



**Analisis dan Prediksi Konsumsi Listrik *Smart Office* Berbasis
IoT Terhadap Faktor Internal dan Eksternal Menggunakan
*Deep Learning***

Zikri Wahyuzi

22917021

Tesis diajukan sebagai syarat untuk meraih gelar Magister Komputer

Konsentrasi Data Science

Program Studi Informatika Program Magister

Fakultas Teknologi Industri

Universitas Islam Indonesia

2024

Lembar Pengesahan Pembimbing

Analisis dan Prediksi Konsumsi Listrik *Smart Office* Berbasis IoT Terhadap Faktor Internal dan Eksternal Menggunakan *Deep Learning*

Zikri Wahyu

22917021

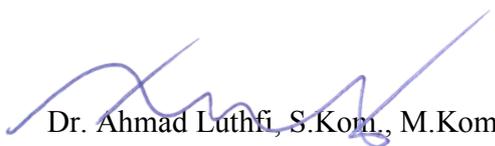


Yogyakarta, 10 Juni 2024

Pembimbing 1

Pembimbing 2


Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D


Dr. Ahmad Luthfi, S.Kom., M.Kom

Lembar Pengesahan Penguji

Analisis dan Prediksi Konsumsi Listrik *Smart Office* Berbasis IoT Terhadap Faktor Internal dan Eksternal Menggunakan *Deep Learning*

Zikri Wahyuzi

22917021

ISLAM

Yogyakarta, 24 Juni 2024

Tim Penguji,

Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D

Ketua

Mukhammad Andri Setiawan, S.T., M.Sc., Ph.D

Anggota I

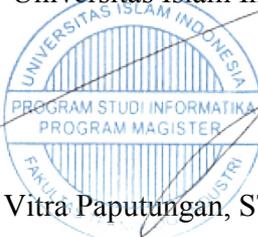
Dr. Ahmad Luthfi, S.Kom., M.Kom

Anggota II

Mengetahui,

Ketua Program Studi Informatika Program Magister

Universitas Islam Indonesia



Irving Vitra Papatungan, ST., M.Sc., Ph.D

Abstrak

Analisis dan Prediksi Konsumsi Listrik Smart Office Berbasis IoT Terhadap Faktor Internal dan Eksternal Menggunakan Deep Learning

Transformasi digital mendorong perusahaan di seluruh dunia untuk meningkatkan efisiensi operasional, termasuk mengurangi konsumsi listrik di gedung perkantoran. Oleh karena itu, kebutuhan akan monitoring dan prediksi konsumsi listrik di dalam perusahaan menjadi hal yang sangat penting karena dapat membantu proses efisiensi dalam meningkatkan penghematan biaya operasional. Dalam konteks ini, perusahaan yang dilengkapi dengan sistem *smart office* memiliki keunggulan dalam meramalkan konsumsi listrik karena menghasilkan data hasil ekstraksi yang dapat diolah lebih lanjut. Sehingga, pada penelitian ini penulis membangun sistem monitoring *smart office* berbasis IoT pada perkantoran konvensional. Hal ini bertujuan untuk dapat melakukan ekstraksi data konsumsi listrik, serta data kondisi internal dan eksternal bangunan kantor. Data historis hasil ekstraksi sensor-sensor IoT yang tertanam pada sistem monitoring *smart office* diolah lebih lanjut melalui proses *pre-processing*, *exploratory* dan *feature engineering*. Termasuk juga didalamnya dilakukan analisis tren konsumsi listrik harian perkantoran. Kemudian, model prediksi dibangun dengan membandingkan implementasi arsitektur *deep learning* GRU dan Bi-GRU. Hasil penelitian menunjukkan bahwa model BiGRU menghasilkan performa prediksi yang lebih baik dibandingkan dengan GRU, meskipun memiliki kompleksitas yang lebih tinggi. Dengan menggunakan data historis satu minggu sebelumnya, model BiGRU dapat memprediksi konsumsi listrik satu hari ke depan dengan lebih akurat. Evaluasi model menunjukkan bahwa BiGRU memiliki kinerja yang lebih unggul dibandingkan dengan GRU. Hal ini terlihat dari nilai MSE, RMSE, dan MAE yang lebih rendah, serta R^2 yang lebih tinggi untuk BiGRU. Pada tahap pengujian, model BiGRU menghasilkan prediksi yang lebih akurat, dengan MAE sebesar 0,0188 dibandingkan dengan GRU yang memiliki MAE sebesar 0,0231. Selain itu, selisih total konsumsi listrik harian antara prediksi dan data aktual adalah 11,76 kWh untuk BiGRU, sementara GRU memiliki selisih sebesar 23,68 kWh. Walaupun waktu pelatihan BiGRU lebih lama, model ini tetap menjadi pilihan terbaik berkat keakuratan prediksinya yang lebih tinggi.

Kata kunci

Smart Office, Prediksi Konsumsi Listrik, Cuaca untuk Peramalan Beban, *Deep Learning*, *Data Time Series*, *Internet of Things*.

Abstract

Analysis and Prediction of Smart Office Electricity Consumption Based on IoT in Relation to Internal & External Factors Using Deep Learning

Digital transformation is driving companies worldwide to enhance operational efficiency, including reducing electricity consumption in office buildings. Consequently, the need for monitoring and predicting electricity consumption within companies has become crucial, as it aids in achieving operational cost savings. In this context, companies equipped with smart office systems have an advantage in forecasting electricity consumption because they generate extracted data that can be further processed. Therefore, in this study, the author developed an IoT-based smart office monitoring system for conventional office buildings. The aim is to extract data on electricity consumption and the internal and external conditions of the office building. The historical data extracted from IoT sensors embedded in the smart office monitoring system is further processed through pre-processing, exploratory analysis, and feature engineering. This also includes the analysis of daily electricity consumption trends in offices. Subsequently, predictive models were built by comparing the implementation of deep learning architectures: GRU and Bi-GRU. The research results indicate that the BiGRU model yields better predictive performance than the GRU, despite being more complex. Using historical data from the previous week, the BiGRU model can more accurately predict the next day's electricity consumption. The model evaluation indicates that the BiGRU outperforms the GRU, showing lower MSE, RMSE, and MAE values, as well as a higher R^2 . During testing, the BiGRU model produced predictions closer to the actual data, with an MAE of 0.0188 compared to the GRU's MAE of 0.0231. Furthermore, the daily electricity consumption deviation between the predicted and actual data was 11.76 kWh for BiGRU, whereas it was 23.68 kWh for GRU. Although the BiGRU model requires longer training time, it remains the best choice due to its higher prediction accuracy.

Keywords

Smart Office, Electricity Consumption Prediction, Weather For Load Forecasting, Deep Learning, Time Series Data, Internet of Things.

Pernyataan Keaslian Tulisan

Dengan ini saya menyatakan bahwa tesis ini merupakan tulisan asli dari penulis, dan tidak berisi material yang telah diterbitkan sebelumnya atau tulisan dari penulis lain terkecuali referensi atas material tersebut telah disebutkan dalam tesis. Apabila ada kontribusi dari penulis lain dalam tesis ini, maka penulis lain tersebut secara eksplisit telah disebutkan dalam tesis ini.

Dengan ini saya juga menyatakan bahwa segala kontribusi dari pihak lain terhadap tesis ini, termasuk bantuan analisis statistik, desain survei, analisis data, prosedur teknis yang bersifat signifikan, dan segala bentuk aktivitas penelitian yang dipergunakan atau dilaporkan dalam tesis ini telah secara eksplisit disebutkan dalam tesis ini.

Segala bentuk hak cipta yang terdapat dalam material dokumen tesis ini berada dalam kepemilikan pemilik hak cipta masing-masing. Apabila dibutuhkan, penulis juga telah mendapatkan izin dari pemilik hak cipta untuk menggunakan ulang materialnya dalam tesis ini.

Yogyakarta, 24 Juni 2024



Zikri Wahyuzi, S.T

Daftar Publikasi

Publikasi yang menjadi bagian dari tesis

Wahyuzi, Z., Ahmad Luthfi, & Dhomas Hatta Fudholi. (2024). Predicting Smart Office Electricity Consumption in Response to Weather Conditions Using Deep Learning. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 8(1), 100 - 110. <https://doi.org/10.29207/resti.v8i1.5530>.

Sitasi publikasi 1

Kontributor	Jenis Kontribusi
Zikri Wahyuzi	Mendesain eksperimen (60%) Menulis <i>paper</i> (70%)
Dhomas Hatta Fudholi	Mendesain eksperimen (20%) Menulis dan mengedit <i>paper</i> (15%)
Ahmad Luthfi	Mendesain eksperimen (20%) Menulis dan mengedit <i>paper</i> (15%)

Halaman Kontribusi

Dalam tesis ini, terdapat beberapa kontribusi dari pihak lain, diantaranya:

1. Kementerian Pendidikan, Kebudayaan, Riset dan Teknologi Republik Indonesia, yang telah mendanai penelitian ini melalui skema Hibah Penelitian Tesis Magister, dengan Nomor Kontrak: 031/DirDPPM/70/DPPM/PPS-PTM-KEMDIKBUDRIS TEK/VI/2023. Dukungan finansial ini memungkinkan penulis untuk melakukan penelitian dan penulisan publikasi artikel dan tesis secara mendalam.
2. Manajer dan karyawan PLN Icon Plus Unit Layanan D.I Yogyakarta, yang telah memberikan izin dan dukungan sebagai objek observasi pada proses pengumpulan data dalam penelitian tesis ini. Kontribusi ini sangat penting untuk memungkinkan penulis mendapatkan data dan informasi yang relevan. Tanpa izin dan kerja samanya, penelitian tesis ini tidak akan dapat dilakukan secara efektif.
3. Tim Magang/PKL Politeknik Negeri Jember, yang telah membantu dalam proses pembangunan sistem monitoring berbasis IoT pada penelitian ini sehingga proses pengumpulan data yang dilakukan penulis dapat berjalan dengan baik.
4. Pembimbing tesis yang telah memberikan bimbingan dan masukan yang berharga, mulai dari konsep dan desain penelitian hingga analisis dan interpretasi data penelitian. Masukan dari pembimbing juga membantu dalam menyusun draf tesis dan melakukan perbaikan yang signifikan, sehingga meningkatkan kualitas interpretasi hasil penelitian.

Halaman Persembahan

Tesis ini penulis persembahkan dengan rasa syukur dan terima kasih kepada pihak-pihak yang telah memberikan dukungan dan bantuan selama masa studi di Program Studi Informatika, Program Magister Universitas Islam Indonesia.

Pertama, penulis ingin menyampaikan terima kasih yang sebesar-besarnya kepada Universitas Muhammadiyah Bangka Belitung, yang telah memberikan beasiswa dan dukungan finansial yang memungkinkan penulis untuk menyelesaikan studi ini. Dukungan ini menjadi pondasi utama dalam perjalanan akademik saya.

Selanjutnya, dengan penuh kasih dan rasa hormat, penulis ingin mengucapkan terima kasih kepada keluarga. Terutama untuk istri ku “Dyah Dwisa”, terima kasih atas cinta dan dukungan tanpa batas, serta kesabaran dan pengertian selama masa-masa sulit. Untuk anak ku “Belleva Risa Zanitha”, terima kasih telah menjadi sumber inspirasi dan semangat. penulis juga ingin mengucapkan terima kasih kepada orang tua, adik, mertua, kakak ipar dan keluarga besar, yang selalu memberikan dukungan moral dan bimbingan, serta menjadi teladan bagi penulis.

Dukungan dari semua pihak ini adalah alasan penulis dapat menyelesaikan tesis ini sehingga mencapai titik karier akademik yang di cita-citakan. Terima kasih kepada semuanya atas cinta, dukungan, dan dorongan yang tiada henti.

Kata Pengantar

Assalamu'alaikum Warahmatullahi Wabarakatuh,

Bismillahirrahmanirrahim, Puji dan syukur senantiasa penulis panjatkan kepada Allah SWT yang telah memberikan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan tesis ini dengan judul "Analisis dan Prediksi Konsumsi Listrik *Smart Office* Berbasis IoT Terhadap Faktor Internal & Eksternal Menggunakan *Deep Learning*". Tesis ini disusun sebagai salah satu syarat untuk memperoleh gelar Magister di Program Studi Informatika, Fakultas Teknik Industri, Universitas Islam Indonesia.

