laporan Tugas Akhir dengan judul **“PREDIKSI NILAI SUSUT ENERGI LISTRIK PADA PT PLN (PERSERO) ULP BANGKINANG MENGGUNAKAN METODE MACHINE LEARNING PROPHET”** ini disusun oleh:

Nama : RADHITYO GUMELAR
NIM : 30602200223
Program Studi : Teknik Elektro

Telah disahkan dan disetujui oleh dosen pembimbing pada:

Hari : Jumat
Tanggal : 23 Mei 2025

Pembimbing


Jenny Putri Hapsari, S.T., M.T.
NIDN : 0607018501

Mengetahui,

Ka. Program Studi Teknik Elektro


Jenny Putri Hapsari, S.T., M.T.
NIDN : 0607018501

LEMBAR PENGESAHAN PENGUJI

Laporan Tugas Akhir dengan judul “**PREDIKSI NILAI SUSUT ENERGI LISTRIK PADA PT PLN (PERSERO) ULP BANGKINANG MENGGUNAKAN METODE MACHINE LEARNING PROPHET**” ini telah dipertahankan di depan Penguji sidang Tugas Akhir pada:

Hari : Rabu

Tanggal : 25 Juni 2025

Tim Penguji

Tanda Tangan

Dr. Gunawan, S.T., M.T.

NIDN : 0607117101

Ketua Penguji I

Dr. Bustanul Arifin, S.T., M.T.

NIDN : 0614117701

Penguji II

Jenny Putri Hapsari, S.T., M.T.

NIDN : 0607018501

Penguji III

SURAT PERNYATAAN

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini:

Nama : Radhityo Gumelar

NIM : 30602200223

Fakultas : Teknik Industri

Program Studi : Teknik Elektro

Dengan ini menyatakan bahwa Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) **Teknik Elektro di Fakultas Teknologi UNISSULA Semarang** dengan judul **“PREDIKSI NILAI SUSUT ENERGI LISTRIK PADA PT PLN (PERSERO) ULP BANGKINANG MENGGUNAKAN METODE MACHINE LEARNING PROPHET”**, adalah asli (orisinal) dan bukan menjiplak (plagiat) dan belum pernah diterbitkan/dipublikasikan dimanapun dalam bentuk apapun baik sebagian atau keseluruhan, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab. Apabila di kemudian hari ternyata terbukti bahwa Karya Tugas Akhir tersebut adalah hasil karya orang lain atau pihak lain, maka saya bersedia dikenakan sanksi akademis.

Semarang, Selasa, 25 Agustus 2025

Yang Menyatakan

Mahasiswa



RADHITYO GUMELAR

NIM. 30602200223

PERNYATAAN PERSETUJUAN UNGGAH KARYA ILMIAH

Saya yang bertanda tangan di bawah ini :

Nama : Radhityo Gumelar

NIM : 30602200223

Program Studi : Teknik Elektro

Fakultas : Teknik Industri

Dengan ini menyerahkan karya ilmiah berupa Tugas Akhir/Skripsi/Tesis/Disertasi* dengan judul :

PREDIKSI NILAI SUSUT ENERGI LISTRIK PADA PT PLN (PERSERO) ULP BANGKINANG
MENGUNAKAN METODE MACHINE LEARNING PROPHET

dan menyetujuinya menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak Bebas Royalti Non-eksklusif untuk disimpan, dialihmediakan, dikelola dalam pangkalan data, dan dipublikasikannya di internet atau media lain untuk kepentingan akademis selama tetap mencantumkan nama penulis sebagai pemilik Hak Cipta.

Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan pihak Universitas Islam Sultan Agung.

Semarang, 21 Agustus 2025

Yang menyatakan,

Radhityo Gumelar

*Coret yang tidak perlu

KATA PENGANTAR



Alhamdulillah, segala puji syukur bagi Allah subhanahu wa ta'ala karena atas berkat rahmat dan hidayah-Nya sehingga saya masih berkesempatan dalam menuntut ilmu dalam keadaan sehat wal'afiat, kemudian Shalawat serta Salam semoga senantiasa tercurahkan kepada baginda Rasulullah Muhammad shallallahu 'alaihi wa sallam, semoga kelak kita mendapatkan syafaatnya. Aamiin Yaa Robbaalalamin.

Penelitian ini diajukan sebagai salah satu syarat untuk menyelesaikan studi Strata Satu (S1) di Fakultas Teknologi Industri, Universitas Islam Sultan Agung Semarang. Dalam penyusunan penelitian ini, pastinya banyak pihak yang sudah memberikan bantuan baik moral dan material. Oleh karena itu saya menyampaikan ucapan Jazakumullah Khoiron dan terima kasih kepada:


1. Bapak Prof. Dr. H. Gunarto, SH., M.Hum. selaku Rektor Universitas Islam Sultan Agung Semarang.
2. Ibu Dr. Ir. Novi Mariyana, ST., MT., IPU., ASEAN, Eng. selaku Dekan Fakultas Teknologi Industri, Universitas Islam Sultan Agung Semarang.
3. Ibu Jenny Putri Hapsari, ST., MT. selaku Ketua Jurusan Teknik Elektro, Fakultas Teknologi Industri, Universitas Islam Sultan Agung Semarang dan selaku Dosen Pembimbing yang dengan penuh kesabaran dan kebijaksanaan telah memberikan bimbingan, arahan, dan motivasi dalam penyusunan penelitian hingga selesai.
4. Seluruh Dosen jurusan Teknik Elektro, Universitas Islam Sultan Agung Semarang yang telah memberikan ilmu, wawasan, dan arahan selama masa perkuliahan. Serta seluruh Staff Teknik Elektro yang selalu siap membantu dalam berbagai urusan administratif dan teknis selama masa perkuliahan.
5. Bapak, Ibu serta Saudara-saudara saya tercinta atas dukungan kepada saya berupa kasih sayang, keridhoan, doa, dan motivasi yang telah diberikan.

6. Teman-teman seperjuangan yang telah memberikan dukungan moral, semangat, serta saran dan kritik yang membangun. Kebersamaan dan kerja sama kalian sangat membantu dalam menjalani perkuliahan.
7. Semua pihak yang telah memberikan bantuan hingga selesainya penelitian ini yang tidak dapat disebutkan satu per satu oleh penulis.


Semarang, 24 Januari 2025

Penulis,

Penulis



Radhityo Gumelar



ABSTRAK


Efisiensi distribusi energi listrik merupakan salah satu tantangan utama bagi PT PLN (Persero), khususnya dalam mengurangi nilai susut energi listrik yang terjadi selama proses distribusi. Penelitian ini bertujuan untuk mengembangkan model prediksi nilai susut energi listrik di PLN ULP Bangkinang menggunakan metode machine learning Prophet. Metode ini dirancang untuk menganalisis data deret waktu dengan pola kompleks, termasuk tren dan musiman, yang umumnya terjadi dalam distribusi energi. Data susut energi dari tahun 2018 hingga 2024 digunakan sebagai dataset penelitian. Proses pengembangan model melibatkan pengumpulan data susut energi bulanan, preprocessing, pelatihan model dengan optimasi hyperparameter menggunakan Optuna, dan evaluasi kinerja model menggunakan metrik Mean Squared Error (MSE) dan R^2 Score. Hasil pengujian menunjukkan bahwa metode Prophet memiliki kinerja terbaik dengan nilai MSE sebesar 0.0054 dan R^2 sebesar 0.68785 dibandingkan dengan metode pembandingan lainnya, seperti ARIMA, SARIMA, dan LSTM. Temuan ini menunjukkan bahwa metode Prophet mampu memprediksi nilai susut energi secara akurat meskipun dengan dataset yang terbatas. Penelitian ini memberikan kontribusi dalam mengidentifikasi pola susut energi secara dini dan mendukung pengambilan keputusan berbasis data untuk meningkatkan efisiensi operasional PLN. Implementasi model ini diharapkan dapat meminimalkan kerugian energi listrik dan meningkatkan kualitas layanan kepada pelanggan.



DAFTAR ISI

KATA PENGANTAR	iii
ABSTRAK	vii
DAFTAR ISI	viii
DAFTAR TABEL	x
DAFTAR GAMBAR	xi
BAB I PENDAHULUAN	5
1.1. Latar belakang	5
1.2. Rumusan Masalah	7
1.3. Batasan Masalah	8
1.4. Tujuan Penelitian	8
1.5. Manfaat Penelitian	9
1.6. Sistematika Penelitian	9
BAB II TINJAUAN PUSTAKA DAN LANDASAN TEORI	11
2.1 Tinjauan Pustaka	11
2.2 Dasar Teori	12
2.2.1 PLN ULP Bangkinang	12
2.2.2 Profil data Aset ULP Bangkinang	12
2.2.3 Susut Energi Listrik	13
2.2.4 <i>Machine Learning</i>	17
2.2.5 Prediksi Menggunakan <i>Machine Learning</i>	18
2.2.6 Metode PROPHET	18
2.2.7 Metode Arima	20
2.2.8 Metode SARIMA	20
2.2.9 Metode LSTM	20
2.2.10 MSE (<i>mean squared error</i>)	21
2.2.11 R^2 Score	21
2.2.12 OPTUNA	22
BAB III METODOLOGI PENELITIAN	18
3.1 Model Penelitian Perancangan	18
3.2 Parameter Penelitian	19
3.3 Metode dan Rancangan Penelitian	19
3.4 Teknik Pengumpulan Data	20

3.4.1	Alat yang Digunakan	20
3.4.2	Pengukuran	21
3.5	Teknik Analisa data.....	21
3.6	Komparasi Prediksi Menggunakan Metode Lain	21
BAB IV HASIL DAN ANALISA		18
4.1	Hasil	18
4.1.1	Perhitungan PLN.....	20
4.1.2	Pengujian Prediksi Nilai Susut dengan Metode PROPHET	21
4.1.3	Pengujian dengan Metode ARIMA	23
4.1.4	Pengujian dengan Metode SARIMA	25
4.1.5	Pengujian dengan metode LSTM	27
4.2	Pembahasan.....	29
4.2.1	Rekap Keseluruhan Pengujian dan Perbandingan Metode ...	29
BAB V KESIMPULAN DAN SARAN.....		18
5.1	Kesimpulan.....	18
5.2	Saran.....	19
DAFTAR PUSTAKA		45



DAFTAR TABEL

Tabel 3. 1 Data Susut PLN ULP Bangkinang	19
Tabel 3. 2 Tabel Alat dan Bahan yang Digunakan	20
Tabel 3. 3 Tabel Hasil	21
Tabel 3. 4 Perbandingan Metode	21



DAFTAR GAMBAR

Gambar 2. 1 Flowchart PROPHET Model [20]	19
Gambar 2. 2 Arsitektur Metode ARIMA[21]	20
Gambar 2. 4 Arsitektur LSTM[25]	21
Gambar 3. 1 Flowchart Sistem Kerja.....	18
Gambar 3. 2 Diagram Blok Rancangan Penelitian	19
Gambar 3. 3 Proses Prediksi Susut Energi Listrik.....	20
Gambar 4. 1 Hasil Plot Data Nilai Susut Original.....	20
Gambar 4. 2 Grafik Perbandingan Prediksi dan Aktual Nilai Susut Metode PROPHET	23
Gambar 4. 3 Grafik Perbandingan Prediksi dan Aktual <i>Nilai Susut</i> Metode ARIMA	25
Gambar 4. 4 Grafik Perbandingan Prediksi dan Aktual Nilai Susut Metode SARIMA	27
Gambar 4. 5 Grafik Perbandingan Prediksi dan Aktual Nilai Susut Metode LSTM	29
Gambar 4. 6 Grafik Perbandingan MSE	30
Gambar 4. 7 Grafik Perbandingan R^2 Score	30
Gambar 4. 8 Grafik Prediksi Nilai Susut	32

BAB I

PENDAHULUAN

1.1. Latar belakang

Permasalahan susut energi listrik telah menjadi isu penting dalam operasional Perusahaan Listrik Negara (PLN), terutama karena berdampak langsung pada efisiensi distribusi dan kerugian energi nasional. Susut energi, yang mencakup susut teknis dan non-teknis, merupakan selisih antara energi listrik yang disalurkan dan yang tercatat sebagai penjualan. Menurut Kementerian Energi dan Sumber Daya Mineral (ESDM), tingkat susut energi listrik nasional pada tahun-tahun terakhir masih berada di atas batas ideal yang ditetapkan, yaitu sekitar 8–9%, sementara standar internasional menyarankan angka di bawah 6% [1].