Dalam penyusunan dan penyelesaian tesis ini, penulis telah menerima banyak bantuan dan dukungan dari berbagai pihak. Oleh karena itu, penulis ingin menyampaikan ucapan terima kasih yang tulus kepada:

1. Bapak Prof. Fathul Wahid, S.T., M.Sc., Ph.D., selaku Rektor Universitas Islam Indonesia, atas dukungan dan arahannya selama studi saya di universitas ini.
2. Bapak Irving Vitra Papatungan, S.T., M.Sc., Ph.D., selaku Ketua Program Studi Magister Informatika Universitas Islam Indonesia, yang telah memberikan bimbingan dan fasilitas selama proses studi.
3. Bapak Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D., dan Bapak Dr. Ahmad Luthfi, S.Kom., M.Kom selaku dosen pembimbing, yang telah memberikan banyak saran/usulan, motivasi, ide, serta kritik yang membangun selama penyusunan tesis ini.
4. Dosen Program Studi Magister Informatika Universitas Islam Indonesia yang telah memberikan ilmu, bimbingan dan bantuan selama masa studi. Semoga ilmu yang diberikan menjadi amal jariyah yang bermanfaat.
5. Staff Akademik Program Studi Magister Informatika Universitas Islam Indonesia, yang telah membantu dalam segala urusan administrasi.
6. Bapak Ir. Fadillah Sabri, S.T., M.Eng., IPM selaku Rektor Universitas Muhammadiyah Bangka Belitung, atas dukungan dan arahan berupa beasiswa pendidikan selama studi magister ini.
7. Ibu Eka Altiarika, S.Kom., M.Eng selaku Kepala Program Studi Ilmu Komputer Universitas Muhammadiyah Bangka Belitung, atas dukungan, arahan, dan saran dalam penyelesaian pendidikan magister ini.
8. Dosen dan staff Universitas Muhammadiyah Bangka Belitung, atas segala dukungan dan bantuan yang diberikan dalam proses beasiswa magister ini.

9. Karyawan PLN Icon Plus Unit Layanan DIY dan SBU Jawa Bagian Tengah, atas dukungan dan doa dalam penyelesaian pendidikan magister ini.
10. Tim PKL/Magang Politeknik Negeri Jember (Muhammad Aman Ahcyad, Nadia Hidayanti Suseno, Nelsen Ardiansah, Lutfi Ardiansyah, Alfiani Nur Aziza, Nanda Arsyah Salsabillah, Sindi Permata Zahro, M Condro Asep Saputra), atas segala dukungan dan bantuan yang diberikan dalam pembangunan sistem monitoring pada penelitian ini.
11. Sahabat dan Teman yang tidak dapat penulis sebutkan satu persatu, atas segala dukungan dan bantuan dalam bentuk apapun.

Penulis menyadari bahwa tesis ini masih memiliki kekurangan dan kelemahan. Oleh karena itu, penulis sangat terbuka terhadap kritik dan saran yang sifatnya membangun agar tesis ini dapat menjadi lebih baik di masa mendatang.

Wassalamu'alaikum Warahmatullahi Wabarakatuh,

Daftar Isi

Lembar Pengesahan Pembimbing	i
Lembar Pengesahan Penguji.....	ii
Abstrak.....	iii
Abstract.....	iv
Pernyataan Keaslian Tulisan	v
Daftar Publikasi	vi
Halaman Kontribusi.....	vii
Halaman Persembahan	viii
Kata Pengantar.....	ix
Daftar Isi	xi
Daftar Tabel.....	xiv
Daftar Gambar	xv
Glosarium	xvi
BAB 1 Pendahuluan	1
1.1 Pendahuluan.....	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	4
1.5 Struktur Laporan	4
BAB 2 Tinjauan Pustaka	5
2.1 Penelitian Terdahulu	5
2.2 <i>Smart Office</i>	12
2.3 <i>Data Pre-processing</i>	13
2.4 <i>Data Exploratory</i>	14
2.5 <i>Feature Engineering</i>	15

2.6	<i>Deep Learning</i> untuk Prediksi	15
2.6.1	<i>Gated Recurrent Unit (GRU)</i>	16
2.6.2	<i>Bidirectional GRU (BiGRU)</i>	17
2.7	Metrik Evaluasi.....	18
2.7.1	<i>Mean Squared Error (MSE)</i>	18
2.7.2	<i>Root Mean Squared Error (RMSE)</i>	19
2.7.3	<i>Mean Absolute Error (MAE)</i>	19
2.7.4	<i>R-Square (R2)</i>	19
BAB 3 Metodologi		21
3.1	Tinjauan Pustaka.....	22
3.2	Pengumpulan Data.....	22
3.2.1	Lokasi dan Waktu.....	23
3.2.2	Infrastruktur Pengumpulan Data	24
3.2.3	Output Data.....	26
3.3	Pemrosesan Dataset	28
3.3.1	Data Pre-processing.....	28
3.3.2	Data Exploratory & Analysis	30
3.3.3	Feature Engineering.....	30
3.4	Pembangunan Model Prediksi	31
3.4.1	Pelatihan Model Prediksi.....	32
3.4.2	Validasi Model Prediksi	34
3.4.3	Pengujian Model Prediksi.....	34
3.5	Evaluasi Model	35
BAB 4 Hasil dan Pembahasan.....		36
4.1	Sistem Monitoring <i>Smart Office</i> Berbasis IoT.....	36
4.1.1	<i>Physical Environment</i>	37
4.1.2	<i>Virtual Environment</i>	39

4.1.3	Output Infrastruktur Pengumpulan Data	42
4.2	Pemrosesan Dataset	43
4.2.1	<i>Data Pre-processing</i>	43
4.2.2	<i>Data Exploratory & Analysis</i>	44
4.2.3	<i>Feature Engineering</i>	49
4.3	Pembangunan Model Prediksi dan Evaluasi Model	50
4.3.1	Pelatihan dan Validasi Model	50
4.3.2	Pengujian Model	53
4.3.3	Evaluasi Model	56
4.4	Analisis Hasil dan Diskusi	58
BAB 5 Kesimpulan dan Saran		61
5.1	Kesimpulan	61
5.2	Saran	61
Daftar Pustaka		63
LAMPIRAN A		71
LAMPIRAN B		73

Daftar Tabel

Tabel 2.1 Ulasan Kritis Tema Penelitian.....	7
Tabel 3.1 Dataset Monitoring Kelistrikan	26
Tabel 3.2 Dataset Monitoring Indor	27
Tabel 3.3 Dataset Monitoring Outdoor.....	27
Tabel 3.4 Dataset Monitoring Kecepatan Angin	28
Tabel 3.5 Penyesuaian <i>Hyperparameter</i>	33
Tabel 4.1 Dataset Hasil <i>Export</i> dari Website	42
Tabel 4.2 Statistik Deskriptif Penggunaan Listrik Jam Kerja & Diluar Jam Kerja.....	49
Tabel 4.3 <i>Tuning Hyperparameter</i> Pada GRU & BiGRU.....	50
Tabel 4.4 Perbandingan Hasil Evaluasi Model Input Data Historis.....	51
Tabel 4.5 Perbandingan Hasil Evaluasi Model Target Prediksi	52
Tabel 4.6 Perbandingan Aktual & Prediksi Konsumsi Listrik Per Jam 26/01/2024 - GRU 54	
Tabel 4.7 Perbandingan Aktual & Prediksi Konsumsi Listrik Per Jam 26/01/2024 - BiGRU	56
Tabel 4.8 Perbandingan Hasil Evaluasi Model Pada Tahap Pengujian.....	57

Daftar Gambar

Gambar 2.1 <i>High Level Architecture Smart Office</i> (Barisic et al., 2020).....	12
Gambar 2.2 Arsitektur GRU.....	16
Gambar 2.3 Arsitektur BiGRU.....	18
Gambar 3.1 Langkah-Langkah Penelitian.....	21
Gambar 3.2 Kondisi Kantor PLN Icon Plus Unit Layanan D.I Yogyakarta.....	23
Gambar 3.3 Rancangan Infrastruktur Pengumpulan Data Sistem Monitoring <i>Smart Office</i>	24
Gambar 3.4 Hubungan Antara <i>Physical</i> dan <i>Virtual Environment</i>	24
Gambar 3.5 Rancangan Halaman Dashboard Website.....	25
Gambar 3.6 Rancangan Halaman <i>Export Data Website</i>	26
Gambar 4.1 Rangkaian Sensor <i>Indoor</i>	37
Gambar 4.2 Rangkaian Sensor <i>Outdoor</i>	38
Gambar 4.3 Tampilan <i>Dashboard Website</i> kantorku.cloud.....	40
Gambar 4.4 Tampilan Halaman <i>Export Data</i> Kelistrikan.....	41
Gambar 4.5 Tampilan Halaman <i>Export Data</i> Indor.....	41
Gambar 4.6 Tampilan Halaman <i>Export Data</i> Outdoor.....	41
Gambar 4.7 Tampilan Halaman <i>Export Data</i> Angin.....	42
Gambar 4.8 Deskripsi dataset gabungan dengan nama 'df_combined'.....	44
Gambar 4.9 Tren Pemakaian Listrik 04/07/2023 - 07/01/2024.....	45
Gambar 4.10 <i>Heatmap</i> Korelasi Antar Variabel.....	46
Gambar 4.11 <i>Heatmap</i> Rata-rata Penggunaan Listrik Per Jam Dalam Seminggu.....	47
Gambar 4.12 Rata-rata Penggunaan Listrik Harian Dalam jam.....	47
Gambar 4.13 Rata-rata Penggunaan Listrik Per Hari.....	48
Gambar 4.14 <i>Training Model Loss</i> GRU.....	53
Gambar 4.15 <i>Training Model Loss</i> BiGRU.....	53
Gambar 4.16 Perbandingan Aktual & Prediksi Konsumsi Listrik 26/01/2024 - GRU.....	54
Gambar 4.17 Perbandingan Aktual & Prediksi Konsumsi Listrik 26/01/2024 - BiGRU....	55

Glosarium

IoT	- Internet of Things
RNN	- Recurrent Neural Network
LSTM	- Long Short-Term Memory
GRU	- Gated Recurrent Unit
LSTM	- Long Short-Term Memory
Bi-LSTM	- Bidirectional Long Short-Term Memory
Bi-GRU	- Bidirectional Gated Recurrent Unit
KESDM	- Kementerian Energi dan Sumber Daya Mineral
UNDP	- United Nations Development Programme
ML	- Machine Learning
GRNN	- Generalized Regression Neural Network
SVM	- Support Vector Machine
ANN	- Artificial Neural Network
KNN	- K-Nearest Neighbor
TCN	- Temporal Convolutional Network
FCM	- Fuzzy C-Means
GWO	- Grey Wolf Optimizer
BP	- Backpropagation
XGBoost	- Extreme Gradient Boosting
MSE	- Mean Squared Error
RF	- Random Forest
CNN	- Convolutional Neural Network
DWT	- Discrete Wavelet Decomposition
MAE	- Mean Absolute Error
SA	- Self Attention
HVAC	- Heating, Ventilation, and Air Conditioning
MSE	- Mean Squared Error
RMSE	- Root Mean Squared Error
MAE	- Mean Absolute Error

BAB 1

Pendahuluan

1.1 Pendahuluan

Transformasi digital telah menjadi salah satu faktor kunci yang memengaruhi efisiensi operasional dan budaya kerja di berbagai perusahaan (Martínez-Peláez et al., 2023). Perusahaan dituntut untuk terus mencari metode adaptasi yang tepat agar dapat menghasilkan keuntungan yang konsisten secara terus menerus (Mantese et al., 2022). Oleh karena itu, proses efisiensi menjadi faktor penting yang harus dilakukan dalam perjalanan bisnis perusahaan, salah satunya efisiensi biaya operasional. Peningkatan efisiensi biaya operasional akan menjadi fokus utama untuk mengurangi pengeluaran sehingga dapat memaksimalkan laba bersih (Lin et al., 2022). Efisiensi biaya operasional bisnis dapat dicapai salah satunya dengan mengurangi konsumsi energi listrik di gedung perkantoran (Danial et al., 2023). Menurut survei tentang penggunaan energi yang dilakukan oleh KESDM-UNDP, gedung perkantoran menempati peringkat ketiga dalam daftar penggunaan energi setelah pusat perbelanjaan dan hotel. dimana mayoritas energi yang digunakan di gedung perkantoran berasal dari pasokan listrik (Direktorat Jendral Energi Baru Terbarukan Dan Konservasi Energi (EBTKE), 2019).

Peningkatan biaya penggunaan listrik berbanding lurus dengan kenaikan biaya operasional, yang pada akhirnya dapat mengurangi laba bersih perusahaan (Ali et al., 2020). Oleh karena itu, prediksi yang tepat tentang penggunaan listrik sangat penting untuk bisnis, karena dapat menghindari pengeluaran yang tidak perlu, mengurangi biaya operasional, serta dapat melakukan optimalisasi pasokan energi listrik (Jogunola et al., 2022). Penelitian Bunn dan Farmer (Bunn & Farmer, 1985) menunjukkan bahwa kenaikan 1% dalam kesalahan saat melakukan prediksi beban listrik dapat menyebabkan kenaikan biaya operasional hampir 10 juta pondsterling setiap tahunnya. Hal ini menunjukkan bahwa bahkan ketidakakuratan kecil dalam prediksi dapat berdampak signifikan pada biaya operasional perusahaan (Chitalia et al., 2020).

Memprediksi konsumsi listrik di gedung perkantoran adalah tugas yang kompleks karena banyaknya variabel yang tidak terduga yang dapat mempengaruhi penggunaan energi secara signifikan (S. Chen et al., 2021). Kesalahan dalam prediksi sering kali bukan hanya disebabkan oleh faktor internal seperti aktivitas harian di kantor, tetapi juga oleh faktor eksternal seperti perubahan pola cuaca, hari libur, dan perilaku karyawan (Hwang et al.,

2020). Chenghong Wang dan rekan-rekannya menekankan bahwa faktor cuaca memiliki peran krusial dalam membentuk pola konsumsi energi, dan memahami dampaknya secara menyeluruh sangatlah penting (Wang et al., 2023). Tantangan ini membutuhkan pendekatan pemodelan yang kompleks yang mampu mengakomodasi interaksi variabel-variabel yang dinamis dan rumit. Oleh karena itu, metodologi yang sedang berkembang seperti algoritma *machine learning* dan model *deep learning* telah menjadi semakin populer untuk meningkatkan akurasi prediksi konsumsi listrik (Vijendar Reddy et al., 2023).

Sejalan dengan tantangan ini, konsep *smart office* muncul sebagai solusi inovatif untuk mendukung prediksi konsumsi listrik dengan lebih akurat. *Smart office* menggunakan teknologi komputasi dan komunikasi yang canggih untuk menciptakan ruang kerja yang efisien dan produktif (Alomoush et al., 2022; Floris et al., 2021). Kerangka kerja "*high-level architecture smart office*" menunjukkan bagaimana teknologi pintar seperti *Internet of Things* (IoT) dapat diintegrasikan dalam pengaturan kantor modern untuk meningkatkan efisiensi operasional dan kinerja perusahaan (Barisic et al., 2020). Dengan adanya sistem monitoring yang cerdas, *smart office* dapat mengumpulkan data historis yang mendalam mengenai penggunaan energi. Data ini dapat memberikan wawasan berharga yang memungkinkan peningkatan dan pengoptimalan prediksi konsumsi listrik secara lebih akurat (Ramos et al., 2022).

Dalam konteks prediksi konsumsi listrik pada perkantoran, penggunaan model *deep learning* seperti *Gated Recurrent Unit* (GRU) dan *Bidirectional Gated Recurrent Unit* (Bi-GRU) menjadi relevan untuk menangani kompleksitas dalam prediksi konsumsi listrik (Mahjoub et al., 2022; Niu et al., 2022). Dimana GRU adalah varian dari *Recurrent Neural Network* (RNN) yang dioptimalkan untuk menyimpan dan memproses informasi penting dalam urutan waktu panjang tanpa mengorbankan efisiensi komputasi. GRU lebih efisien dibandingkan dengan LSTM karena arsitekturnya yang lebih sederhana namun tetap mampu menangani masalah *vanishing gradient* (Mateus et al., 2021). Di sisi lain, Bi-GRU dapat menangkap hubungan antara data historis dengan cara melihat ke depan dan ke belakang dalam urutan waktu, yang membuatnya ideal untuk aplikasi yang membutuhkan analisis temporal mendalam (Dey et al., 2023).

Banyak penelitian terdahulu sebagian besar hanya fokus pada memprediksi konsumsi listrik di rumah atau tempat kerja dengan menggunakan faktor-faktor internal, baik menggunakan algoritma *machine learning* atau model *deep learning*. Namun, hanya sedikit penelitian yang meneliti pengaruh faktor eksternal sebagai faktor yang bisa memengaruhi konsumsi listrik (Asif Karim, Rootul Patel, 2021; Chou et al., 2019; Peng et al., 2022; Shapi

et al., 2021; Tian et al., 2020). Oleh karena itu, penelitian ini bertujuan untuk membangun sistem monitoring *smart office* berbasis IoT terhadap kondisi internal dan eksternal gedung kantor, ekstraksi dan analisa data historis, serta membangun model prediksi berbasis *deep learning* terhadap konsumsi listrik. Data historis yang tersimpan oleh sistem monitoring *smart office* akan dilakukan proses *pre-processing*, *data exploratory*, dan *feature engineering*. Selanjutnya, data historis ini digunakan sebagai inputan model prediksi konsumsi listrik dengan menggunakan arsitektur *deep learning*. Keunikan penelitian ini terletak pada fokusnya yang tidak hanya pada analisa dan prediksi dari data historis yang didapatkan. Namun, penelitian ini juga membangun infrastruktur pengumpulan data berupa sistem monitoring *smart office* berbasis IoT pada kantor konvensional untuk mendapatkan data historis yang sesuai dengan kearifan lokal perusahaan di Indonesia. Keunikan lainnya, pada penelitian ini juga dilakukan komparasi terhadap kemampuan arsitektur *deep learning* yang digunakan, yaitu GRU dan Bi-GRU. Komparasi ini bertujuan untuk melihat perbandingan akurasi prediksi dan skalabilitas model agar dapat melakukan prediksi konsumsi listrik yang paling efektif terhadap data yang berhasil terkumpul. Harapannya, sistem monitoring *smart office* berbasis IoT dan model prediksi konsumsi listrik berbasis *deep learning* ini dapat digunakan sebagai sistem rekomendasi pengambilan keputusan yang dapat membantu operasional perusahaan. Dimana perusahaan dapat memantau, mengoptimalkan dan merencanakan penggunaan energi listrik yang lebih efisien dan terkomputasi. Harapan kedepannya, sistem monitoring dan model prediksi konsumsi listrik ini dapat dikembangkan lebih lanjut untuk membangun model efisiensi terotomatisasi pada sistem *smart office*, sehingga dapat mengurangi biaya operasional dan meningkatkan pendapatan bersih perusahaan.

1.2 Rumusan Masalah

1. Bagaimana membangun sistem monitoring *smart office* berbasis IoT pada kantor konvensional?
2. Bagaimana melakukan analisa terhadap tren konsumsi listrik harian pada perkantoran lokal Indonesia?
3. Bagaimana membangun model prediksi konsumsi listrik perkantoran menggunakan arsitektur *deep learning* GRU dan Bi-GRU?

1.3 Tujuan Penelitian

1. Membangun sistem monitoring *smart office* berbasis IoT pada kantor konvensional.

2. Melakukan analisa terhadap tren konsumsi listrik harian pada perkantoran lokal indonesia.
3. Membangun model prediksi konsumsi listrik perkantoran menggunakan arsitektur *deep learning* GRU dan Bi-GRU.

1.4 Manfaat Penelitian

Sistem monitoring *smart office* berbasis IoT dan model prediksi konsumsi listrik berbasis *deep learning* ini dapat digunakan sebagai sistem rekomendasi bagi pengelola bisnis, pimpinan perusahaan dan para peneliti bidang *smart city* untuk dapat memantau, mengoptimalkan dan merencanakan penggunaan listrik yang lebih efisien pada perkantoran. Dengan manfaat lebih lanjut agar sistem monitoring dan model prediksi konsumsi listrik ini dapat dikembangkan lagi untuk membangun model efisiensi terotomatisasi pada sistem *smart office*, sehingga tujuan perusahaan dapat terwujud dalam upaya mengurangi biaya operasional dan mendapatkan keuntungan bersih sebesar-besarnya.

1.5 Struktur Laporan

BAB 1 Pendahuluan

Berisi tentang deskripsi mengenai bidang penelitian, temuan yang relevan dari penelitian sebelumnya, masalah penelitian, rumusan masalah, tujuan, manfaat, dan struktur penulisan laporan penelitian.

BAB 2 Tinjauan Pustaka

Bagian ini berisi kajian kritis atas pustaka yang relevan dengan bidang penelitian dan rumusan masalah, baik berupa artikel jurnal, konferensi, buku, dan laporan penelitian.

BAB 3 Metodologi

Bagian ini memuat metode yang dipilih beserta argumentasinya dan uraian tentang langkahnya. Metode yang dituliskan termasuk untuk pengumpulan, pengujian, dan analisis data. Bagian ini juga memuat model yang dikonstruksi dan hipotesis yang diformulasikan.

BAB 4 Hasil dan Pembahasan

Bagian ini menyajikan gambaran sistem yang telah dibuat, konsideran munculnya rancangan, informasi data yang dikumpulkan melalui proses observasi pada penelitian ini.

BAB 5 Kesimpulan dan Saran

Bagian ini merangkum masalah, temuan-temuan pokok, dan diskusi yang ditulis di tinjauan pustaka. Bagian ini juga berisi bagaimana temuan penelitian menjawab rumusan masalah, implikasi dari hasil penelitian, keterbatasan, dan arah penelitian selanjutnya.

BAB 2

Tinjauan Pustaka

2.1 Penelitian Terdahulu

Dalam membangun model prediksi konsumsi listrik pada perkantoran, penulis telah melakukan kajian terhadap beberapa penelitian terdahulu dalam bidang konsumsi energi listrik pada gedung perkantoran (Tian et al., 2020), gedung apartemen (Nabavi et al., 2021), rumah (Asif Karim, Rootul Patel, 2021), bahkan pada kota (Alomoush et al., 2022). Penulis menemukan bahwa tidak hanya faktor internal dengan data hasil sensor dalam ruangan yang menjadi variabel penting dalam proses prediksi konsumsi listrik, tapi faktor eksternal seperti cuaca juga menjadi salah satu variabel yang dapat memengaruhi prediksi terhadap konsumsi listrik suatu bangunan (Aisyah et al., 2022; Brahim, 2021; L. Li et al., 2017). Model yang dibangun untuk melakukan prediksi terhadap konsumsi listrik juga beragam, beberapa diantaranya yang sangat populer seperti model prediksi menggunakan *machine learning* dan *deep learning*. Penggunaan berbagai model ini memberikan fleksibilitas dan akurasi yang tinggi dalam memprediksi pola konsumsi listrik dengan baik sesuai dengan kebutuhan data yang tersedia (Chou et al., 2019; Mahjoub et al., 2022; Niu et al., 2022).

Penelitian oleh Mel Keytingan dan tim pada 2021, mereka mengembangkan model prediktif untuk memprediksi konsumsi listrik menggunakan *machine learning* di Microsoft Azure Cloud (Shapi et al., 2021). Penelitian ini dilakukan di Malaysia pada 2 gedung komersial dengan sistem *smart building*. Menggunakan 3 algoritma *machine learning*, yaitu SVM, ANN, dan KNN, data input berasal dari pemakaian listrik selama 7 bulan (Juni 2018 - Desember 2018). Hasilnya menunjukkan bahwa SVM memiliki kinerja prediksi konsumsi listrik terbaik dengan nilai RMSE terendah dan akurasi tinggi dalam memprediksi permintaan energi listrik. Meskipun demikian, pelatihan model SVM membutuhkan waktu yang lama (13-18 jam) dibandingkan dengan ANN dan KNN. Penggunaan Azure ML sebagai platform *cloud* untuk pengembangan model prediksi memiliki beberapa keunggulan, tetapi memerlukan pemrograman R untuk mengatasi keterbatasan algoritma di Azure ML. Secara keseluruhan, penelitian ini berhasil mencapai tujuan dan memberikan wawasan penting untuk prediksi konsumsi listrik di *smart building*.

Penelitian kedua oleh Shaikh dan tim pada tahun 2023, mereka mengembangkan model TCN untuk peramalan konsumsi listrik musiman di *smart grids* (Shaikh et al., 2023). Penelitian ini menggunakan data dari konsumen di Inggris dengan empat musim berbeda dan membandingkan performa TCN dengan LSTM berdasarkan eror *Mean Absolute*

Deviation (MAD) dan *Symmetric Mean Absolute Percentage Error* (sMAPE). Hasilnya menunjukkan bahwa TCN memiliki akurasi yang lebih baik dan waktu komputasi yang lebih cepat dibandingkan LSTM. TCN mampu memprediksi konsumsi energi dengan lebih baik selama musim semi, musim panas, musim gugur, dan musim dingin, terutama dalam menghadapi fluktuasi tinggi selama musim panas dan musim dingin. Kesimpulannya, TCN lebih unggul dalam mengolah data besar dan memberikan prediksi *real-time* yang akurat, sehingga dapat membantu menjaga stabilitas *grid* dan mengoptimalkan sistem energi di lingkungan *smart grid*.