PLN (Perusahaan Listrik Negara) adalah perusahaan milik negara Indonesia yang bergerak di bidang penyediaan energi listrik. Sebagai perusahaan BUMN, PLN bertanggung jawab untuk menghasilkan, mengelola, dan mendistribusikan listrik ke seluruh wilayah Indonesia. Misinya adalah menyediakan layanan listrik yang handal, efisien, dan terjangkau untuk mendukung pertumbuhan ekonomi serta kesejahteraan masyarakat. PLN juga berperan penting dalam pengembangan energi terbarukan dan perluasan akses listrik di daerah-daerah terpencil di Indonesia [2]. Salah satu indikator kinerja distribusi listrik adalah nilai susut energi, yaitu selisih antara energi listrik yang diproduksi dengan energi yang diterima oleh konsumen. Susut energi ini dapat disebabkan oleh berbagai faktor, baik teknis maupun non-teknis, seperti kerugian pada jaringan distribusi, pencurian listrik, maupun kesalahan pencatatan meteran [3].

Susut energi listrik merujuk pada selisih antara jumlah energi listrik yang diproduksi oleh pembangkit listrik dengan jumlah energi listrik yang sampai ke konsumen akhir. Susut ini merupakan kehilangan energi di sepanjang proses transmisi dan distribusi listrik. Susut energi listrik, baik teknis maupun non-teknis, adalah masalah serius yang harus dikelola secara efektif untuk menjaga efisiensi distribusi energi [4]. Susut energi pada PLN yang disebabkan oleh resistansi kabel, kehilangan pada transformator, dan faktor lingkungan. Energi listrik yang mengalir melalui kabel mengalami perubahan bentuk menjadi panas karena resistansi,

sedangkan transformator yang menaikkan atau menurunkan tegangan juga mengalami kerugian [5]. Dampak negatif dari susut energi ini sangat luas, mencakup aspek ekonomi, teknis, sosial, dan lingkungan. Dengan upaya untuk meminimalkan susut energi, PLN dapat meningkatkan kinerja operasionalnya, mengurangi biaya, dan memberikan pelayanan yang lebih baik kepada pelanggan. Dalam konteks inilah, pentingnya pengembangan model prediksi yang akurat, seperti melalui *machine learning* menjadi sangat relevan untuk mengidentifikasi tren susut dan mengambil tindakan pencegahan yang tepat dengan proses yang ringan.

Di PLN ULP (Unit Layanan Pelanggan) Bangkinang, seperti di banyak unit layanan lain, masalah susut energi listrik masih menjadi perhatian serius karena dapat berdampak signifikan terhadap kinerja operasional dan keuangan perusahaan. Susut energi yang tinggi akan menurunkan efisiensi distribusi listrik dan meningkatkan biaya operasional. Pada perhitungan susut, adapun anomali susut yang bisa dihasilkan pada perhitungan susut energi listriknya, yang notabene dipengaruhi oleh hal teknis, maupun dipengaruhi fenomena-fenomena yang tidak terprediksi, seperti pola penggunaan listrik oleh pelanggan. Oleh karena itu, diperlukan upaya untuk memahami pola susut energi ini dan mengembangkan model prediksi yang akurat agar langkah-langkah preventif dan korektif dapat diambil secara efektif untuk menghasilkan perhitungan dengan tingkat akurasi sebaik mungkin.

Seiring dengan kemajuan teknologi dan pemanfaatan data, metode prediksi berbasis kecerdasan buatan (*Artificial Intelligence/AI*) semakin banyak digunakan dalam berbagai bidang, termasuk energi. Penggunaan AI dalam deteksi susut energi pada PLN menawarkan keunggulan berupa kecepatan dan akurasi yang lebih tinggi dalam mendeteksi masalah, baik teknis maupun non-teknis seperti pencurian listrik. AI memungkinkan pemeliharaan prediktif, analisis data real-time, serta peningkatan efisiensi operasional dengan mengotomatisasi proses pemantauan. Selain itu, AI membantu mengurangi biaya operasional dan meningkatkan keamanan jaringan listrik dengan deteksi dini terhadap potensi gangguan atau aktivitas ilegal. Semua ini berkontribusi pada peningkatan keandalan dan efisiensi sistem distribusi listrik [6]. Salah satu metode yang potensial untuk diterapkan

dalam prediksi nilai susut energi listrik adalah metode *machine learning*. Salah satu machine learning yang cocok untuk prediksi adalah metode PROPHET dirancang khusus untuk menangani data berurutan dengan pola jangka panjang dan mampu digunakan untuk *real time*, sehingga cocok untuk memprediksi nilai susut energi listrik yang memiliki karakteristik time series atau berurutan dari waktu ke waktu namun mampu menganalisa data yang sedikit ataupun banyak [7].

Adapun ,metode yang sering digunakan pada pengujian regresi prediksi, yaitu: Regresi Linier, ARIMA, Random Forest, LSTM[8] dan SVM [9]. Pada penelitian ini memiliki kendala pada data susut yang masih diambil secara manual dan setiap 1 bulan 1 kali, hasil susut ini mengakibatkan penanganan yang kurang karena pengambilan dan pengujian susut yang tidak sering, sehingga nilai susut harian baik itu susut teknis yang disebabkan kesalahan pada sistem transmisi atau trafo, atau pada susut non teknis yang disebabkan human error seperti pencurian listrik. Sehingga *machine learning* diperlukan untuk membuat sistem prediksi yang kemudian bisa lebih sering membaca jika terjadinya susut sehingga penanggulangan akan lebih cepat.

Dengan menggunakan metode *machine learning* pada metode PROPHET, diharapkan dapat diperoleh model prediksi yang lebih akurat dibandingkan dengan metode tradisional dan dengan hasil prediksi susut yang sesuai pada pengujian tradisional, sehingga memungkinkan PLN ULP Bangkinang untuk mengidentifikasi tren susut energi lebih dini dan mengambil tindakan mitigasi yang tepat. Penerapan metode ini juga dapat membantu dalam proses pengambilan keputusan berbasis data yang lebih baik, guna meningkatkan efisiensi distribusi energi dan mengurangi kerugian yang dialami PLN.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model prediksi nilai susut energi listrik pada PLN ULP Bangkinang dengan menggunakan metode PROPHET, serta mengevaluasi performa model dalam memberikan prediksi yang akurat. Penelitian ini juga diharapkan dapat memberikan kontribusi bagi upaya peningkatan efisiensi distribusi listrik di PLN secara keseluruhan.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan diatas, maka dapat diambil perumusan masalah sebagai berikut:

1. Seberapa akurat metode PROPHET dalam memprediksi nilai susut energi listrik di periode-periode waktu tertentu dibandingkan dengan metode ARIMA, SARIMA, dan LSTM?
2. Bagaimana optimasi parameter pada metode PROPHET dapat meningkatkan akurasi prediksi susut energi listrik pada PLN ULP Bangkinang?
3. Seberapa besar selisih antara nilai susut aktual dan hasil prediksi pada setiap metode, serta kapan perbedaan terbesar terjadi?

1.3. Batasan Masalah

Batasan masalah dalam tugas akhir ini adalah sebagai berikut:

- a. Metode yang digunakan pada prediksi susut energi hanya menggunakan metode PROPHET
- b. Bahasa yang digunakan untuk memprediksi susut energi pada PT PLN ULP Bangkinang hanya menggunakan bahasa pemrograman python.
- c. Data berasal dari database PT PLN ULP Bangkinang.
- d. Penelitian ini difokuskan untuk memprediksi susut di periode waktu kedepan.

1.4. Tujuan Penelitian

Tujuan penelitian ini adalah:

- a. Menganalisa dan menguji kemampuan metode PROPHET dalam memprediksi nilai susut energi listrik dibandingkan dengan metode prediksi lainnya.
- b. Memaparkan dampak dan hasil penerapan metode PROPHET dapat dioptimalkan untuk meningkatkan akurasi prediksi susut energi listrik pada PLN ULP Bangkinang.
- c. Menjelaskan dan membandingkan nilai susut aktual dan hasil prediksi, beserta tampilan pada bulan perbedaan terbesar yang terjadi.

1.5. Manfaat Penelitian

Manfaat penelitian ini adalah sebagai berikut:

- a. Dengan memprediksi susut energi secara akurat, PLN ULP Bangkinang dapat mengidentifikasi dan mengatasi area dengan kerugian energi tinggi, sehingga meningkatkan efisiensi operasional dan mengurangi pemborosan energi.
- b. Dengan mengurangi susut energi, perusahaan dapat menghemat biaya operasional yang terkait dengan kerugian energi dan perawatan infrastruktur.
- c. Menjadi dasar pertimbangan rencana perbaikan susut untuk membantu PLN dalam menyediakan pasokan listrik yang lebih stabil dan andal bagi konsumen, meningkatkan kualitas layanan dan kepuasan pelanggan.
- d. Meningkatkan kapabilitas dan akurasi pembacaan pemakaian pelanggan.
- e. Meningkatkan upaya perbaikan kinerja susut distribusi.
- f. Penelitian ini dapat membuka jalan bagi penerapan metode analisis canggih dalam manajemen energi, mendorong inovasi dan adopsi teknologi baru di sektor kelistrikan.

1.6. Sistematika Penelitian

Sistematika penulisan dari penelitian ini adalah sebagai berikut:

BAB I PENDAHULUAN

Bab ini berisi latar belakang penelitian, rumusan masalah, tujuan penelitian, batasan masalah, manfaat penelitian, dan sistematika penulisan.

BAB II TINJAUAN PUSTAKA DAN LANDASAN TEORI

Bab ini berisi teori-teori dan penelitian terdahulu yang relevan dengan topik penelitian.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan metode yang digunakan dalam penelitian, termasuk alat dan bahan, serta prosedur penelitian.

BAB IV HASIL DAN ANALISA

Melakukan perhitungan dan prediksi nilai susut energi listrik dengan metode PROPHET. Melakukan perbandingan data dengan metode lain untuk mendapatkan hasil prediksi yang tepat dan dengan melihat kemampuan metode PROPHET dalam menganalisa nilai susut dengan parameter evaluasi.

BAB V PENUTUP

Berisi kesimpulan dan saran dari hasil penelitian.



BAB II

TINJAUAN PUSTAKA DAN LANDASAN TEORI

2.1 Tinjauan Pustaka

Dalam upaya meningkatkan efisiensi dan keandalan sistem tenaga listrik, berbagai penelitian telah dilakukan untuk mendeteksi dan meminimalisasi kerugian energi, baik yang bersifat teknis maupun non-teknis. Syahtriatna et al. [11] mengkaji pencurian tenaga listrik pada PT PLN (Persero) Panam dengan pendekatan klasifikasi menggunakan algoritma Naïve Bayes. Algoritma ini terbukti mampu mengklasifikasikan pelanggan ke dalam kategori sasaran operasi, penyimpangan, dan normal secara lebih akurat dibandingkan metode lain seperti K-Means. Hasil analisis terhadap 50 pelanggan menunjukkan efektivitas metode ini dalam mendukung operasional P2TL dan pengurangan pencurian listrik. Sejalan dengan itu, Surusa et al. [14] memanfaatkan teknologi *Automatic Meter Reading* (AMR) untuk menganalisis susut non-teknis pada pelanggan potensial. Studi kasus di Kota Gorontalo menunjukkan kerugian energi signifikan akibat kerusakan *Current Transformer*, dan AMR terbukti efektif dalam mempercepat deteksi serta penormalan sistem.

Pendekatan prediktif berbasis *machine learning* dan *deep learning* juga banyak digunakan untuk menganalisis kerugian energi dan kerusakan peralatan listrik. Mahendra et al. [1] menerapkan kombinasi Fuzzy Logic dan Feed Forward Neural Network (F-FFNN) untuk peramalan susut energi jangka pendek pada jaringan distribusi tegangan rendah. Hasilnya menunjukkan akurasi tinggi dalam estimasi susut energi, yang berguna dalam perencanaan teknis guna meminimalkan kerugian. Sementara itu, Novian dan Kartini [15] menggunakan model Long Short-Term Memory (LSTM) dalam meramalkan susut umur transformator di Gardu Induk 150 kV Buduran. Model ini menghasilkan prediksi yang sangat akurat, dengan MSE sebesar 0,0002 dan RMSE sebesar 0,014, memperkuat potensi implementasi LSTM dalam perencanaan pemeliharaan preventif berbasis data historis operasional.

Dalam konteks yang lebih kompleks, penerapan metode kecerdasan buatan juga diterapkan pada disipasi energi di sistem hidrolik dan diagnosis kecelakaan nuklir. Nouri et al. [12] membandingkan efektivitas berbagai metode AI seperti stochastic M5P dan *random forest* terhadap model regresi dalam memprediksi kehilangan energi pada aliran skimming di spillway bertingkat. Stochastic M5P menunjukkan hasil terbaik dengan sensitivitas tinggi terhadap parameter kemiringan spillway. Di sisi lain, She et al. [13] mengembangkan model hybrid berbasis CNN, LSTM, dan ConvLSTM untuk diagnosis dan prediksi kejadian *Loss of Coolant Accidents* (LOCA) di PLTN. Model ConvLSTM mampu mengekstraksi fitur data multivariat dan deret waktu secara efektif, sementara kombinasi CNN+LSTM menunjukkan performa unggul dalam prediksi pasca-kecelakaan,

memberikan kontribusi signifikan terhadap sistem tanggap darurat dan pengambilan keputusan berbasis kecerdasan buatan.

2.2 Dasar Teori

2.2.1 PLN ULP Bangkinang

Sistem kelistrikan di Provinsi Riau saat ini didukung oleh 9 Gardu Induk (GI) 150 kV, yaitu Koto Panjang, Bangkinang, Garuda Sakti, Teluk Lembu, Duri, Dumai, Bagan Batu, Teluk Kuantan, dan Balai Pungut. Sementara itu, wilayah lainnya di Provinsi Riau masih dilayani oleh sistem terisolasi [10]. PT. PLN (Persero) ULP Bangkinang merupakan perusahaan milik negara yang bergerak di bidang distribusi listrik dan layanan pelanggan, berlokasi di Jalan Ahmad Yani, Kecamatan Bangkinang Kota, Kabupaten Kampar. PT. PLN (Persero) ULP Bangkinang melayani 9 kecamatan di Kabupaten Kampar dan memiliki 4 posko pelayanan teknik. Sistem pelayanan yang digunakan melibatkan pengawasan dan penanganan gangguan pada jaringan tegangan menengah (JTM), jaringan tegangan rendah (JTR), serta instalasi listrik pelanggan. Target utama yang diberikan perusahaan meliputi pemangkasan pohon atau dahan yang berpotensi mengganggu jaringan tegangan menengah, inspeksi jaringan tegangan menengah, penyeimbangan beban trafo, serta pemeliharaan PHB-TR (Pemeliharaan Hubung Bagi Tegangan Rendah).

2.2.2 Profil data Aset ULP Bangkinang

Data profil untuk aset ULP Bangkinang menunjukkan berbagai jenis fasilitas dan peralatan distribusi tenaga listrik di wilayah tersebut. Beberapa aset utama termasuk transformer, yang jumlahnya mencapai 756 unit, jaringan tegangan menengah udara (SUTM) sekitar 827,1 kilometer, dan kabel bawah laut tegangan menengah udara (SKTM) sekitar 15 kilometer. Selain itu, terdapat 5,6-kilometer kabel tegangan rendah bawah tanah (SKUTM) serta 3,753 kilometer kabel tegangan rendah overhead (SKUTR) yang memasok listrik kepada pelanggan.

Selain transmisi dan kabel, ULP Bangkinang memiliki fasilitas pendukung yang mencakup 2 gardu induk (GI), 16 recloser untuk melindungi jaringan dari gangguan, dan 10-unit Load Break Switch (LBS) untuk mendistribusikan beban listrik. Data ini membantu dalam memvisualisasikan kapasitas dan distribusi

geografis fasilitas infrastruktur listrik yang dimiliki oleh ULP Bangkinang, meningkatkan keandalan layanan penyediaan listrik kepada konsumen.

Tabel 2.2 Rekap Data Aset Maximo ULP Bangkinang

No	Asset	Satuan	Jumlah
1	Trafo	Buah	756
2	SUTM	Kms	827.1
3	SKTM	Kms	15
4	SKUTM	Kms	5.6
5	SKUTR	Kms	3,753
6	GI	Unit	2
7	RECLOSER	Unit	16
8	LBS	Unit	10

2.2.3 Susut Energi Listrik

Susut energi (*loss*) adalah hilangnya energi yang terjadi dalam suatu sistem selama proses pengiriman, distribusi, atau konversi energi dari satu bentuk ke bentuk lainnya. Susut energi ini bisa terjadi dalam berbagai bentuk, seperti panas, suara, getaran, atau energi lain yang tidak bisa dimanfaatkan secara efektif oleh sistem. Saat listrik ditransmisikan melalui kabel dari pembangkit listrik ke konsumen, sebagian energi hilang dalam bentuk panas karena resistansi dalam kabel. Ini disebut sebagai susut daya atau susut transmisi. Nilai susut pada dasarnya dihitung dengan konsep perhitungan pada rumus 2.1.

$$E_{\text{loss}} = E_{\text{produksi}} - (E_{\text{jual}} + E_{\text{transfer}}) \dots \dots \dots (2.1)$$

Keterangan:

- E_{loss} : Rugi-rugi energi listrik (dalam satuan kWh)
- E_{produksi} : Energi listrik yang diproduksi.
- E_{jual} : Energi listrik yang dijual.
- E_{transfer} : Energi listrik yang ditransfer ke unit lain.

Semakin jauh jarak transmisi, semakin besar energi yang hilang. Faktor-faktor Penyebab Susut Energi:

- a. Resistansi: Hambatan dalam material yang dilalui oleh energi, seperti kabel listrik, menyebabkan energi hilang sebagai panas.
- b. Gesekan: Di dalam mesin, gesekan antara komponen bergerak menyebabkan hilangnya energi dalam bentuk panas.
- c. Radiasi: Energi juga bisa hilang melalui radiasi, seperti dalam sistem panas di mana panas diradiasikan ke lingkungan sekitarnya[3].

Susut energi dapat terjadi dalam berbagai bentuk dan konteks. Berikut adalah jenis-jenis susut energi berdasarkan proses dan sumbernya: Adapun macam-macam susut energi khususnya pada listrik, yaitu:

1) Susut Teknis (*Technical Losses*):

Susut teknis adalah energi yang hilang secara alamiah dan tidak bisa dihindari karena sifat fisik sistem listrik saat proses transmisi dan distribusi energi listrik. Susut ini umumnya terjadi di peralatan dan infrastruktur listrik. Susut energi ini terjadi karena faktor teknis, misalnya resistansi dalam kabel transmisi dan distribusi. Contoh umumnya adalah panas yang dihasilkan oleh arus listrik saat melewati kabel. Dasar rugi daya pada penghantar netral yang disebabkan oleh arus yang mengalir di titik netral dihitung menggunakan persamaan (2.1) [11].

$$\Delta P_n = R_N \times I_N^2 \dots \dots \dots (2.2)$$

Keterangan

ΔP_N : Rugi daya penghantar netral (kW)

R_N : Tahanan penghantar netral (Ω)

I_N : Arus penghantar netral (A)

Susut daya jaringan listrik yang biasa terjadi pada sistem transmisinya dinyatakan dengan persamaan (2.2) [12]:

$$PL = 3 I^2 R_l \dots \dots \dots (2.3)$$

Rugi-rugi daya menurut perumusan Conen (1987) adalah:

$$PL = 3 R_x L (I_2^2 - I_1 I_2 \sin \phi_r + I_1^2) \dots \dots \dots (2.4)$$

Keterangan:

PL = Hilang daya (watt) R = Tahanan kawat per fasa (Ω / Km)

I = Arus beban (A)

L = Panjang saluran (Km)

IC = Arus pemuat pada titik pengiriman (A)

$\cos \phi_r$ = Faktor – daya beban / ujung penerima

Sedangkan untuk mengetahui besar nilai susut daya listrik dinyatakan dengan Persamaan 2.4:

$$PL = PS - PR \dots \dots \dots (2.5)$$

Persentase antara daya yang diterima dan daya yang disalurkan dinyatakan dengan persamaan :

Contoh Susut Teknis:

- a. Resistansi pada Kabel: Saat listrik mengalir melalui kabel, sebagian energi hilang sebagai panas akibat resistansi dalam kabel. Semakin panjang kabel, semakin besar pula energi yang hilang.
- b. Transformator: Ketika listrik melewati transformator untuk menaikkan atau menurunkan tegangan, ada energi yang hilang dalam bentuk panas dan medan magnet.
- c. Arus Eddy (Eddy Current): Terjadi di dalam inti transformator atau mesin listrik lainnya, di mana arus listrik yang berputar menghasilkan panas yang menyebabkan hilangnya energi.
- d. Induktansi dan Kapasitansi: Hambatan dalam jaringan listrik yang disebabkan oleh elemen induktif dan kapasitif juga menyebabkan hilangnya energi.