Penelitian ketiga yang dilakukan oleh Siti Aisyah dan tim pada tahun 2022, mereka melakukan analisis dan merancang sistem prediksi beban listrik berbasis model *machine learning* berdasarkan parameter cuaca (Aisyah et al., 2022). Penelitian ini juga berfokus pada eskplorasi data cuaca dan data beban listrik, kemudian dilakukan optimasi fitur menggunakan metode statistik koefisien korelasi pada model prediksi yang akan dibangun. Tujuan dari penelitian ini yaitu untuk melihat melihat faktor cuaca mana yang memiliki pengaruh tinggi terhadap beban listrik di pulau bali dan membangun model prediksi bebannya. Hasil dari penelitian ini menunjukkan bahwa faktor cuaca dengan nilai korelasi tertinggi terhadap beban listrik di Bali adalah suhu, yang diikuti oleh radiasi matahari dan kecepatan angin. Model prediksi yang dibangun ini juga berhasil meningkatkan akurasi prediksi beban listrik cukup tinggi dengan menggunakan algoritma GRNN dan SVM, yaitu dengan nilai korelasi masing-masing 0,95 dan 0,965.

Penelitian keempat yang dilakukan oleh Mahjoub dan tim pada tahun 2022, mereka bertujuan untuk memodelkan dan membandingkan tiga algoritma *deep learning* untuk membuat prediksi konsumsi daya listrik dalam deret waktu 1 hari, 3 hari, 7 hari dan 15 hari (Mahjoub et al., 2022). Data yang digunakan dalam proses analisa dan prediksi pada penelitian ini diambil dari proyek penelitian *smart grid* dengan nama VERTPOM. Model yang diusulkan menggunakan LSTM, GRU, dan Drop-GRU. Hasil eksperimen dari penelitian pada berbagai jenis waktu yang ditentukan menunjukkan bahwa model LSTM menghasilkan akurasi yang lebih baik dibandingkan dengan metode prediksi GRU dan Drop-GRU. Model LSTM memiliki lebih sedikit kesalahan prediksi dan presisinya lebih baik dari kedua model *deep learning* yang lainnya.

Penelitian kelima oleh Jogunola dan tim pada 2022 menyajikan model berbasis *deep learning* untuk memprediksi konsumsi energi listrik dari berbagai jenis bangunan di Kanada dan Inggris (Jogunola et al., 2022). Menggunakan dataset konsumsi daya listrik rumah tangga dari Universitas California, penelitian ini memanfaatkan model deep learning seperti

CNN, *Autoencoder* (AE) dengan LSTM, dan *Bidirectional* LSTM (BiLSTM). CNN mengekstrak fitur-fitur penting dari dataset, sementara AE-BiLSTM dan LSTM digunakan untuk prediksi. Hasilnya menunjukkan peningkatan kinerja model ini sebesar 56% dan 75.2% dalam waktu komputasi, serta mengurangi *mean squared error* (MSE) sebesar 80% dan 98.7% dibandingkan dengan model-model sebelumnya yang menggunakan CNN-BiLSTM dan LSTM konvensional. Selain itu, model ini dapat diaplikasikan pada berbagai dataset dengan karakteristik berbeda, menghasilkan nilai MSE rata-rata sekitar 0,09 pada setiap dataset yang diuji.

Dalam menghadapi tantangan kompleksitas prediksi konsumsi listrik di perkantoran, penelitian pertama hingga kelima di atas telah menjelajahi berbagai model dan teknik menggunakan *machine learning* atau *deep learning*. Namun, penggunaan faktor eksternal sebagai salah satu variabel pendukung masih terbatas. Oleh karena itu, dengan mempertimbangkan ulasan kritis pada Tabel 2.1, penelitian ini memperkenalkan pendekatan baru yang mempertimbangkan faktor internal dan eksternal dalam menganalisis dan memprediksi konsumsi listrik perkantoran di Indonesia, menggunakan model *deep learning* GRU dan Bi-GRU. Dengan menggabungkan keunggulan teknologi *deep learning* serta memperhatikan aspek temporal dan variabilitas eksternal, diharapkan penelitian ini dapat memberikan prediksi yang lebih akurat dan efisien dalam mengelola dan mengoptimalkan konsumsi listrik di perkantoran Indonesia. Sehingga, potensi kedepannya perusahaan dapat mengurangi biaya operasional serta dapat meningkatkan profit bisnis.

Tabel 2.1 Ulasan Kritis Tema Penelitian

No.	Sub Tema	Keywords	Ulasan Kritis	Hasil	Pustaka
1.	<i>Electricity Consumption Prediction</i>	<i>Building electrical load prediction, BP neural network, Fuzzy C-means clustering, Grey wolf optimizer algorithm</i>	Penulis membangun model prediksi listrik bangunan menggunakan algoritma FCM-GWO-BP berbasis data listrik dari sebuah gedung perkantoran di China.	Model FCM-GWO-BP memiliki kemampuan generalisasi yang tinggi, akurasi prediksi yang lebih baik, dan keandalan yang tinggi di bandingkan dengan <i>neural network</i> tradisional.	(Tian et al., 2020)

2.	<i>Electricity Consumption Prediction</i>	<i>Cooling energy, Energy prediction, Machine learning method, XGBoost model, Parameter tuning, Weather features</i>	Dalam penelitian ini dilakukan perbandingan beberapa pemodelan statistik, kemudian model prediksi penggunaan energi pendingin dibangun menggunakan algoritma XGBoost.	Algoritma XGBoost dengan <i>Feature Importance Analysis</i> terbukti dapat memprediksi dengan akurat penggunaan energi listrik pendinginan pada bangunan residensial.	(Feng et al., 2021)
3.	<i>Electricity Consumption Prediction</i>	<i>Building energy management system, Machine learning, Microsoft Azure, Energy consumption Prediction</i>	Mengembangkan model prediktif untuk memprediksi konsumsi energi menggunakan <i>machine learning</i> pada Microsoft Azure Cloud.	Hasil dari penelitian ini bahwa metode SVM menunjukkan kinerja prediksi konsumsi listrik yang paling baik dibandingkan 2 model lain yang diajukan. Serta Penggunaan Azure ML juga terbukti menguntungkan.	(Shapi et al., 2021)
4.	<i>Electricity Consumption Prediction</i>	<i>Hybrid deep learning, convolutional neural network, bidirectional long short-term memory, energy consumption</i>	Penelitian ini membangun model berbasis <i>deep learning</i> untuk memprediksi konsumsi listrik secara akurat dari berbagai jenis bangunan, baik komersial maupun	Model yang dibangun memiliki peningkatan kinerja lebih baik dalam waktu komputasi sebesar 56% dan 75.2%, serta MSE sebesar 80% dan 98.7%	(Jogunola et al., 2022)

		<i>prediction, autoencoder</i>	rumah tangga di berbagai negara.	dibandingkan model terdahulu.	
5.	<i>Electricity Consumption Prediction</i>	<i>Neural networks, time series, LSTM, GRU, Drop-GRU, energy consumption prediction, load shedding</i>	Memodelkan dan membandingkan tiga algoritma <i>deep learning</i> yang berbeda untuk membuat prediksi konsumsi daya listrik dalam deret waktu 1 hari, 3 hari, 7 hari dan 15 hari.	Model prediksi konsumsi listrik dengan LSTM menghasilkan akurasi yang lebih baik karena memiliki lebih sedikit kesalahan prediksi dan presisinya lebih baik dari model lainnya.	(Mahjoub et al., 2022)
6.	<i>Weather For Load Forecasting</i>	<i>Smart homes, electricity prediction, energy forecasting, machine learning, weather information</i>	Memprediksi konsumsi listrik pada <i>smart home</i> menggunakan data cuaca berbasis algoritma <i>Machine Learning</i> .	Algoritma <i>Random Forest</i> menunjukkan hasil prediksi paling tinggi dibandingkan 3 algoritma lainnya dengan nilai koefisien korelasi sebesar 75,7%.	(Brahim, 2021)
7.	<i>Weather For Load Forecasting</i>	<i>Electricity consumption, Weather forecast, BDA models, Data Analytic techniques, Machine learning</i>	Mengembangkan model prediktif untuk memprediksi konsumsi energi listrik terhadap kondisi cuaca diluar rumah berbasis model <i>big data</i> dengan algoritma	Model ini dikembangkan sebagai Model Analitik Big Data untuk melacak dan memantau konsumsi listrik rumah tangga berdasarkan faktor eksternal seperti cuaca.	(Asif Karim, Rootul Patel, 2021)

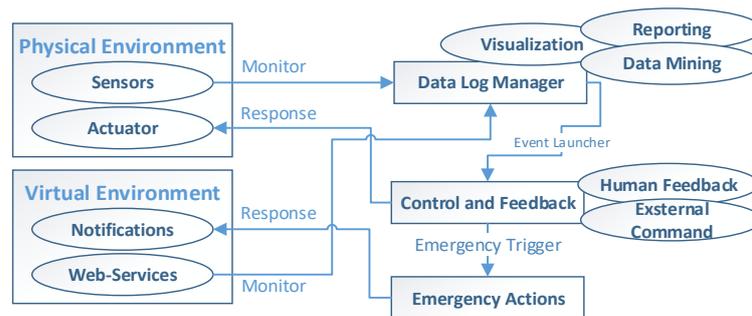
			<i>Machine Learning.</i>		
8.	<i>Weather For Load Forecasting</i>	<i>Electricity load, forecasting, weather, GRNN, SVM</i>	Penulis melakukan analisa dan merancang sistem prediksi beban listrik menggunakan model machine learning (GRNN & SVM) berdasarkan parameter cuaca.	Faktor cuaca dengan nilai korelasi tertinggi terhadap peningkatan beban listrik di Bali adalah suhu, yang diikuti oleh radiasi matahari dan kecepatan angin. Model prediksi yang dibangun juga berhasil meningkatkan akurasi prediksi beban listrik.	(Aisyah et al., 2022)
9.	<i>Deep Learning</i>	<i>Multi-energy load forecasting, CNN, BiGRU, Attention mechanism, Multi-task loss function weight optimization</i>	Model forecasting beban listrik dibangun dengan menggunakan algoritma <i>deep learning</i> CNN-BiGRU dengan mekanisme optimasi <i>attention</i> .	Dibandingkan dengan model forecasting menggunakan LSTM tradisional, model yang diusulkan memiliki akurasi yang lebih tinggi yaitu diantara 61-73%.	(Niu et al., 2022)
10.	<i>Deep Learning</i>	<i>AI-based energy model, LSTM, Smart active buildings, building</i>	Penelitian ini menggunakan metode <i>deep learning</i> DWT-LSTM untuk membuat model	Metode ini dapat memprediksi permintaan dan pasokan energi dengan tingkat akurasi tinggi	(Nabavi et al., 2021)

		<i>energy management, deep learning, discrete wavelet transformation, energy supply scheduling, energy system modeling</i>	<i>forecasting</i> manajemen energi listrik suatu bangunan. Model yang dibangun juga menganalisa beberapa faktor seperti harga listrik, cuaca, dan lain-lain sebagai inputan model <i>forecasting</i> yang akan dibangun.	(3,63-8,57% kesalahan prediksi per jam) untuk satu bulan ke depan. Penggunaan kombinasi model juga berhasil mengurangi impor energi dari jaringan listrik sebesar 84%, menghasilkan penghematan biaya listrik sebesar 87%.	
11.	<i>Deep Learning</i>	<i>Load forecasting, machine learning, deep learning models, electric power system, short-term load forecasting</i>	Penelitian menggunakan LSTM, GRU, dan RNN untuk memprediksi beban listrik di Tubas, Palestina, guna meningkatkan akurasi prediksi dan efisiensi distribusi listrik.	Model GRU unggul dengan R-squared 90.228%, MSE 0.00215, dan MAE 0.03266. Suhu mempengaruhi beban listrik, dengan konsumsi terendah pada malam hari. Rekomendasi masa depan mencakup penggunaan data dari smart meter.	(Abumohsen et al., 2023)
12.	<i>Deep Learning</i>	<i>Electricity consumption, prediction, CNN, BiLSTM, self attention</i>	Penelitian ini mengembangkan model CNN-BiLSTM dengan <i>Self Attention</i> untuk memprediksi konsumsi listrik rumah tangga, menggabungkan	Model CNN-BiLSTM-SA unggul dalam semua metrik evaluasi dibandingkan model lain. Eksperimen selanjutnya	(Wu & Wu, 2024)

			ekstraksi fitur temporal, korelasi variabel, dan analisis fitur intrinsik untuk meningkatkan akurasi prediksi.	direncanakan menggunakan dataset terbaru untuk penelitian lebih mendalam.	
--	--	--	--	---	--

2.2 Smart Office

Smart office atau kantor pintar merupakan konsep modern yang memanfaatkan teknologi canggih untuk meningkatkan efisiensi operasional, produktivitas, dan kenyamanan karyawan (Tuzcuoğlu et al., 2021). Teknologi yang digunakan meliputi IoT, sensor, *Building Management System* (BMS), serta kecerdasan buatan (AI). Integrasi teknologi ini memungkinkan pengelolaan ruang kerja yang lebih efisien dan responsif terhadap kebutuhan pengguna. Seperti yang dapat dilihat pada Gambar 2.1 konsep terbaru dengan nama “*High Level Architecture Smart Office*” mengintegrasikan aspek virtual, fisik, *feedback* dari manusia dan data historis yang tersimpan yang saling berhubungan dalam membentuk kesinambungan sistem (Barisic et al., 2020). Dalam *smart office*, perangkat pintar seperti sensor dan sistem berbasis IoT digunakan untuk memonitor dan mengontrol berbagai aspek operasional kantor secara *real-time*. Misalnya, sistem manajemen energi berbasis IoT dapat mengontrol penggunaan listrik secara efisien pada bangunan, dengan sensor yang mendeteksi kehadiran manusia untuk mengatur pencahayaan dan sistem HVAC secara otomatis sesuai kebutuhan aktual (Berawi et al., 2023). Teknologi *smart office* memungkinkan penghematan energi yang signifikan, dengan studi penelitian sebelumnya menunjukkan bahwa sistem cerdas dalam manajemen energi bangunan dapat mengurangi konsumsi energi hingga 35% (Ilbeigi et al., 2020).



Gambar 2.1 *High Level Architecture Smart Office* (Barisic et al., 2020)

Sistem cerdas berperan penting dalam analisis data yang dihasilkan oleh sensor di seluruh kantor. Sistem cerdas dapat memprediksi pola penggunaan energi berdasarkan data historis dan faktor lingkungan eksternal seperti cuaca, sehingga mengoptimalkan pengaturan energi dan mengurangi pemborosan (Asif Karim, Rootul Patel, 2021). Selain itu, *deep learning*, yang menggunakan arsitektur jaringan saraf tiruan seperti CNN dan RNN, mampu mempelajari pola dan hubungan kompleks dalam data konsumsi energi (Wu & Wu, 2024). Dengan data *real-time* dari berbagai sensor, *deep learning* dapat memberikan prediksi yang akurat mengenai konsumsi energi di masa depan, membantu pengelolaan energi yang lebih efisien (Yang, Wan, et al., 2020). Keamanan dan kenyamanan juga menjadi fokus dalam *smart office*. Teknologi pengenalan wajah dan akses kontrol berbasis IoT dapat meningkatkan keamanan gedung. Kemudian, sistem manajemen fasilitas yang terintegrasi juga dapat mengatur suhu, kelembaban, dan kualitas udara secara otomatis, sehingga menciptakan lingkungan kerja yang nyaman dan sehat (Floris et al., 2021).

2.3 Data Pre-processing

Data pre-processing adalah langkah penting dalam pengolahan data sebelum digunakan dalam model prediksi. Langkah ini mencakup pembersihan data, penanganan data yang hilang, dan transformasi data untuk memastikan bahwa data yang digunakan dalam analisis bersifat konsisten dan bebas dari kesalahan (Fan et al., 2021). Beberapa teknik yang umum digunakan untuk mengisi data yang hilang pada dataset yaitu teknik interpolasi dan imputasi. Kedua teknik ini penting karena data yang hilang dapat mengurangi akurasi model prediksi secara signifikan jika tidak ditangani dengan benar (Maharana et al., 2022). Selain itu, normalisasi dan standardisasi data juga merupakan langkah krusial dalam *data pre-processing*. Normalisasi membantu dalam mengatur data pada skala yang sama, sementara standardisasi memastikan distribusi data berada pada kisaran tertentu, biasanya dengan *mean nol* dan standar deviasi satu (Abidi et al., 2022).

Teknik lain yang penting dalam *pre-processing* adalah deteksi dan penanganan *outlier*. *Outlier* dapat mempengaruhi model prediksi dengan cara yang tidak diinginkan, sehingga penting untuk mengidentifikasi dan memutuskan apakah *outlier* tersebut harus dihapus atau disesuaikan. Metode seperti *Z-score* dan *IQR (Interquartile Range)* sering digunakan untuk deteksi *outlier* (Vijendar Reddy et al., 2023).

Data pre-processing juga melibatkan transformasi data, seperti transformasi logaritmik atau eksponensial, yang bertujuan untuk mengurangi *skewness* atau ketidaknormalan distribusi data. Transformasi ini membantu dalam meningkatkan kinerja

model prediksi dengan membuat pola data lebih jelas dan mudah dipelajari oleh model (Joshi & Patel, 2021).

2.4 Data Exploratory

Data exploratory merupakan tahap di mana data dianalisis secara mendalam untuk memahami struktur, pola, dan hubungan antar variabel. Langkah ini penting untuk memperoleh wawasan awal tentang data yang dapat digunakan untuk membuat keputusan lebih lanjut dalam pemodelan dan analisis. Salah satu alat yang sering digunakan dalam eksplorasi data adalah visualisasi data, seperti grafik *scatter plots*, *histogram*, dan *box plots*. Visualisasi ini membantu dalam mengidentifikasi distribusi data, hubungan antar variabel, dan keberadaan *outlier* (Mukhiya & Ahmed, 2020).

Analisis eksploratif juga mencakup penggunaan statistik deskriptif untuk memberikan ringkasan numerik dari data. Ukuran seperti *mean*, *median*, standar deviasi, dan *skewness* memberikan gambaran tentang karakteristik dasar data (Zekić-Sušac et al., 2021). Selain itu, analisis korelasi digunakan untuk mengidentifikasi hubungan linier antara variabel-variabel dalam dataset. Metrik korelasi adalah alat yang umum digunakan untuk tujuan ini, membantu dalam mengidentifikasi pasangan variabel yang mungkin memiliki hubungan yang signifikan dan dapat dipertimbangkan lebih lanjut dalam model prediksi (Aisyah et al., 2022). Teknik-teknik ini membantu dalam memahami struktur data yang lebih kompleks dan menyediakan dasar yang lebih kuat untuk langkah-langkah pemrosesan data selanjutnya (Nielsen, 2019).

2.5 Feature Engineering

Feature engineering adalah proses pembuatan fitur-fitur baru dari data mentah yang ada untuk meningkatkan kinerja model prediksi. Proses ini melibatkan transformasi data mentah menjadi fitur yang lebih informatif dan relevan dengan tujuan analisis. Salah satu teknik dasar dalam *feature engineering* adalah membuat fitur dari kombinasi linear atau non-linear dari variabel yang ada. Teknik ini bertujuan untuk menangkap interaksi antara variabel yang mungkin tidak terlihat dengan jelas dalam bentuk aslinya (Duboue, 2020).

Selain itu, *encoding* variabel kategori merupakan langkah penting dalam *feature engineering*. Teknik seperti *one-hot encoding*, *label encoding*, dan *target encoding* digunakan untuk mengubah data kategori menjadi format numerik yang dapat digunakan oleh model pembelajaran mesin. Pemilihan teknik *encoding* yang tepat dapat berdampak signifikan pada kinerja model, tergantung pada karakteristik data dan model yang digunakan (Sun et al., 2022).

Feature engineering juga mencakup penggunaan teknik statistik dan *domain knowledge* untuk menciptakan fitur yang lebih bermakna. Misalnya, dalam analisis data waktu, fitur seperti hari dalam minggu, bulan, atau bahkan cuaca dapat ditambahkan untuk menangkap efek musiman atau tren temporal. Penggunaan *domain knowledge* dalam *feature engineering* membantu dalam memastikan bahwa fitur yang dibuat relevan dan dapat meningkatkan kinerja model prediksi (Fan et al., 2019).

2.6 Deep Learning untuk Prediksi

Deep learning telah menjadi salah satu pendekatan paling populer dan efektif untuk tugas-tugas prediksi dalam berbagai domain, termasuk keuangan, kesehatan, pemasaran, dan cuaca. *Deep learning* adalah subset dari *machine learning* yang menggunakan jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan (*deep neural networks*) untuk memodelkan dan mempelajari representasi data yang kompleks. Pendekatan ini mampu mengatasi keterbatasan metode tradisional dengan memanfaatkan kemampuan untuk belajar dari data dalam jumlah besar, menangkap pola yang tersembunyi, dan menghasilkan prediksi yang akurat (Janiesch et al., 2023).

Deep learning juga menawarkan fleksibilitas dan skalabilitas dalam memproses berbagai jenis data, termasuk data struktural, semi-struktural, dan tidak terstruktur. Arsitektur *deep learning*, seperti CNN, RNN, dan varian RNN seperti LSTM dan GRU, telah terbukti efektif dalam menangani berbagai tugas prediksi dengan kinerja yang mengesankan. Teknologi ini terus berkembang dengan penemuan arsitektur dan algoritma baru yang meningkatkan efisiensi dan akurasi model prediksi (Jiménez-Navarro et al., 2023).

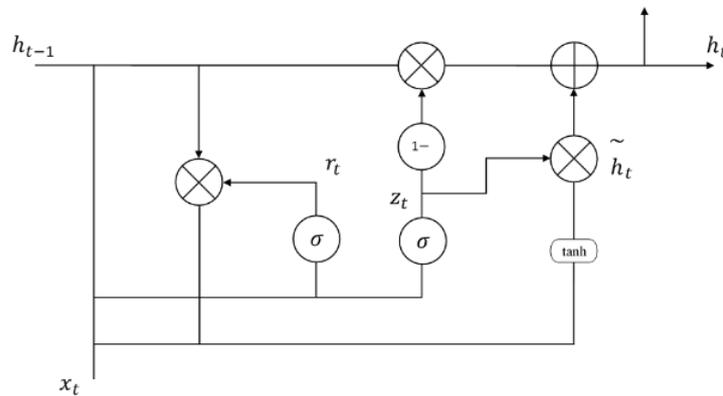
Dengan kemajuan dalam kemampuan komputasi dan ketersediaan data besar (*big data*), implementasi *deep learning* menjadi semakin praktis dan bermanfaat. GPU dan TPU, misalnya, memungkinkan pelatihan model *deep learning* yang sangat kompleks dalam waktu yang lebih singkat, sehingga mempercepat proses pengembangan dan penerapan model. Selain itu, kemajuan dalam teknik optimisasi dan regularisasi membantu dalam mengatasi tantangan *overfitting* dan meningkatkan generalisasi model pada data yang belum pernah dilihat sebelumnya (Y. Li et al., 2021).

Secara keseluruhan, *deep learning* menawarkan pendekatan yang sangat kuat dan fleksibel untuk prediksi. Dengan kemampuan untuk menangani data yang kompleks dan berstruktur tinggi, *deep learning* terus menjadi pilihan utama dalam berbagai aplikasi prediksi yang menuntut akurasi tinggi dan pemodelan yang mendalam. Ini membuka peluang baru untuk inovasi dan pengembangan di berbagai sektor, memungkinkan

pengambilan keputusan yang lebih baik dan lebih tepat waktu berdasarkan wawasan yang diperoleh dari data (Lim & Zohren, 2021).

2.6.1 Gated Recurrent Unit (GRU)

GRU merupakan tipe RNN yang mirip dengan LSTM, tetapi dengan struktur yang lebih sederhana. Model ini juga efektif dalam mengatasi masalah *time series* dan mengurangi kompleksitas komputasi dibandingkan dengan LSTM (Abumohsen et al., 2023). GRU memberikan keseimbangan antara kompleksitas dan performa. GRU sering digunakan ketika performa LSTM diperlukan namun dengan biaya komputasi yang lebih rendah. GRU juga menggunakan mekanisme pintu/gerbang, termasuk *reset gate* dan *update gate*, yang memungkinkan pengontrolan aliran informasi dalam sel memori (Zameer et al., 2023). Skema arsitektur GRU dapat dilihat pada Gambar 2.3 dimana aliran data melewati *reset gate* dan *update gate*, yang merupakan komponen kunci dalam alur GRU.