2) Susut Non-Teknis (Non-Technical Losses):

Susut non-teknis adalah energi yang hilang bukan karena faktor teknis, tetapi lebih disebabkan oleh masalah administrasi, operasional, atau faktor eksternal lainnya. Susut non-teknis sering kali bersifat tidak sah atau ilegal. Susut ini disebabkan oleh faktor non-teknis seperti pencurian listrik,

kesalahan pencatatan meteran, atau kerusakan pada perangkat pengukuran[13].

Contoh Susut Non-Teknis:

- a. Pencurian Listrik: Konsumen menggunakan listrik tanpa membayar, misalnya dengan menyambungkan kabel secara ilegal atau memanipulasi meteran.
- b. Kesalahan Pencatatan Meteran: Meteran listrik yang rusak, tidak akurat, atau disengaja dimanipulasi sehingga konsumsi listrik yang tercatat lebih rendah dari penggunaan sebenarnya.
- c. Keterlambatan Pembayaran atau Non-Payment: Konsumen tidak membayar tagihan listrik mereka, yang berkontribusi terhadap kerugian pada perusahaan listrik.
- d. Administrasi yang Tidak Efisien: Kesalahan dalam pencatatan data, ketidaksesuaian antara pembacaan meter dan faktur, atau kebocoran informasi yang menyebabkan kehilangan pendapatan.

2.2.4 Anomali Data Susut

Data Susut yang di kumpulkan oleh PLN, mempunyai anomali tahunan yang seringkali menjadi kendala dalam menghitung susut *real*. Anomali data terjadi apabila ada perubahan skema dalam pencatatan KWH Produksi (yang berada di Gardu Induk) maupun pencatatan KWH Jual (yang berasal dari pencatatan PLN Pusat).

Adapun penyebab anomali data susut dibagi menjadi 2, yaitu:

1. Anomali Teknis

Anomali Teknis pada data susut disebabkan oleh pengaruh-pengaruh teknis, seperti pencatatan KWH Meter pada Gardu Induk yang tidak akurat dikarenakan KWH Meter rusak, ataupun adanya gangguan pada pengukuran pada sistem metering sehingga pencatatan produksi tidak bisa maksimal, mengakibatkan terjadinya anomali pada pencatatan susut.

2. Anomali Non-Teknis

Anomali Non-Teknis disebabkan oleh sebab-sebab yang tidak teknis. Anomali Non-Teknis adalah jenis anomali yang paling banyak dan paling

sering berpengaruh pada rendahnya tingkat akurasi perhitungan susut. Salah satu contoh kasus Anomali ini meliputi fenomena pembelian pulsa/token pada pelanggan prabayar saat memasuki bulan suci ramadhan, mengakibatkan drastisnya peningkatan KWH Jual pada bulan tersebut, mengakibatkan turunnya akurasi perhitungan susut akibat KWH Jual yang melambung tinggi, yang terkadang bahkan menghasilkan susut yang *minus*, atau besaran KWH Produksi lebih rendah dari KWH Jual, yang tentu saja tidak mungkin terjadi.

2.2.5 *Machine Learning*

Machine Learning (Pembelajaran Mesin) adalah cabang dari kecerdasan buatan (*Artificial Intelligence* atau AI) yang memungkinkan sistem komputer untuk belajar dari data dan pengalaman tanpa harus diprogram secara eksplisit untuk setiap tugas. Dalam machine learning, algoritma digunakan untuk menganalisis data, mengenali pola, dan membuat prediksi atau keputusan berdasarkan data tersebut [14]. Terdapat beberapa jenis machine learning, di antaranya:


- a. *Supervised Learning* (Pembelajaran Terawasi): Algoritma dilatih menggunakan dataset yang sudah diberi label, artinya data input dan outputnya sudah diketahui. Tujuan utamanya adalah memprediksi output berdasarkan data input baru.
- b. *Unsupervised Learning* (Pembelajaran Tanpa Pengawasan): Algoritma dilatih menggunakan data yang tidak memiliki label. Tujuannya adalah untuk menemukan pola tersembunyi atau struktur dalam data.
- c. *Reinforcement Learning* (Pembelajaran Penguatan): Algoritma belajar berdasarkan umpan balik dari tindakan-tindakan yang diambil dalam lingkungan tertentu. Algoritma ini berusaha memaksimalkan penghargaan (reward) dengan mempelajari strategi yang optimal.
- d. *Semi-supervised Learning* (Pembelajaran Semi-terawasi): Kombinasi antara pembelajaran terawasi dan tanpa pengawasan, di mana sebagian data diberi label dan sebagian lagi tidak.


Machine learning digunakan dalam berbagai aplikasi, seperti pengenalan wajah, deteksi penipuan, rekomendasi produk, kendaraan otonom, analisis pasar, dan banyak lagi.

2.2.6 Prediksi Menggunakan *Machine Learning*

Machine learning dapat digunakan untuk prediksi dengan memanfaatkan algoritma yang menganalisis data historis untuk mengenali pola dan hubungan antar variable [15]. Proses ini dimulai dengan pengumpulan dan pra-pemrosesan data, diikuti oleh pemilihan model machine learning yang sesuai, seperti regresi, decision tree, atau neural networks. Data tersebut kemudian digunakan untuk melatih model, di mana model belajar dari contoh-contoh yang diberikan untuk memprediksi hasil pada data baru yang belum pernah dilihat sebelumnya. Setelah model dilatih, ia dapat digunakan untuk membuat prediksi berdasarkan input data yang diberikan. Evaluasi akurasi prediksi dilakukan menggunakan metrik tertentu, dan model dapat disesuaikan atau ditingkatkan berdasarkan performanya. Pendekatan ini memungkinkan prediksi yang lebih akurat dalam berbagai bidang, seperti pertanian, keuangan, kesehatan, dan banyak lagi.

2.2.7 Metode PROPHET






Gambar 2.1 Flowchart PROPHET Model [16]

Metode Prophet merupakan alat analisis deret waktu yang dirancang oleh Facebook untuk menangani tantangan prediksi data dengan karakteristik kompleks, seperti tren yang tidak linier, pola musiman yang berulang, serta peristiwa-peristiwa khusus seperti hari libur. Metode ini dikembangkan dengan tujuan untuk menyediakan prediksi yang cepat dan akurat, terutama dalam konteks bisnis yang seringkali memiliki data dengan variasi musiman atau tren jangka panjang[16].

Cara kerja Prophet berpusat pada pemisahan data ke dalam tiga komponen utama: tren, musiman, dan peristiwa khusus. Komponen tren digunakan untuk menangkap perubahan jangka panjang dalam data, baik itu pertumbuhan maupun penurunan yang mungkin terjadi seiring waktu. Tren ini dapat non-linear, memungkinkan Prophet untuk menangani pola perubahan yang melambat atau semakin cepat. Komponen musiman menangani pola berulang yang muncul secara periodik, seperti perubahan mingguan, bulanan, atau tahunan, yang sering terlihat dalam data penjualan atau pengunjung. Prophet juga mampu mengidentifikasi dan menyesuaikan perubahan musiman yang tidak tetap, misalnya fluktuasi penjualan yang lebih tinggi pada bulan-bulan tertentu setiap tahunnya. Sementara itu, komponen peristiwa khusus memungkinkan model untuk mempertimbangkan efek dari peristiwa tertentu seperti hari libur nasional, promosi besar, atau acara musiman lainnya yang dapat mempengaruhi data secara signifikan pada waktu-waktu tertentu [7].

Secara keseluruhan, metode Prophet menawarkan pendekatan yang kuat dan fleksibel untuk prediksi deret waktu, menjadikannya alat yang sangat berguna dalam berbagai aplikasi bisnis dan teknis, termasuk dalam pengelolaan jaringan komunikasi dan analisis data bisnis yang dinamis.

2.2.8 Metode Arima




Gambar 2. 2 Arsitektur Metode ARIMA[17]

ARIMA adalah model statistik berbasis deret waktu yang cocok untuk data linier dan stasioner. Model ini memprediksi dengan memanfaatkan hubungan data masa lalu melalui komponen autoregressive, differencing, dan moving average. ARIMA efektif untuk pola sederhana tetapi kurang mampu menangani musiman atau tren kompleks[18].

2.2.9 Metode SARIMA

SARIMA adalah pengembangan ARIMA yang mencakup pola musiman melalui parameter tambahan. Metode ini cocok untuk data dengan pola musiman yang konsisten, tetapi proses penyesuaian parameternya lebih kompleks [19].

2.2.10 Metode LSTM



Gambar 2. 3 Arsitektur LSTM[20]

LSTM adalah jaringan saraf dalam kategori RNN yang unggul menangkap pola non-linear dan ketergantungan jangka panjang. Metode ini fleksibel dan tidak memerlukan data stasioner, namun membutuhkan sumber daya komputasi yang besar[21].

2.2.11 MSE (mean squared error)

MSE adalah rata-rata dari kuadrat kesalahan antara nilai yang diprediksi oleh model dengan nilai aktual. Ini digunakan sebagai metrik untuk mengukur kinerja model regresi, di mana semakin kecil nilai MSE, semakin baik kinerja model [22].

$$MSE(y, y_{pred}) = \|y - y_{pred}\|_2^2 \dots \dots \dots (2.6)$$

y = lebel target

y_{pred} = label prediksi

2.2.12 R² Score

R² Score adalah ukuran yang menunjukkan seberapa baik variabel independen menjelaskan variabel dependen dalam model regresi. Nilainya berkisar antara 0 hingga 1, di mana:

- berarti model sepenuhnya menjelaskan variabilitas data.
- 0 berarti model tidak menjelaskan variabilitas sama sekali.