Gambar 2.2 Arsitektur GRU

Reset Gate mengontrol sejauh mana informasi dari status sebelumnya dilupakan sebelum menghasilkan status baru, dengan rumus matematika dapat dilihat pada persamaan 2.1. Dimana r_t adalah output dari *reset gate* pada waktu t , simbol σ mewakili fungsi sigmoid yang menghasilkan nilai antara 0 dan 1, W_{ir} dan W_{hr} adalah matriks bobot yang diterapkan pada input x_t dan output dari langkah sebelumnya h_{t-1} secara berturut-turut, dan b_{ir} dan b_{hr} adalah bias yang sesuai.

$$r_t = \sigma(W_{ir}x_t + b_{ir} + W_{hr}h_{t-1} + b_{hr}) \quad (2.1)$$

Update Gate mengontrol sejauh mana informasi baru harus disimpan dalam sel memori, dengan rumus matematika dapat dilihat pada persamaan 2.2. Dimana z_t adalah output dari *update gate* pada waktu t , simbol σ mewakili fungsi sigmoid yang menghasilkan nilai antara 0 dan 1, W_{iz} dan W_{hz} adalah matriks bobot yang diterapkan pada input x_t dan output dari langkah sebelumnya h_{t-1} secara berturut-turut, b_{iz} dan b_{hz} adalah bias yang sesuai.

$$z_t = \sigma(W_{iz}x_t + b_{iz} + W_{hz}h_{t-1} + b_{hz}) \quad (2.2)$$

Kandidat nilai (\hat{h}_t) dihasilkan dengan menggunakan *reset gate* (r_t) untuk menggabungkan informasi dari input dan informasi lama (h_{t-1}), dengan rumus matematika dapat dilihat pada persamaan 2.3. Dimana \hat{h}_t adalah vektor kandidat aktual pada waktu t yang merupakan kandidat untuk nilai output aktual pada langkah waktu tersebut. *tanh* adalah fungsi tangen hiperbola, yang mengonversi input menjadi rentang nilai antara -1 dan 1, membantu dalam mempertahankan gradien selama pelatihan. W_{ih} adalah matriks bobot yang diterapkan pada input x_t dan b_{ih} adalah bias yang sesuai. r_t adalah output dari reset gate yang telah dijelaskan sebelumnya, yang menentukan seberapa banyak informasi dari langkah sebelumnya harus dipertahankan. \odot adalah operator perkalian titik demi titik (*element-wise*) antara dua vektor atau matriks. W_{hh} adalah matriks bobot yang diterapkan pada output dari langkah sebelumnya h_{t-1} dan b_{hh} adalah bias yang sesuai.

$$\hat{h}_t = \tanh(W_{ih}x_t + b_{ih} + r_t \odot (W_{hh}h_{t-1} + b_{hh})) \quad (2.3)$$

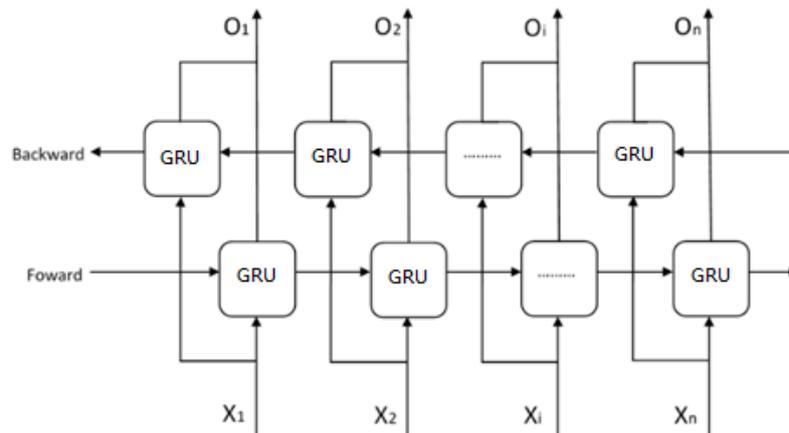
Kemudian, Nilai sel memori (h_t) diperbarui dengan menggunakan *update gate* (z_t) dan kandidat nilai (\hat{h}_t), dengan rumus pada persamaan 2.4. Dimana h_t adalah output aktual dari sel GRU pada waktu t , z_t adalah nilai dari *update gate* pada waktu t , h_{t-1} adalah output dari sel GRU pada waktu sebelumnya ($t - 1$), \hat{h}_t adalah nilai kandidat yang dihasilkan pada waktu t , dan \odot adalah operator perkalian titik demi titik (*element-wise*) antara dua vektor atau matriks.

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \hat{h}_t \quad (2.4)$$

2.6.2 Bidirectional GRU (BiGRU)

BiGRU adalah jenis arsitektur *deep learning* RNN yang merupakan pengembangan dari arsitektur GRU (Dey et al., 2023). BiGRU memiliki dua buah gerbang GRU yang berjalan ke arah yang berlawanan: satu maju (*forward* GRU) dan satu mundur (*backward* GRU). Konsep BiGRU memberikan keunggulan dalam memahami dan mengekstraksi informasi dari dua arah yang berbeda, menyediakan kerangka kerja yang lebih kuat untuk memodelkan pola temporal yang kompleks dalam data, dan hasil akhir yang dihasilkan merupakan hasil kolaborasi dari dua perspektif berbeda yang melengkapi satu sama lain (Ahuja et al., 2022). Dengan menggunakan BiGRU, model dapat memahami hubungan kompleks antara faktor-faktor yang mempengaruhi target, sehingga memungkinkan prediksi yang lebih akurat dan lebih handal (Putpuek et al., 2023). Skema arsitektur BiGRU dapat

dilihat pada Gambar 2.3 dimana dua buah GRU digunakan untuk menghasilkan 1 hasil akhir dari target yang diinginkan.



Gambar 2.3 Arsitektur BiGRU

2.7 Metrik Evaluasi

Dalam pengembangan model prediksi *time series*, penting untuk dapat mengevaluasi kinerja model secara objektif menggunakan metrik evaluasi yang tepat. metrik evaluasi adalah alat yang digunakan untuk mengukur seberapa baik model prediksi memperkirakan nilai sebenarnya dalam deret waktu. Dengan menganalisis kesalahan prediksi model, analisis dapat menentukan kekuatan dan kelemahan model serta membuat perbaikan yang diperlukan (González-Sopeña et al., 2021).

Penerapan metrik evaluasi dalam analisis prediksi *time series* menawarkan sejumlah manfaat yang signifikan. Pertama, metrik evaluasi memungkinkan penilaian yang objektif terhadap kinerja model, yang penting dalam mengidentifikasi area-area yang memerlukan peningkatan. Tanpa metrik evaluasi yang tepat, penilaian kinerja model dapat menjadi subjektif dan tidak akurat (Al Hamoud et al., 2022).

Selain itu, penggunaan metrik evaluasi yang sesuai dapat membantu para pengambil keputusan dalam memilih model terbaik untuk digunakan dalam aplikasi praktis. Misalnya, dengan membandingkan hasil dari beberapa model menggunakan berbagai metrik evaluasi, para analis dapat menentukan model mana yang paling sesuai dengan tujuan dan kebutuhan mereka (J. Chen et al., 2022).

2.7.1 Mean Squared Error (MSE)

MSE adalah metrik yang mengukur rata-rata dari kuadrat perbedaan antara nilai prediksi dan nilai sebenarnya dalam dataset. MSE memberikan informasi tentang seberapa besar kesalahan prediksi secara rata-rata, dengan menyatakan kesalahan dalam bentuk kuadrat. Semakin rendah nilai MSE, semakin baik model memprediksi data. Hal ini

mengakibatkan penalti yang lebih besar terhadap perbedaan yang signifikan, memastikan bahwa nilai-nilai yang jauh dari nilai sebenarnya memiliki dampak yang besar pada evaluasi model (Ullah et al., 2022). Dimana n adalah jumlah sampel, y_i adalah nilai sebenarnya, dan \hat{y}_i adalah nilai prediksi, seperti yang dapat dilihat pada persamaan 2.5.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.5)$$

2.7.2 Root Mean Squared Error (RMSE)

Kemudian RMSE adalah akar kuadrat dari MSE seperti yang dapat dilihat pada persamaan 2.6, dimana n adalah jumlah sampel, y_i adalah nilai sebenarnya, dan \hat{y}_i adalah nilai prediksi. RMSE memberikan gambaran tentang seberapa besar deviasi prediksi dari nilai sebenarnya dalam satuan yang sama dengan variabel yang diukur. Karena RMSE menghitung akar kuadrat dari MSE, ia memberikan perhitungan yang lebih intuitif dan mudah dipahami (Feng et al., 2021).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.6)$$

2.7.3 Mean Absolute Error (MAE)

MAE adalah metrik yang mengukur rata-rata dari nilai absolut perbedaan antara prediksi dan nilai sebenarnya. MAE memberikan informasi tentang sejauh mana rata-rata prediksi berbeda dari nilai sebenarnya. MAE cenderung memberikan gambaran yang lebih baik tentang kesalahan prediksi secara keseluruhan, karena ia tidak memberikan bobot lebih besar pada perbedaan yang besar seperti MSE. Sebaliknya, hasil MAE akan memiliki satuan yang sama dengan variabel yang diprediksi, mirip dengan RMSE. Namun, perbedaannya adalah MAE tidak mempertimbangkan kuadrat dari kesalahan, sehingga lebih fokus pada "*average magnitude*" kesalahan tanpa memperhitungkan arahnya (Niu et al., 2022). MAE memiliki rumus matematika yang dapat dilihat pada persamaan 2.7, dimana n adalah jumlah sampel, y_i adalah nilai sebenarnya, dan \hat{y}_i adalah nilai prediksi.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.7)$$

2.7.4 R-Square (R^2)

R^2 adalah metrik yang mengukur seberapa baik variasi dalam variabel target dapat dijelaskan oleh prediktor dalam model. Nilai R^2 berkisar antara 0 dan 1, di mana nilai yang lebih tinggi menunjukkan bahwa model lebih baik dalam menjelaskan variasi dalam data. R^2 berguna dalam mengevaluasi kualitas keseluruhan model prediksi *time series* dan

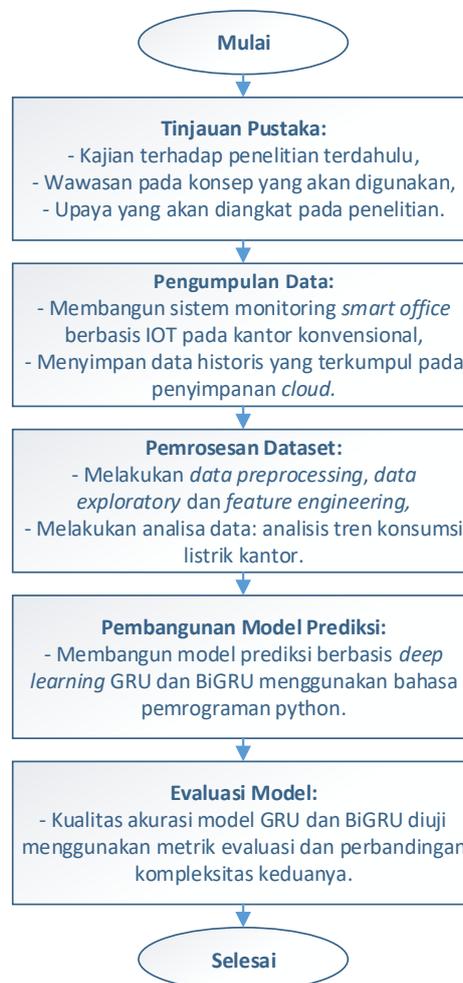
memberikan informasi tentang seberapa baik model cocok dengan data (J. Chen et al., 2022). R^2 memiliki rumus matematika yang dapat dilihat pada persamaan 2.8, Dimana n adalah jumlah sampel, y_i adalah nilai sebenarnya, dan \hat{y}_i adalah nilai prediksi.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.8)$$

BAB 3

Metodologi

Untuk mencapai tujuan penelitian ini, penulis telah merancang dan mengimplementasikan serangkaian langkah metodologis yang sistematis. Diagram alur langkah-langkah penelitian tercantum dalam Gambar 3.1, yang memberikan penjelasan tentang tahapan-tahapan penelitian secara terperinci. Proses dimulai dengan tinjauan pustaka untuk mengumpulkan referensi dan teori dari penelitian-penelitian terdahulu. Langkah berikutnya adalah pengumpulan data, di mana penulis menggunakan infrastruktur IoT yang telah dibangun untuk menghasilkan data melalui proses observasi. Data kemudian diproses untuk membersihkan dataset serta melakukan analisis dan eksplorasi mendalam, sehingga menghasilkan data input yang sesuai untuk model prediksi. Data hasil pemrosesan digunakan untuk membangun model prediksi menggunakan arsitektur deep learning. Sehingga pada akhirnya, keberhasilan model dinilai melalui berbagai metrik evaluasi.



Gambar 3.1 Langkah-Langkah Penelitian

3.1 Tinjauan Pustaka

Pada tahap awal penelitian, dilakukan tinjauan pustaka untuk mengidentifikasi dan mencari referensi yang akan mendukung penelitian. Manfaat dari tinjauan pustaka adalah untuk memahami penelitian terdahulu yang relevan dengan topik yang akan diteliti, sehingga penulis dapat mengidentifikasi apa yang telah diketahui dan apa yang belum diketahui tentang topik mengenai prediksi konsumsi listrik menggunakan arsitektur *deep learning* (Paul & Barari, 2022). Terdapat 3 proses yang dilakukan pada tahap tinjauan pustaka, proses pertama yaitu kajian terhadap penelitian-penelitian terdahulu yang berkaitan dengan prediksi konsumsi listrik pada rumah tempat tinggal, bangunan bahkan wilayah/kota. Dilakukan juga tinjauan teori untuk mencari lebih dalam wawasan tentang konsep *smart office* masa kini dalam mendukung efisiensi energi. Selain itu, tinjauan teori untuk kebutuhan model prediksi juga dilakukan, diantaranya teori tentang *data preparation*, *data exploratory*, *feature engineering*, *deep learning* untuk tugas prediksi, serta teknik evaluasi untuk menguji kualitas model prediksi. Kemudian, pada tahapan tinjauan pustaka ini juga dijabarkan upaya-upaya yang akan diangkat untuk menyelesaikan penelitian ini berdasarkan kajian dan tinjauan teori yang telah dilakukan.

3.2 Pengumpulan Data

Pada penelitian ini, untuk menghasilkan sebuah model prediksi konsumsi listrik pada perkantoran, maka dibutuhkan data hasil observasi dari kondisi sebuah kantor. Kenyataan yang penulis dapatkan di lapangan bahwa, untuk mendapatkan sekumpulan data baik tentang konsumsi listrik, kondisi internal dan kondisi eksternal suatu gedung perkantoran di Indonesia sangat sulit didapatkan. Sebagai contoh, lembaga besar milik pemerintah seperti Badan Meteorologi, Klimatologi dan Geofisika (BMKG), memberikan akses terbuka terhadap data kondisi cuaca di wilayah Indonesia, namun data hasil pemantauannya terbatas pada pengukuran harian. Sehingga jika diperlukan data dengan interval waktu yang lebih pendek, seperti per jam atau per menit, BMKG belum dapat menyediakan informasi tersebut (Pusat Database BMKG, 2024). Oleh sebab itu, penelitian ini membangun sistem monitoring berbasis IoT pada sebuah kantor konvensional yang menghasilkan sekumpulan data yang merepresentasikan konsumsi listrik, kondisi internal dan kondisi eksternal gedung perkantoran sesuai dengan kearifan lokal Indonesia. Dengan menggunakan metode observasi, penulis dapat mengumpulkan data secara langsung dari lapangan, mengamati fenomena atau kejadian secara *real-time*, mendapatkan data yang spesifik dan relevan sesuai dengan tujuan penelitian. Sehingga memungkinkan penulis untuk mengeksplorasi aspek tertentu yang tidak dapat diakses melalui sumber data sekunder (Floris et al., 2021).

3.2.1 Lokasi dan Waktu

Lokasi penelitian dalam melakukan proses pengumpulan data dilakukan pada sebuah kantor konvensional di kota Yogyakarta. Bangunan kantor ini milik perusahaan ISP ternama yaitu PT. Indonesia Coments Plus (PLN Icon Plus) Unit Layanan D.I Yogyakarta yang menduduki gedung 2 lantai dengan luas bangunan $\pm 225 \text{ m}^2$ dan jumlah karyawan sekitar 50-60 orang. Gambar 3.2 menampilkan kondisi terkini kantor PLN Icon Plus Yogyakarta yang menjadi objek observasi penelitian. Waktu penelitian dalam proses pengumpulan data dilakukan mulai dari periode desember 2023 sampai januari 2024. Dengan *trial* dan *error* yang penulis lalui sehingga akhirnya penulis dapat menghasilkan penambangan data historis selama 35 hari mulai dari tanggal 4 desember 2023 sampai dengan 7 januari 2024. Selama proses pengumpulan data ini, kondisi konsumsi listrik, kondisi internal dan kondisi eksternal bangunan kantor telah berhasil di rekam dalam bentuk data historis berbentuk *time series* dan tersimpan di penyimpanan *cloud database* secara *real-time*.

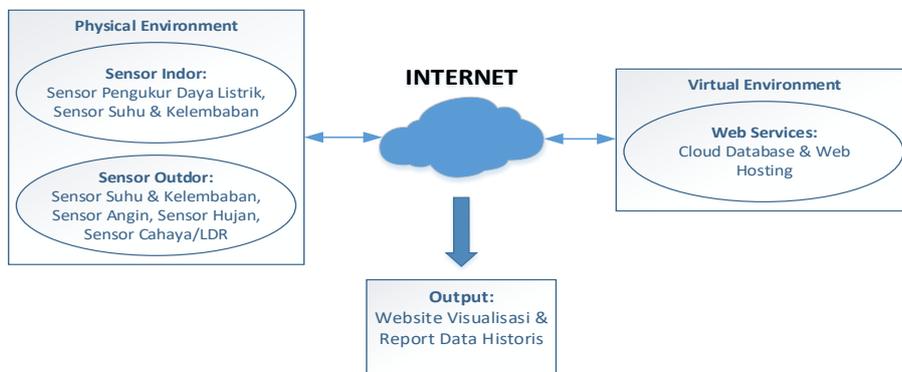


Gambar 3.2 Kondisi Kantor PLN Icon Plus Unit Layanan D.I Yogyakarta

Dalam penelitian ini, pengumpulan data selama 35 hari yang dianggap sebagai waktu pengukuran jangka pendek, tidak hanya disebabkan oleh keterbatasan dalam kemampuan pengumpulan data. Beberapa penelitian terdahulu menunjukkan bahwa pola cuaca di Indonesia dapat dianalisis secara efektif dengan data bulanan, karena variabilitas cuaca yang tidak terlalu signifikan sepanjang tahun. Meskipun ada variasi dalam jangka waktu yang lebih panjang, analisis dalam periode satu bulan sudah memberikan gambaran yang akurat tentang tren iklim umum (Putra et al., 2022; Setiawan, 2020; Suryadi et al., 2018; Tosepu et al., 2020). Pemahaman ini mendukung dasar yang kuat untuk memahami karakteristik cuaca sebagai faktor eksternal yang mempengaruhi konsumsi listrik pada bangunan kantor.

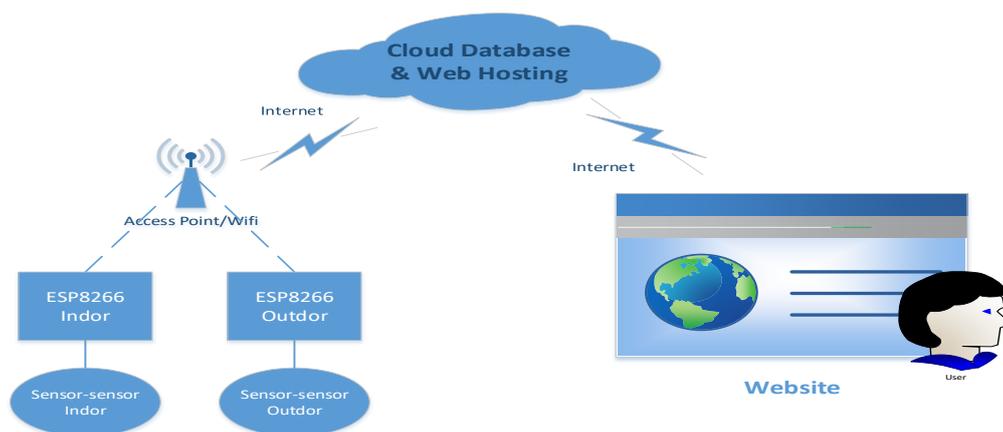
3.2.2 Infrastruktur Pengumpulan Data

Gambar 3.3, dapat dilihat rancangan infrastruktur pengumpulan data yang selanjutnya disebut dengan nama sistem monitoring *smart office* berbasis IoT. Dari gambar ini menjelaskan bahwa sistem monitoring *smart office* dibangun berdasarkan *physical environment* dan *virtual environment* yang saling terhubung sehingga menghasilkan *output* berupa data historis observasi hasil pengukuran.



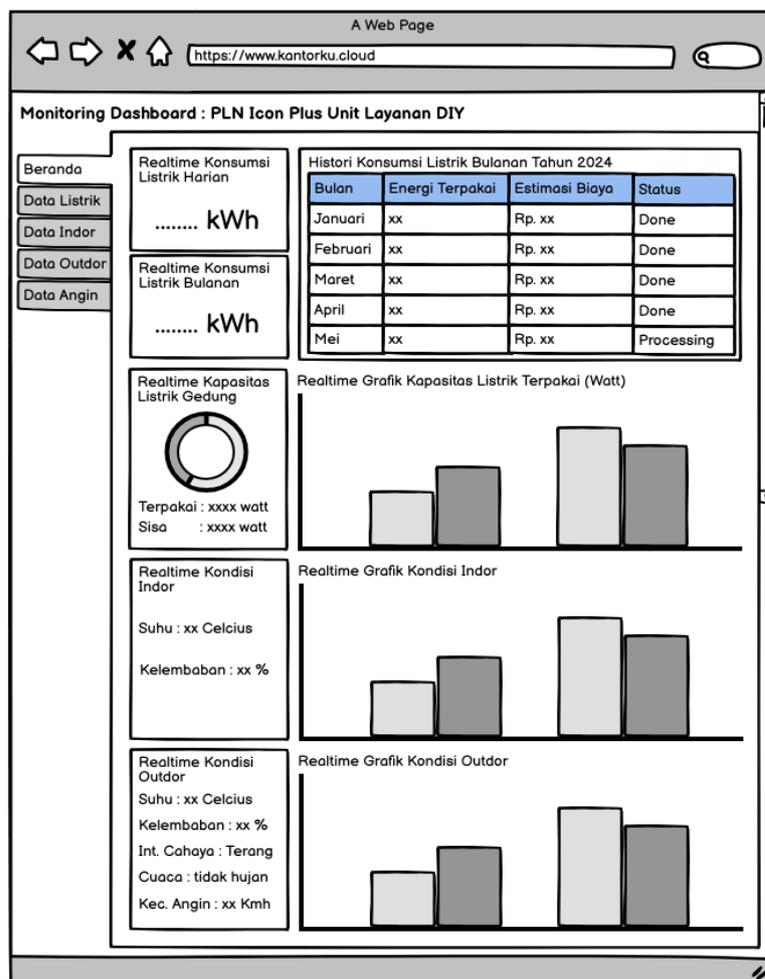
Gambar 3.3 Rancangan Infrastruktur Pengumpulan Data Sistem Monitoring *Smart Office*

Pada bagian *physical environment*, dilakukan proses pengumpulan data historis dari sensor yang tertanam didalam dan diluar bangunan kantor. Pengumpulan data didalam bangunan dilakukan pada area kelistrikan dan area ruangan tempat kerja. Sedangkan pengumpulan data diluar bangunan dilakukan pada area atap gedung. Kemudian pada *virtual environment*, dilakukan proses penyimpanan data dari *physical environment* ke dalam *database cloud* melalui media jaringan internet. Pada *virtual environment* ini juga *web hosting* digunakan untuk dapat melakukan akses secara *online* pada *website* yang dibangun untuk keperluan output sistem. Hubungan antara *physical* dan *virtual environment* dapat dilihat pada blok diagram Gambar 3.4 dimana data sensor yang terhubung ke ESP8266 akan dikirimkan melalui internet ke *cloud database* dan akan di tampilkan dalam bentuk *website*.



Gambar 3.4 Hubungan Antara *Physical* dan *Virtual Environment*

Selanjutnya pada bagian output, penulis menggunakan *website* dari *virtual environment* untuk menampilkan visualisasi dan *report* terhadap data yang tersimpan dari proses penambangan data yang dilakukan. Penggunaan website ini diperlukan agar proses visualisasi data secara *real-time* dan *reporting* data yang tersimpan lebih terorganisir dengan baik. Sehingga pada akhirnya, tujuan dari pembangunan infrastruktur pengumpulan data dapat menghasilkan dataset historis yang dapat diolah lebih lanjut untuk digunakan sebagai inputan pada model prediksi yang akan dibangun. *Website* dibangun menggunakan tampilan halaman *dashboard* dan halaman *export* data. Rancangan halaman *dashboard* digunakan untuk visualisasi dalam bentuk grafik dan tabel agar dapat menampilkan banyak data dan informasi terkait kondisi *realtime* bangunan kantor seperti yang terlihat pada Gambar 3.5. Sedangkan, rancangan halaman *export* digunakan untuk dapat menghasilkan data hasil observasi dalam bentuk file csv/excel/pdf seperti terlihat pada Gambar 3.6. Halaman *export* diperlukan untuk mempermudah aksesibilitas dalam mendapatkan data output dari sistem ini, sehingga selanjutnya dapat dianalisa dan diproses lebih lanjut menggunakan platform lain.



Gambar 3.5 Rancangan Halaman Dashboard Website



Gambar 3.6 Rancangan Halaman *Export Data Website*

3.2.3 Output Data

Setelah sistem monitoring *smart office* berhasil dibangun, maka sistem menghasilkan empat dataset dari sensor yang tertanam di *physical environment*. Keempat dataset ini selanjutnya akan di proses melalui pemrosesan data sehingga menghasilkan 1 dataset akhir sebagai inputan model prediksi konsumsi listrik. Keempat dataset ini adalah:

1. Dataset Monitoring Kelistrikan

Pada dataset monitoring kelistrikan terdapat 13 variabel yang dihasilkan dari sensor pengukuran pada sistem monitoring yang dibangun. Deskripsi dari masing-masing variabel dapat dilihat pada Tabel 3.1.