Rumus:

$$R^2 = 1 - \frac{SS_{res}}{SS_{total}} \dots \dots \dots (2.7)$$

Keterangan


- $SS_{res} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$
- $SS_{Total} = \sum_{i=1}^n (y_i - \bar{y})^2$
- SS_{res} = Sum of Squares of Residuals (Total kesalahan atau jarak antara nilai yang diprediksi dan nilai aktual)
- SS_{tot} = Total Sum of Squares (Total variasi dalam data)
- $\bar{y}$ = adalah rata-rata nilai sebenarnya

2.2.13 OPTUNA

Optuna adalah pustaka Python yang digunakan untuk optimasi hiperparameter secara otomatis dan efisien. Cara kerjanya dimulai dengan mendefinisikan fungsi tujuan (objective function) yang mengevaluasi performa model berdasarkan kombinasi hiperparameter tertentu. Optuna kemudian menggunakan berbagai metode pencarian, seperti Tree-structured Parzen Estimator (TPE) untuk Bayesian optimization, Grid Search, atau Random Search, guna menemukan kombinasi terbaik. Selain itu, Optuna memiliki fitur pruning, yang memungkinkan penghentian lebih awal pada percobaan yang tidak menjanjikan, sehingga mempercepat proses optimasi. Hasil utama dari optuna adalah hiperparameter terbaik yang menghasilkan kinerja terbaik, kinerja terbaik dapat diketahui dengan parameter evaluasi terbaik seperti, MSE dan R^2 Score[23].

BAB III METODOLOGI PENELITIAN

3.1 Model Penelitian Perancangan



Gambar 3. 1 *Flowchart* Sistem Kerja

Gambar 3.1 adalah langkah-langkah pengerjaan sistem prediksi untuk mengukur susut energi listrik yang menggunakan metode *Machine Learning* PROPHET untuk memprediksi susut energi pada PLN ULP Bangkinang. Pengerjaan akan dilakukan dengan landasan teori untuk mencari informasi metode yang paling baik untuk memprediksi susut energi, kemudian data susut pada PLN ULP Bangkinang dari tahun 2018-2024 akan dianalisa untuk mendapatkan data dasar pembelajaran model PROPHET. Kemudian akan dilakukan komparasi hasil prediksi dengan kondisi sebenarnya untuk memastikan hasil prediksi benar. Pada tahap akhir akan dilakukan evaluasi dengan metode dan jika diperukannya perbaikan maka akan dilakukan perbaikan.


3.2 Parameter Penelitian

Data yang dikumpulkan dari data pelanggan dan hasil perhitungan nilai susut distribusi baik data susut teknis ataupun data susut non-teknis yang diambil setiap bulan sekali oleh PLN ULP Bangkinang dan bentuk datanya dengan masing-masing jumlah energi berbentuk satuan kilowatt-hour (KWH) seperti pada tabel 3.1.


Tabel 3. 1 Data Susut PLN ULP Bangkinang

NO	TAHUN	BULAN	ENERGI PRODUKSI (KWH)	ENERGI JUAL (KWH)	ENERGI TRANSFER (KWH)	NILAI SUSUT (KWH)
1	2021	DESEMBER	26,000,338	15,293,318	8,508,924	2,961,448
2	2022	JANUARI	26,087,709	15,302,014	8,586,461	2,977,352
3	2022	FEBRUARI	22,964,640	13,732,954	7,394,733	2,553,662
4	2022	MARET	27,289,436	15,633,282	9,030,802	3,370,011
5	2022	APRIL	28,419,122	15,854,841	10,048,207	3,132,221
6	2022	MEI	28,899,889	16,268,763	10,048,207	3,252,804
7	2022	JUNI	28,372,332	15,769,922	10,393,969	3,252,804
8	2022	JULI	29,698,178	16,604,771	11,008,224	2,770,479
9	2022	AGUSTUS	29,159,180	16,525,970	10,718,472	2,606,143
10	2022	SEPTEMBER	28,224,465	15,900,649	10,453,981	2,495,769
11	2022	OKTOBER	28,619,850	16,075,479	10,612,251	2,628,530
12	2022	NOVEMBER	27,932,151	15,554,167	10,347,273	2,630,512
13	2022	DESEMBER	27,637,706	15,869,659	10,084,797	2,323,222

3.3 Metode dan Rancangan Penelitian



Gambar 3. 2 Diagram Blok Rancangan Penelitian



Gambar 3. 3 Proses Prediksi Susut Energi Listrik

Dari gambar 3.2 dan 3.3 menjelaskan bagaimana rancangan penelitian untuk prediksi susut energi dengan menggunakan metode PROPHET. Metode Prophet akan memprediksi hasil dari nilai susut energi yang didapatkan dari hasil data yang diperoleh dari data susut energi PLN ULP Bangkinang mengenai data susut energi yang disimpan data hasil rekap pada excel sebagai dataset untuk model PROPHET pada Kaggle dan sebagai pembelajaran yang kemudian akan didapatkan hasil prediksi dan hasil nilai evaluasi nilai MSE dan R^2 Score hasil evaluasi kemampuan model memprediksi.

3.4 Teknik Pengumpulan Data

3.4.1 Alat yang Digunakan

Adapun alat dan bahan yang digunakan pada tugas akhir ini seperti pada table 3.2:

Tabel 3. 2 Tabel Alat dan Bahan yang Digunakan

No	Alat dan Bahan	Unit	Keterangan
1	Laptop	1	Laptop digunakan untuk media pengerjaan, training, analisa dan dokumentasi perekapan hasil
2	Kaggle	1	Kaggle digunakan untuk mentraining sistem prediksi PROPHET yang kemudian digunakan untuk pembelajaran model.
3	Excel	1	Excel digunakan untuk perekapan hasil data dan input rekap data konsumen

3.4.2 Pengukuran

Pengukuran pada penelitian ini dilakukan dengan hasil evaluasi parameter pada training dengan mendapatkan nilai prediksi susut yang sama dengan menghasilkan nilai MSE dan R^2 Score dan akan dikomparasi dengan hasil nilai susut sebenarnya seperti pada tabel 3.3

Tabel 3. 3 Tabel Hasil

No	Metode	MSE	R^2 Score

3.5 Teknik Analisa data

Data akan dianalisa hasilnya dengan membandingkan hasil dengan nilai susut sebenarnya apakah hasil nilai susut yang diprediksi didapatkan hasil yang mirip atau hampir sama. Selain dengan menggunakan metode komparasi dengan susut sebenarnya yang kemudian menggunakan parameter evaluasi, seperti MSE dan R^2 Score.

3.6 Komparasi Prediksi Menggunakan Metode Lain

Seperti tabel 3.4 pengujian akan dilakukan komparasi atau perbandingan dengan metode lain dalam hal ini menggunakan 3 pembanding seperti Arima, Sarima dan LSTM. Hal ini bertujuan untuk mengetahui apakah metode PROPHET yang diusulkan sudah baik dalam membaca dan memprediksi data susut energi listrik di PLN ULP Bangkinang. Parameter yang digunakan terdapat 2 parameter yaitu MSE dan R^2 Score untuk mengevaluasi masing-masing metode dalam membaca dan ‘memprediksi data nilai susut energi di PLN ULP Bangkinang.

Tabel 3. 4 Perbandingan Metode

No	Metode	MSE	R^2 Score
1	Arima		
2	Sarima		
3	LSTM		
4	PROPHET		

BAB IV

HASIL DAN ANALISA

4.1 Hasil

Laporan ini menyajikan data mengenai *Nilai Susut* dalam periode Desember 2021 hingga Mei 2024. *Nilai Susut* mengacu pada jumlah atau nilai yang mengalami penurunan selama periode tertentu. Data ini disusun secara sistematis berdasarkan bulan untuk memberikan gambaran tren perubahan yang terjadi dari waktu ke waktu seperti pada table 4.1.

Tabel 4. 1 Data Nilai Susut PLN ULP Bangkinang

No	Tanggal	Nilai Susut (kWh)
1	Dec-21	2,961,448.165
2	Jan-22	2,977,352.195
3	Feb-22	2,553,661.667
4	Mar-22	3,370,010.856
5	Apr-22	3,132,220.852
6	May-22	3,252,804.118
7	Jun-22	2,888,696.21
8	Jul-22	2,770,479.052
9	Aug-22	2,606,143.124
10	Sep-22	2,495,768.514
11	Oct-22	2,628,529.777
12	Nov-22	2,630,511.819
13	Dec-22	2,323,22.,66
14	Jan-23	2,867,672.765
15	Feb-23	2,589,319.995
16	Mar-23	2,927,029.98
17	Apr-23	2,734,742.025
18	May-23	3,477,342.856
19	Jun-23	2,562,250.759
20	Jul-23	3,149,464.494
21	Aug-23	3,098,231.446

No	Tanggal	Nilai Susut (kWh)
22	Sep-23	2,610,330.81
23	Oct-23	2,686,284.787
24	Nov-23	2,517,980.634
25	Dec-23	2,303,303.751
26	Jan-24	2,477,964.455
27	Feb-24	2,451,105.617
28	Mar-24	3,490,641.711
29	Apr-24	2,979,615.159
30	May-24	2,933,894.081

Melalui analisis data tabel 4.1 dan gambar 4.1, dapat diidentifikasi pola fluktuasi, faktor yang mempengaruhi perubahan nilai, serta implikasi dari tren yang terjadi. Grafik pada gambar 4.1 menunjukkan tren *Nilai Susut* dari Januari 2022 hingga sekitar tahun 2024, dengan data historis yang divisualisasikan bersama prediksi ke depan. Sumbu horizontal (X) merepresentasikan waktu, sementara sumbu vertikal (Y) menunjukkan jumlah nilai susut dalam satuan tertentu, berkisar antara 2.2 hingga 3.4 M. Data memperlihatkan terjadi perbedaan nilai susut pada setiap bulan. Namun seperti gambar 4.1 rentang waktu tertentu memiliki pola yang mirip terkait kenaikan dan penurunan nilai susut. Dengan data pada tabel 4.1, data akan digunakan sebagai landasan pengujian prediksi nilai susut dengan menggunakan metode PROPHET, ARIMA, SARIMA, dan LSTM. Tujuan dari penelitian ini adalah untuk mendapatkan model terbaik yang mampu memprediksi nilai susut energi listrik secara optimal. Pengujian dilakukan dengan melakukan *training* model menggunakan platform Kaggle.com dan untuk perekapan data menggunakan Microsoft excel. Tantangan pada pengujian masing-masing metode adalah sedikitnya data untuk pembelajaran dengan hanya 30 data pada rentang pengambilan waktu setiap bulannya seperti pada tabel 4.1. Sehingga untuk menguji metode prediksi terbaik dilakukan pula OPTUNA pada setiap model baik pada metode PROPHET, ARIMA, SARIMA, dan metode LSTM dari semua pengujian akan didapatkan *best* parameter pengujian *best* nilai MSE dan R^2 Score terbaik.



Gambar 4. 1 Hasil Plot Data Nilai Susut Original

4.1.1 Perhitungan PLN

Pada perhitungan susut listrik yang dilakukan oleh PT PLN ULP Bangkinang, sistem pencatatan dilakukan secara rutin setiap bulan menggunakan Microsoft Excel. Data yang diperoleh mencerminkan perbandingan antara energi listrik yang diproduksi, energi yang terjual, serta energi yang ditransfer ke unit PLN lainnya. Dari hasil perhitungan, diperoleh nilai susut listrik yang merupakan selisih antara produksi listrik dengan total konsumsi listrik oleh pelanggan dan transfer antarunit PLN.

NO	UNIT	SIN	SEPTEMBER	SEPTEMBER Tanpa EMIN	OKTOBER	OKTOBER Tanpa EMIN
V	BANGKINANG					
1	PRODUKSI	KWH	30.464.277,91	30.464.277,91	31.992.019,87	31.992.019,87
2	TERIMA DARI UNIT LAIN		2.064,00	2.064,00	2.661.119,43	2.661.119,43
3	TERIMA DARI UNIT LAIN diluar AREA		1.071.062,57	1.071.062,57	1.120.455,34	1.120.455,34
4	PEMAKAIAN SENDIRI	KWH	-	-	-	0,00
5	KWH SIAP SALUR	KWH	31.537.404,48	31.537.404,48	35.773.594,64	35.773.594,64
6	SUSUT TRAVO (PSSD)	KWH	487.992,00	487.992,00	488.414,80	488.414,80
7	SIAP JUAL	KWH	31.049.412,48	31.049.412,48	35.285.179,84	35.285.179,84
8	TRANSFER KE UNIT LAIN	KWH	9.969.839,04	9.969.839,04	13.157.831,47	13.157.831,47
9	KWH NETTO	KWH	31.049.412,48	31.049.412,48	35.285.179,84	35.285.179,84
10	KWH EMIN			174.656,00		171.582
11	JUAL	KWH	18.692.477	18.517.821	19.126.650,98	18.955.068,98
	- KWH JUAL NORMAL III-07	KWH	10.279.744	10.279.744	10.550.980	10.550.980,00
	- KOREKSI (N)	KWH	28.179,0	28.179,0	12.155	12.155,00
	- BATAL MURNI (N)	KWH	(26.426)	(26.426)	(13.233)	-13.233,00
	- P2TL (N)	KWH	455.226	455.226	341.203	341.203,00
	- PESTA (N)	KWH	3.133	3.133	3.973	3.973,00
	- STAN BONGKAR YG LUNAS (N)	KWH	9.074	9.074	7.054	7.054,00
	- KWH IMPORT		7.299	7.299	43.107	43.107,00
	- PRABAYAR (N)	KWH	7.936.248	7.936.248	8.181.412	8.181.411,98
12	KWH SUSUT	KWH	2.387.096,28	2.561.752,28	3.000.697,40	3.172.279,40
13	SUSUT (%)	%	7,57%	8,12%	8,39%	8,97%
14	SUSUT KOMULATIF (%)	%	7,88%	8,50%	7,93%	8,54%

Gambar 4. 2 Perhitungan Data PLN

Berdasarkan data pada Gambar 4.2, diketahui bahwa produksi listrik pada bulan Oktober sebesar 35,285,179.84 kWh. Produksi listrik dalam satu bulan

tersebut didapatkan dari pencatatan pada kWh Meter pada Gardu Induk Distribusi PLN. Dari jumlah ini, energi listrik yang terjual kepada pelanggan mencapai 19,126,650.98 kWh yang terdiri dari penjualan listrik pelanggan pascabayar dan prabayar dalam 1 bulan (sumber data berasal dari rekap pendapatan PLN Pusat). Selanjutnya yaitu ada energi yang ditransfer ke unit PLN lainnya sebesar 13,157,831.47 kWh. Energi transfer ini di dapatkan dari pencatatan pada metering kWh batas yang dipasangkan kepada penyulang yang menaungi lebih dari satu ULP untuk menentukan produksi masing-masing ULP yang berada pada penyulang yang sama. Dari komposisi-komposisi tersebut, nilai susut listrik (Eloss) dapat dihitung dengan persamaan pada 2.5 sebagai, yaitu:

- Susut Bulan Oktober

$$E_{\text{loss}} = E_{\text{produksi}} - (E_{\text{jual}} + E_{\text{transfer}})$$

$$E_{\text{loss}} = 35,285,179.84 - (19,126,650.98 + 13,157,831.47)$$

$$E_{\text{loss}} = 3,000,697.40 \text{ kWh}$$

Dari sistem perhitungan tersebut dan gambar 4.2 memaparkan bahwa, PT PLN ULP Bangkinang masih melakukan perhitungan nilai susut berdasarkan selisih hasil produksi dengan nilai pemakaian (nilai terjual+nilai transfer ke pln area lain) tanpa melakukan pengujian dan prediksi untuk nilai susut yang terjadi. Nilai susut yang didapat pada bulan Oktober sebesar 3,000,697.40 kwh. Perhitungan untuk data nilai susut dilakukan setiap bulan dengan sistem pencatatan pada excel.

4.1.2 Pengujian Prediksi Nilai Susut dengan Metode PROPHET

Pengujian untuk prediksi dilakukan menggunakan library dari PROPHET dan scikit-learn dan fitur seperti tabel 4.2. Untuk mendapatkan kinerja metode terbaik dilakukan pengujian best parameter dengan menggunakan metode OPTUNA dengan n_{trial} sebanyak 2000, sehingga model akan menguji dan mempelajari model keseluruhan sebanyak 2000 kali untuk memperkuat pengujian terbaik. Didapatkan hyperparameter tuning terbaik adalah Best parameters: {'changepoint_prior_scale': 0,07004300902657103, 'seasonality_prior_scale': 0,12767799465377402, 'n_changepoints': 81}. Didapatkan nilai MSE dan R^2 Score terbaik adalah 0,0054 dan 0,68785. Hasil kemampuan prediksi nilai susut dapat

dilihat pada gambar 4.3 grafik perbandingan nilai susut prediksi dan aktual. Didapatkan seperti gambar 4.3 nilai prediksi dan nilai susut sebenarnya memiliki grafik yang cenderung mirip dan tidak berbeda jauh, hal ini membuktikan metode PROPHET mampu memprediksi nilai susut energi listrik walaupun dengan data pembelajaran yang sedikit dalam hal ini hanya terdapat 30 data nilai susut pada rentang waktu tertentu.

Tabel 4. 2 Fitur yang Digunakan pada Pengujian Metode PROPHET

Fitur	Deskripsi
Library yang digunakan	Menggunakan pustaka Pandas, NumPy, Prophet, Scikit-learn, dan Optuna
Dataset	Data berisi dua kolom: Tanggal (waktu) dan Nilai Susut (nilai yang akan diprediksi)
Preprocessing	Mengubah format Tanggal ke datetime dan menerapkan transformasi log pada Nilai Susut untuk membuat data lebih stabil
Split Data	Membagi data menjadi data latih (train) yang mencakup semua kecuali 5 bulan terakhir, dan data uji (test) yang terdiri dari 5 bulan terakhir
Hyperparameter Tuning	Menggunakan Optuna untuk mencari nilai terbaik dari hyperparameter: changepoint_prior_scale (0,001 - 2.0), seasonality_prior_scale (0,1 - 200.0), dan n_changepoints (10 - 200).
Modeling	Melatih model Prophet menggunakan data latih dengan hyperparameter terbaik yang ditemukan oleh Optuna
Prediksi	Membuat data masa depan untuk 5 bulan ke depan dan melakukan prediksi berdasarkan model yang telah dilatih
Evaluasi Model	Menghitung Mean Squared Error (MSE) untuk mengukur seberapa jauh hasil prediksi dibandingkan dengan data aktual
Optimasi	Menjalankan hingga 2000 n_train dan 10 iterasi pencarian hyperparameter, tetapi akan berhenti lebih

Fitur	Deskripsi
	awal jika MSE sudah mencapai nilai 0.015 atau lebih kecil



Gambar 4. 3 Grafik Perbandingan Prediksi dan Aktual Nilai Susut Metode PROPHET

Merujuk kepada data susut aktual, bisa di dapatkan bahwa kecenderungan terjadinya anomali susut secara drastis terjadi di bulan April di setiap tahunnya. Metode *Prophet*, selaku metode utama yang terpilih, mampu memprediksikan hasil susut berdasarkan parameter data yang telah di input, dengan besaran susut aktual beserta susut prediksi di bulan April sebagai berikut:

Tabel 4. 2 Tabel Perbandingan Susut Aktual VS Prediksi Bulan April

Tahun	Susut Aktual (KWH)	Susut Prediksi (KWH)	Selisih Aktual vs Prediksi (KWH)
2022	3,370,011	3,336,974	33,037
2023	2,927,030	3,227,369	-300,339
2024	3,490,642	3,219,913	270,729

4.1.3 Pengujian dengan Metode ARIMA


Pengujian untuk prediksi dilakukan menggunakan library dari Statsmodels pada metode dan scikit-learn dan fitur seperti tabel 4.3. Untuk mendapatkan kinerja metode terbaik dilakukan pengujian best parameter dengan menggunakan metode OPTUNA dan didapatkan hyperparameter tuning terbaik adalah Best parameters: {'p': 3, 'd': 1, 'q': 5}. Didapatkan nilai MSE dan R^2 score terbaik adalah 0,0108 dan

0,304922. Hasil kemampuan prediksi nilai susut dapat dilihat pada gambar 4.4 grafik perbandingan nilai susut prediksi dan aktual. Hasil kemampuan prediksi nilai susut dapat dilihat pada gambar 4.4 grafik perbandingan nilai susut prediksi dan aktual. Didapatkan seperti gambar 4.4 nilai prediksi dan nilai susut sebenarnya memiliki grafik yang cenderung mirip dan tidak berbeda jauh namun menghasilkan nilai prediksi lebih rendah dibandingkan nilai susut energi listrik sebenarnya, hal ini membuktikan metode ARIMA mampu memprediksi pola nilai susut energi listrik walaupun dengan nilai yang cenderung lebih rendah daripada nilai data sebenarnya, hal ini dapat disebabkan oleh data pembelajaran yang sedikit dalam hal ini hanya terdapat 30 data nilai susut pada rentang waktu tertentu.

Tabel 4. 3 Fitur yang Digunakan pada Pengujian Metode ARIMA

Fitur	Deskripsi
Library yang digunakan	Menggunakan pustaka Pandas, NumPy, Statsmodels (ARIMA), Scikit-learn, Plotly, dan Optuna
Dataset	Data berisi dua kolom: Tanggal (waktu) dan Nilai Susut (nilai yang akan diprediksi)
Preprocessing	Mengubah format Tanggal ke datetime, menjadikannya sebagai indeks, dan menerapkan transformasi log pada Nilai Susut
Split Data	Membagi data menjadi data latih (train) yang mencakup semua kecuali 5 bulan terakhir, dan data uji (test) yang terdiri dari 5 bulan terakhir
Hyperparameter Tuning	Menggunakan Optuna untuk mencari nilai terbaik dari hyperparameter ARIMA: p (0-5), d (0-2), dan q (0-5)
Modeling	Melatih model ARIMA menggunakan data latih dengan hyperparameter terbaik yang ditemukan oleh Optuna
Prediksi	Membuat prediksi untuk 5 bulan ke depan menggunakan model ARIMA yang telah dilatih

Fitur	Deskripsi
Evaluasi Model	Menghitung Mean Squared Error (MSE) dan R^2 Score untuk mengukur seberapa jauh hasil prediksi dibandingkan dengan data aktual
Optimasi	Menjalankan hingga 10 iterasi 2000 n_train pencarian hyperparameter dengan Optuna untuk mendapatkan kombinasi parameter terbaik



Gambar 4. 4 Grafik Perbandingan Prediksi dan Aktual *Nilai Susut* Metode ARIMA

4.1.4 Pengujian dengan Metode SARIMA


Pengujian untuk prediksi dilakukan menggunakan library dari Statsmodels pada metode SARIMAX dan scikit-learn dan fitur seperti tabel 4.4. Untuk mendapatkan kinerja metode terbaik dilakukan pengujian best parameter dengan menggunakan metode OPTUNA dan didapatkan hyperparameter tuning terbaik adalah Non-seasonal (p,d,q): (1,0,3), dan Seasonal (P,D,Q,s): (0,1,0,12). Didapatkan nilai MSE dan R^2 Score terbaik adalah 0,0165 dan 0,0772005. Hasil kemampuan prediksi nilai susut dapat dilihat pada gambar 4.4 grafik perbandingan nilai susut prediksi dan aktual. Didapatkan seperti gambar 4.5 nilai prediksi dan nilai susut sebenarnya memiliki grafik yang cenderung mirip dan tidak berbeda jauh namun menghasilkan nilai prediksi lebih rendah dibandingkan nilai susut energi

listrik sebenarnya dan pada bulan juni 2024 mengalami lonjakan nilai prediksi susut energi listrik dan prediksi awal januari hingga maret juga mengalami peningkatan nilai dibandingkan nilai susut energi listrik sebenarnya, hal ini membuktikan metode SARIMA mampu memprediksi pola nilai susut energi listrik walaupun dengan nilai yang cenderung lebih rendah atau lebih tinggi pada bulan tertentu daripada nilai data sebenarnya, hal ini dapat disebabkan oleh data pembelajaran yang sedikit dalam hal ini hanya terdapat 30 data nilai susut pada rentang waktu tertentu.

Tabel 4. 4 Fitur yang Digunakan pada Pengujian Metode SARIMA

Fitur	Deskripsi
Library yang digunakan	Menggunakan pustaka Pandas, NumPy, Statsmodels (SARIMAX), Scikit-learn, Plotly, dan Optuna
Preprocessing	Mengubah format Tanggal ke datetime, menjadikannya sebagai indeks, dan menerapkan transformasi log pada Nilai Susut
Nilai Susut	Data nilai susut yang digunakan sebagai target prediksi.
Transformasi Log	Data nilai susut ditransformasikan menggunakan logaritma natural (log) agar lebih stabil.
Train-Test Split	Data dipisahkan menjadi train (80%) dan test (20%).
Hyperparameter SARIMA	Mencakup (p, d, q) untuk komponen non-musiman dan (P, D, Q, s) untuk musiman dengan periode 12 bulan (d disesuaikan dengan periode 1 tahun terdapat 12 bulan).
Optimasi Hyperparameter	Menggunakan Optuna untuk mencari kombinasi parameter SARIMA terbaik berdasarkan MSE dan R^2 Score.
Evaluasi Model	Metrik evaluasi mencakup MSE dan R^2 Score setelah transformasi balik (exponential).

Fitur	Deskripsi
Optimasi	Menjalankan hingga 10 iterasi 2000 n_train pencarian hyperparameter dengan Optuna untuk mendapatkan kombinasi parameter terbaik



Gambar 4. 5 Grafik Perbandingan Prediksi dan Aktual Nilai Susut Metode SARIMA


4.1.5 Pengujian dengan metode LSTM

Pengujian untuk prediksi dilakukan menggunakan library dari Tensorflow (Keras) dengan metode LSTM dan scikit-learn dan fitur seperti tabel 4.5. Untuk mendapatkan kinerja metode terbaik dilakukan pengujian best parameter dengan menggunakan metode OPTUNA dan didapatkan hyperparameter tuning terbaik adalah Hasil Optimasi Hyperparameter: Best LSTM units: 32 dan Best learning rate: 0,000118. Didapatkan nilai MSE dan R^2 Score terbaik adalah 429,574.55 dan -0.0240. Hasil kemampuan prediksi nilai susut dapat dilihat pada gambar 4.6 grafik perbandingan nilai susut prediksi dan aktual. Didapatkan seperti gambar 4.6 nilai prediksi dan nilai susut sebenarnya memiliki grafik yang cenderung tidak mirip dan berbeda jauh namun menghasilkan nilai prediksi lebih rendah dibandingkan nilai susut energi listrik sebenarnya, hal ini membuktikan metode LSTM tidak mampu memprediksi pola nilai susut energi listrik walaupun dengan nilai yang cenderung lebih rendah daripada nilai data sebenarnya. Nilai grafik seperti gambar 4.6 prediksi cenderung terbentuk pada pola yang sama dengan nilai dibawah 2,4 M dan tidak

mampu memprediksi jika terdapat lonjakan nilai susut. Hal ini dapat disebabkan oleh data pembelajaran yang sedikit dalam hal ini hanya terdapat 30 data nilai susut pada rentang waktu tertentu.

Tabel 4. 5 Fitur yang Digunakan pada Pengujian Metode LSTM

Fitur	Deskripsi
Library yang digunakan	Menggunakan Pandas, NumPy, Scikit-learn, TensorFlow (Keras), Optuna, dan Matplotlib
Dataset	Data terdiri dari dua kolom: Tanggal (waktu) dan Nilai Susut (nilai yang akan diprediksi)
Preprocessing	Mengonversi Tanggal ke format datetime, menormalkan Nilai Susut menggunakan MinMaxScaler, dan membentuk sequence untuk input LSTM
Split Data	Data dibagi menjadi 80% train dan 20% test
Hyperparameter Tuning	Menggunakan Optuna untuk mencari nilai terbaik dari hyperparameter LSTM: jumlah unit LSTM (32-128) dan learning rate (1e-4 hingga 1e-2)
Modeling	Membuat model LSTM dengan satu lapisan LSTM dan satu lapisan Dense untuk output
Training Model	Model dilatih menggunakan 2000 epoch selama proses tuning dengan Optuna, dan 50 epoch untuk pelatihan akhir menggunakan hyperparameter terbaik. Batch size = 32 dan n_trial adalah 10.
Prediksi	Model membuat prediksi berdasarkan data uji
Evaluasi Model	Menghitung R^2 Score, Mean Absolute Error (MAE), dan Mean Squared Error (MSE) untuk mengukur performa model
Visualisasi	Membandingkan hasil prediksi dengan data aktual menggunakan plot Matplotlib



Gambar 4. 6 Grafik Perbandingan Prediksi dan Aktual Nilai Susut Metode LSTM


4.2 Pembahasan

4.2.1 Rekap Keseluruhan Pengujian dan Perbandingan Metode


Dari semua pengujian yang dilakukan dari setiap pengujian keseluruhan pada metode baik pada metode PROPHET, ARIMA, SARIMA, dan LSTM serta dilakukan pengujian OPTUNA untuk mendapatkan parameter terbaik untuk pembelajaran masing-masing metode dengan iterasi sebanyak 2000 pada masing-masing metode didapatkan nilai parameter evaluasi MSE dan R^2 Score seperti pada tabel 4.6, grafik nilai MSE pada gambar 4.7, dan grafik perbandingan nilai R^2 Score pada gambar 4.8.

Tabel 4. 6 Rekap Nilai MSE dan R^2 Score Keseluruhan Metode

No	Metode	MSE	R^2 Score
1	PROPHET	0,0054	0,68785
2	ARIMA	0,0108	0,304922
3	SARIMA	0,0165	0,0772005
4	LSTM	429,574.55	-0,0240




Gambar 4. 7 Grafik Perbandingan MSE

Gambar 4. 8 Grafik Perbandingan R² Score

Dari perbandingan metode yang dilakukan didapatkan metode terbaik untuk memprediksi nilai susut di PT PLN ULP Bangkinang adalah metode PROPHET. Pengujian selanjutnya adalah menguji dengan metode terbaik untuk memunculkan hasil prediksi nilai susut hingga Januari 2025 seperti pada grafik perbandingan nilai MSE gambar 4.7 dan gambar 4.8 perbandingan nilai R^2 Score. Dengan nilai MSE dan R^2 Score pada metode PROPHET adalah 0,0054 dan 0,68785, dari hal tersebut didapatkan bahwa nilai error pembacaan prediksi data yang minim dengan nilai R^2 Score adalah 69%.

Dari metode PROPHET dengan hasil nilai parameter evaluasi dan grafik prediksi paling baik maka dilakukan pengujian untuk prediksi data nilai susut kedepannya seperti grafik 4.9. Pada grafik gambar 4.9 garis biru tebal menggambarkan tren utama perubahan nilai susut, yang terlihat mengalami fluktuasi signifikan dari bulan ke bulan, menunjukkan adanya pola musiman atau siklus tertentu. Titik-titik hitam merepresentasikan data aktual yang digunakan dalam pemodelan, dengan sebaran yang cukup dekat dengan garis tren, mengindikasikan pola yang konsisten. Selain itu, area berbayang biru mencerminkan interval kepercayaan atau tingkat ketidakpastian dalam prediksi, di mana semakin lebar area ini, semakin tinggi ketidakpastian estimasi di masa depan. Panel bawah memberikan ringkasan tren dalam jangka panjang, memungkinkan identifikasi pola musiman dengan lebih jelas. Secara keseluruhan, grafik ini menunjukkan bahwa nilai susut mengalami fluktuasi yang cukup konsisten dengan kemungkinan adanya faktor musiman yang berulang, sementara prediksi ke depan tetap mengikuti pola historis dengan beberapa ketidakpastian.



Gambar 4. 9 Grafik Prediksi Nilai Susut

Nilai hasil prediksi pada gambar 4.3-4.6 dan 4.9 memiliki perbedaan pada nilai hasil aktual dan prediksi. Arti pada gambar 4.9 adalah sebagai berikut:

1. Garis berwarna biru memiliki arti hasil *trend* dari prediksi susut yang merupakan hasil akhir dari machine learning.
2. Warna biru pudar memiliki arti toleransi *plus-minus* pada hasil prediksi, yang akan menjadi parameter batas *error* dari prediksi susut dari machine learning.
3. Titik-titik hitam pada grafik memiliki arti data *real* susut yang di tujuan sebagai pembandingan dengan garis biru untuk membandingkan hasil prediksi dengan data *real* yang ada.
4. *Range* waktu dari bulan Juli 2024 memiliki komposisi data output murni dari prediksi machine learning saja, ditunjukkan dengan tidak adanya titik-titik hitam, menandakan data *real* pada bulan tersebut tidak di inputkan.

Adapun faktor-faktor yang mempengaruhi hal tersebut antara lain adalah sebagai berikut:

1. Jumlah data yang masih sangat terbatas dimana metode *mechine learning* ataupun *deep learning* memerlukan data yang kompleks dan banyak (*big data*) untuk dapat menjadi semakin presisi dalam prediksi dan pembelajaran

datanya. Pada kasus penelitian ini data hanya berjumlah 30 data dan ini adalah jumlah data yang sangat sedikit untuk pembelajaran.

2. Nilai data dasar belum memiliki pola yang khusus yang masih naik dan turun pada titik data tertentu.
3. Kemampuan belajar metode yang belum maksimal, hal tersebut dapat dilihat dari parameter R^2 Score yang masih rendah dengan nilai terbaik adalah 0,68 pada metode PROPHET dan MSE yang digunakan masih tinggi dengan nilai tertinggi pada metode LSTM dengan nilai 429,574.55. hal ini menunjukkan metode masih belum mampu memprediksi dan membaca pola nilai susut dan error yang masih tinggi.



BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan


1. Berdasarkan hasil pengujian yang dilakukan terhadap empat metode prediksi, yaitu PROPHET, ARIMA, SARIMA, dan LSTM, dapat disimpulkan bahwa metode PROPHET menunjukkan performa paling akurat dalam memprediksi nilai susut energi listrik pada PLN ULP Bangkinang. Hal ini ditunjukkan oleh nilai Mean Squared Error (MSE) sebesar 0,0054 dan nilai koefisien determinasi (R^2 Score) sebesar 0,68785. Sebagai perbandingan, metode ARIMA menghasilkan MSE sebesar 0,0108 dan R^2 sebesar 0,30492, metode SARIMA memperoleh MSE sebesar 0,0165 dan R^2 sebesar 0,0772, sedangkan metode LSTM menunjukkan hasil paling rendah dengan MSE sebesar 429,574.55 dan R^2 sebesar -0,0240. Dari hasil tersebut, dapat disimpulkan bahwa PROPHET adalah metode paling efektif dalam memprediksi susut energi listrik dibandingkan metode lainnya.
2. Optimasi parameter pada metode PROPHET dilakukan dengan menggunakan algoritma Optuna selama 2000 iterasi untuk mendapatkan hasil prediksi yang paling akurat. Parameter terbaik yang ditemukan adalah changepoint_prior_scale sebesar 0,0700, seasonality_prior_scale sebesar 0,1277, dan jumlah n_changepoints sebanyak 8. Penerapan parameter hasil optimasi ini terbukti mampu meningkatkan akurasi prediksi metode PROPHET secara signifikan dibandingkan penggunaan parameter default. Upaya tuning ini juga dilakukan pada metode lain, seperti ARIMA dengan parameter terbaik ($p=3$, $d=1$, $q=5$), SARIMA dengan parameter Non-seasonal (1,0,3) dan Seasonal (0,1,0,12), serta LSTM dengan 32 unit dan learning rate sebesar 0,000118.
3. Selisih antara nilai susut aktual dengan hasil prediksi menunjukkan bahwa prediksi paling meleset terjadi pada periode Maret-April 2024. Pada periode tersebut terdapat lonjakan nilai susut yang signifikan sehingga menyebabkan model tidak mampu mengikuti pola perubahan secara akurat.

Sementara itu, selisih terkecil antara nilai aktual dan prediksi terjadi pada bulan-bulan dengan pola data yang relatif stabil, seperti Januari 2024, di mana hasil prediksi hampir mendekati nilai aktual. Perbedaan ini menunjukkan bahwa performa model sangat bergantung pada kestabilan pola data historis.

5.2 Saran

Dari keseluruhan pengujian dan penelitian yang telah dilakukan terdapat beberapa saran yang perlu diperhatikan untuk perbaikan penelitian kedepannya, yaitu:

1. Diperlukan pengumpulan data yang lebih banyak agar didapatkan prediksi yang lebih lengkap untuk membantu pembelajaran model mengenali pola data nilai susut yang lebih akurat.
2. Diperlukan menggunakan metode komputasi yang lebih ringan sehingga metode mampu belajar dengan data yang terbatas.
3. Kedepannya dapat dibuat untuk system yang siap diterapkan secara *real time* agar dapat diterapkan pada prediksi susut energi listrik agar mengurangi kerugian dimasa depan.



DAFTAR PUSTAKA

- [1] Kementrian ESDM Direktrat Jenderal Keteragalistrikan, “Statistik Ketenagalistrikan 2020,” *Kementrian Energi dan Sumber Daya Miner. Direktrat Jenderal Keteragalistrikan*, vol. 34, no. April, p. 122, 2021.
- [2] R. F. Ariyanti, “Identifikasi Penyebab Susut Energi Listrik PT PLN (Persero) Area Semarang Menggunakan Metode Failure Mode & Effect Analysis (FMEA),” *Ind. Eng. Online J.*, vol. 8, no. 1, pp. 1–8, 2019.
- [3] N. S. Romadhon, H. Tasmono, and R. S. Widagdo, “Analisis Susut Energi Jaringan Tegangan Rendah pada Gardu AE123 ,” pp. 608–619, 2024.
- [4] A. Bactiar and A. Doni, “Optimasi Penyeimbangan Beban Pada Trafo Distribusi Terhadap Susut Energi,” *J. Tek. Elektor Inst. Teknol. Padang*, vol. 9, no. 2, p. 7, 2020.
- [5] G. W. Aji, H. Tasmono, and R. S. Widagdo, “Studi Susut Energi pada Gardu Distribusi dengan Beban Tidak Seimbang di PLN ULP Indrapura UP3 Surabaya Utara,” vol. 1978, pp. 340–352, 2024.
- [6] Y. Sun, F. Haghighat, and B. C. M. Fung, “A review of the-state-of-the-art in data-driven approaches for building energy prediction,” *Energy Build.*, vol. 221, 2020, doi: 10.1016/j.enbuild.2020.110022.
- [7] U. S. Hashmi *et al.*, “Towards Real-Time User QoE Assessment via Machine Learning on LTE Network Data,” *IEEE Veh. Technol. Conf.*, vol. 2019-Sept, 2019, doi: 10.1109/VTCFall.2019.8891552.
- [8] Y. Zhao, C. Zhang, Y. Zhang, Z. Wang, and J. Li, “A review of data mining technologies in building energy systems: Load prediction, pattern identification, fault detection and diagnosis,” *Energy Built Environ.*, vol. 1, no. 2, pp. 149–164, 2020, doi: <https://doi.org/10.1016/j.enbenv.2019.11.003>.
- [9] W. Amponsah and P. Kaur, “Exploratory Data Analysis And Crime Prevention Using Machine Learning: The case of Ghana,” *Int. J. Innov. Sci. Res. Technol.*, vol. 6, no. 3, pp. 613–621, 2021.
- [10] K. ESDM, *Rencana Usaha Penyediaan Tenaga Listrik PT PLN (Persero) 2015-2024*, no. 112. 2014.
- [11] P. A. Mahendra, W. Aribowo, and S. I. Haryudo, “Peramalan Susut Energi

- Jangka Pendek Menggunakan Metode Fuzzy Logic Dan Feed Forward Neural Network Berdasarkan Keseimbangan Beban,” *J. Tek. Elektro*, vol. 10, no. 2, pp. 453–462, 2021.
- [12] H. L. Latupeirissa, H. M. Muskita, and T. J. Tahalele, “Analisa Susut Daya Pada Sistem Distribusi Jaringan Tegangan Menengah,” *J. Simetrik*, vol. 10, no. 1, pp. 313–321, 2020, doi: 10.31959/js.v10i1.242.
- [13] D. Desmira, “Pengaruh Susut Energi (Losses) Pada Jaringan Distribusi (Studi Kasus: di PT. Krakatau Daya listrik),” *Energi & Kelistrikan*, vol. 12, no. 2, pp. 80–89, 2020, doi: 10.33322/energi.v12i2.1079.
- [14] A. D. Sidik and A. Ansawarman, “Prediksi Jumlah Kendaraan Bermotor Menggunakan Machine Learning,” *Formosa J. Multidiscip. Res.*, vol. 1, no. 3, pp. 559–568, 2022, doi: 10.55927/fjmr.v1i3.745.
- [15] A. Satria, R. M. Badri, and I. Safitri, “Prediksi Hasil Panen Tanaman Pangan Sumatera dengan Metode Machine Learning,” *Digit. Transform. Technol.*, vol. 3, no. 2, pp. 389–398, 2023, doi: 10.47709/digitech.v3i2.2852.
- [16] Z. Yi, K. Zhao, J. Sun, L. Wang, K. Wang, and Y. Ma, “Prediction of the Remaining Useful Life of Supercapacitors,” *Math. Probl. Eng.*, vol. 2022, 2022, doi: 10.1155/2022/7620382.
- [17] D. Fan, H. Sun, J. Yao, K. Zhang, X. Yan, and Z. Sun, “Well production forecasting based on ARIMA-LSTM model considering manual operations,” *Energy*, vol. 220, p. 119708, 2021, doi: <https://doi.org/10.1016/j.energy.2020.119708>.
- [18] T. Dimri, S. Ahmad, and M. Sharif, “Time series analysis of climate variables using seasonal ARIMA approach,” *J. Earth Syst. Sci.*, vol. 129, no. 1, 2020, doi: 10.1007/s12040-020-01408-x.
- [19] S. O. Adams, M. Bamanga, and M. Ardo Bamanga, “Modelling and Forecasting Seasonal Behavior of Rainfall in Abuja, Nigeria; A SARIMA Approach,” *Am. J. Math. Stat.*, vol. 2020, no. 1, pp. 10–19, 2020, doi: 10.5923/j.ajms.20201001.02.
- [20] J. Hu, X. Wang, Y. Zhang, D. Zhang, M. Zhang, and J. Xue, “Time Series Prediction Method Based on Variant LSTM Recurrent Neural Network,”

- Neural Process. Lett.*, vol. 52, no. 2, pp. 1485–1500, 2020, doi: 10.1007/s11063-020-10319-3.
- [21] H. Alizadegan, B. Rashidi Malki, A. Radmehr, H. Karimi, and M. A. Ilani, “Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction,” *Energy Explor. Exploit.*, 2024, doi: 10.1177/01445987241269496.
- [22] J. Ren, M. Zhang, C. Yu, and Z. Liu, “Balanced MSE for Imbalanced Visual Regression,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2022-June, pp. 7916–7925, 2022, doi: 10.1109/CVPR52688.2022.00777.
- [23] R. Kausar, F. Iqbal, A. Raziq, N. Sheikh, and A. Rehman, “Enhanced Foreign Exchange Volatility Forecasting using CEEMDAN with Optuna-Optimized Ensemble Deep Learning Model,” *Sains Malaysiana*, vol. 53, no. 9, pp. 3229–3239, 2024, doi: 10.17576/jsm-2024-5309-25.