Tabel 3.1 Dataset Monitoring Kelistrikan

Variabel	Deskripsi
Tegangan 1	Hasil pengukuran tegangan listrik <i>phasa R</i> pada kantor dalam volt (v)
Arus 1	Hasil pengukuran arus listrik <i>phasa R</i> pada kantor dalam ampere (i)
Daya 1	Hasil pengukuran daya listrik <i>phasa R</i> pada kantor dalam watt (W)
Tegangan 2	Hasil pengukuran tegangan listrik <i>phasa S</i> pada kantor dalam volt (v)
Arus 1	Hasil pengukuran arus listrik <i>phasa S</i> pada kantor dalam ampere (i)

Daya 2	Hasil pengukuran daya listrik <i>phasa</i> S pada kantor dalam watt (W)
Tegangan 3	Hasil pengukuran tegangan listrik <i>phasa</i> T pada kantor dalam volt (v)
Arus 1	Hasil pengukuran arus listrik <i>phasa</i> T pada kantor dalam ampere (i)
Daya 3	Hasil pengukuran daya listrik <i>phasa</i> T pada kantor dalam watt (W)
Total Daya	Hasil pengukuran daya listrik total (3 <i>phasa</i>) pada kantor dalam watt (W)
Sisa Daya	Hasil pengukuran daya listrik sisa (3 <i>phasa</i>) pada kantor dalam watt (W)
Day	Hari saat pembacaan dilakukan
Datetime	Waktu saat pembacaan dilakukan (yyyy-mm-dd hh:mm:ss).

2. Dataset Monitoring *Indoor*

Pada dataset monitoring *indoor* terdapat 4 variabel yang dihasilkan dari sensor pengukuran pada sistem monitoring yang dibangun. Deskripsi dari masing-masing variabel dapat dilihat pada Tabel 3.2.

Tabel 3.2 Dataset Monitoring Indor

Variabel	Deskripsi
Suhu Ind	Hasil pengukuran Suhu di dalam bangunan kantor dalam celcius (°C)
Kelembaban Ind	Hasil pengukuran kelembaban di dalam bangunan kantor dalam persen (%)
Day	Hari saat pembacaan dilakukan
Datetime	Waktu saat pembacaan dilakukan (yyyy-mm-dd hh:mm:ss).

3. Dataset Monitoring *Outdoor*

Pada dataset monitoring *outdoor* terdapat 7 variabel yang dihasilkan dari sensor pengukuran pada sistem monitoring yang dibangun. Deskripsi dari masing-masing variabel ini dapat dilihat pada Tabel 3.3.

Tabel 3.3 Dataset Monitoring Outdoor

Variabel	Deskripsi
Suhu Out	Hasil pengukuran Suhu di luar bangunan kantor dalam <i>celcius</i> (°C)
Kelembaban Out	Hasil pengukuran kelembaban di luar bangunan kantor dalam persen (%)
Hujan	Hasil pengukuran kondisi hujan atau tidak di luar bangunan kantor

Kondisi Cahaya	Hasil pengukuran kondisi cahaya langit apakah terang atau gelap di luar bangunan kantor
Intensitas Cahaya	Hasil pengukuran intensitas cahaya di luar bangunan kantor
Day	Hari saat pembacaan dilakukan
Datetime	Waktu saat pembacaan dilakukan (yyyy-mm-dd hh:mm:ss).

4. Dataset Monitoring Kecepatan Angin

Pada dataset monitoring kecepatan angin terdapat 3 variabel yang dihasilkan dari sensor pengukuran pada sistem monitoring yang dibangun. Deskripsi dari masing-masing variabel dapat dilihat pada Tabel 3.4.

Tabel 3.4 Dataset Monitoring Kecepatan Angin

Variabel	Deskripsi
Kec Angin	Hasil pengukuran kecepatan angin di luar bangunan kantor dalam kilometer/jam (km/h)
Day	Hari saat pembacaan dilakukan
Datetime	Waktu saat pembacaan dilakukan (yyyy-mm-dd hh:mm:ss).

3.3 Pemrosesan Dataset

Langkah selanjutnya setelah data historis terkumpul dari sistem monitoring *smart office* yang dibangun, maka dilakukan tahapan pemrosesan terhadap dataset. Hal ini sangat penting dilakukan karena kualitas dan informasi yang didapatkan dari dataset akan berpengaruh langsung pada kemampuan model untuk belajar. Sehingga, mulai dari tahapan pemrosesan dataset hingga pembangunan dan evaluasi model, penulis akan menggunakan bahasa pemrograman python pada platform *cloud computing* Google Collaboratory (Google Colab). Python pada Google Colab sudah dikenal secara umum sebagai alat pemrosesan data yang sangat baik dengan dukungan *library* yang sudah sangat lengkap untuk kebutuhan menghasilkan informasi yang berharga dari suatu data (Jogunola et al., 2022; Y. Li et al., 2021; Rick & Berton, 2022; Zaheer et al., 2023). Ada tiga kegiatan yang akan dilakukan dalam pemrosesan dataset, yaitu:

3.3.1 Data Pre-processing

Pada bagian *data preprocessing*, data hasil export dari sistem monitoring *smart office* akan melalui beberapa tahapan proses, antara lain:

- Melakukan pembersihan dataset agar data sesuai standar pemrosesan dengan baris pertama sebagai *header* dan baris sisanya sebagai isi dari data.
- Mengatur kolom waktu menjadi tipe data *datetime*. Hal ini sangat diperlukan untuk dapat melakukan ekstraksi fitur waktu lain pada tahapan proses selanjutnya.
- Membuat nama indeks baru menggunakan data pada kolom waktu dengan format *datetime* agar masing-masing *record* data memiliki nilai indeks yang berbeda dan berurutan berdasarkan waktu.
- Membuat urutan data berdasarkan indeks waktu dari periode awal hingga periode akhir pada data.
- Melakukan pengecekan urutan indeks berdasarkan waktu, agar dapat dipastikan dataset memiliki data yang tidak terlangkah sesuai dengan konsep data *time series*. jika ditemukan indeks yang terlangkah, maka akan dilakukan penciptaan *record* baru dengan nama indeks yang terlangkah.
- Melakukan pengecekan terhadap data yang kosong. Dikarenakan data yang kosong sangat berpengaruh terhadap kemampuan model dalam melakukan prediksi (Maharana et al., 2022).
- Melakukan teknik interpolasi dan imputasi terhadap data, sehingga *record* yang memiliki nilai data yang kosong dapat terisi. Teknik interpolasi dan imputasi pada pemrosesan dataset *time series* sangat penting dilakukan, hal ini dikarenakan penanganan nilai kosong pada dataset *time series* tidak dapat langsung dihapus seperti model dataset lainnya. Urutan data yang terlangkah atau acak pada data *time series* akan sangat berpengaruh buruk terhadap kemampuan model dalam mempelajari pola data (Maharana et al., 2022). Dalam penelitian ini teknik interpolasi data yang digunakan yaitu interpolasi linier untuk kolom dengan jenis data numerik, dimana pengisian data yang baru pada *record* yang kosong diisi dari perkiraan nilai diantara dua titik data yang diketahui (Hwang et al., 2020; Rick & Berton, 2022). Sedangkan untuk mengisi nilai pada jenis data kategori menggunakan teknik imputasi *backward fill* agar data baru yang dihasilkan diambil dari data pada *record* sebelumnya (Shapi et al., 2021).
- Menggabungkan keempat dataset yang sudah melalui tahapan pengisian data yang kosong menjadi satu dataset dengan melakukan persamaan terhadap indeks waktu yang sesuai.
- Menghapus variabel yang tidak diperlukan atau dianggap redundan pada dataset.
- Merubah nama variabel yang tidak sesuai.

- Melakukan teknik pemetaan manual pada data variabel kategori agar bentuk variabelnya berubah menjadi numerik untuk mempermudah proses lebih lanjut.

3.3.2 Data Exploratory & Analysis

Setelah dataset melewati proses *data pre-processing*, maka selanjutnya dataset akan divisualisasikan dan dianalisa sesuai kebutuhan melalui beberapa tahapan proses pada *data exploratory*, diantaranya:

- Membuat deskripsi variabel pada dataset untuk menampilkan sebaran data yang dimiliki.
- Membuat visualisasi *heatmap correlation matrix* untuk melihat korelasi antar variabel pada dataset.
- Membuat visualisasi kapasitas listrik kantor yang terpakai selama masa pengukuran. Visualisasi terhadap data diperlukan untuk menampilkan sebaran pemakaian listrik kantor selama waktu pengukuran (Yuniarti et al., 2022).
- Melakukan analisa korelasi antara variabel faktor internal dan variabel faktor eksternal terhadap konsumsi listrik kantor.
- Membuat visualisasi dan analisis tren pemakaian listrik harian dalam seminggu. Hal ini diperlukan untuk melihat informasi perbandingan pemakaian listrik saat hari kerja dan bukan hari kerja.
- Membuat visualisasi dan analisis tren pemakaian listrik saat jam kerja dan diluar jam kerja. Hal ini diperlukan untuk lebih memahami perbandingan antara keduanya.

3.3.3 Feature Engineering

Feature engineering dilakukan untuk dapat menghasilkan variabel yang baru atau bahkan mereduksi variabel sesuai pola yang berhasil ditemukan dari tahapan sebelumnya. Hal ini penting dilakukan mengingat untuk dapat meningkatkan akurasi prediksi diperlukan kreatifitas dalam memahami data yang didapatkan. Berikut beberapa proses yang dilakukan dalam tahapan ini:

- Menghapus variabel yang memiliki nilai korelasi rendah terhadap variabel target.
- Melakukan ekstraksi data dari variabel waktu sehingga menghasilkan fitur baru seperti tahun, bulan, hari, tanggal, jam dan menit.
- Membuat fitur baru berupa variabel *weekend* atau *weekdays* serta variabel jam kerja atau bukan jam kerja. Karena dari yang dapat dilihat pada tahapan *data exploratory*, didapatkan bahwa kondisi *weekend* dan jam kerja memiliki pengaruh yang tinggi terhadap pemakaian listrik pada kantor.

- Mengubah variabel kategori menjadi variabel numerik menggunakan teknik *label encoding*. Hal ini diperlukan karena model prediksi hanya bisa memproses fitur dengan jenis numerik (Maharana et al., 2022).
- Membuat variabel baru berupa nilai energi konsumsi listrik (kWh) dari variabel *real-time* pengukuran daya (Watt). Hal ini dikarenakan tujuan model prediksi dibangun untuk memprediksi konsumsi listrik bukan memprediksi kapasitas pemakaian listrik dalam satuan watt.
- Memilih fitur target dan fitur input dari variabel yang ada di dataset berdasarkan korelasi antara fitur dan target.
- Melakukan normalisasi fitur agar fitur berada dalam rentang yang sama saat diproses pada tahap pemrosesan model *deep learning*.(Maharana et al., 2022)
- Menerapkan teknik *sliding window* pada prediksi data *time series*, dimana untuk memprediksi target konsumsi listrik pada hari besok akan menggunakan fitur pada 7 hari sebelumnya. Metode *sliding window* merupakan salah satu teknik dalam pemrosesan data *time series* yang memiliki kemampuan dalam membuat fitur dari periode sebelumnya dengan target pada periode kedepannya. Sehingga untuk menghasilkan target periode kedepannya tidak harus menyediakan fitur pada periode target tersebut (Chou et al., 2019; Wu & Wu, 2024).
- Melakukan pemisahan data pelatihan (*training data*) dan data validasi (*validation data*), serta data baru untuk data pengujian (*testing data*). Data pelatihan akan digunakan pada pelatihan model dengan porsi 90% dari keseluruhan dataset, dan sisanya dengan porsi 10% digunakan untuk data validasi pada proses validasi pelatihan model. Sedangkan data pengujian diambil dari dataset berbeda yang merupakan pengukuran lanjutan dengan periode berbeda. Dimana data pengujian terdiri dari 8 hari pengukuran, dengan porsi 7 hari sebagai fitur input model dan 1 hari akhir digunakan untuk dapat melihat kemampuan model dalam memprediksi konsumsi listrik sehari kedepan.

3.4 Pembangunan Model Prediksi

Setelah data melalui tahapan pemrosesan dataset, maka selanjutnya data akan di proses dalam tahapan pembangunan model prediksi berbasis *deep learning*. Dalam membangun model prediksi ini, penulis menggunakan bahasa pemrograman python dan menggunakan arsitektur *deep learning* GRU dan BiGRU yang sudah banyak terbukti kemampuannya dalam melakukan prediksi pada data *time series*. Pemilihan GRU dan BiGRU pada penelitian ini dibandingkan arsitektur *deep learning* lainnya seperti LSTM dan BiLSTM

dilakukan karena beberapa alasan terkait dengan karakteristik dataset yang penulis miliki. Alasan pertama yaitu, walaupun LSTM lebih dikenal dalam kemampuan untuk mempelajari ketergantungan terhadap data panjang pada dataset *time series* dengan lebih baik, namun kadang sangat rentan terhadap masalah *vanishing gradient/exploding gradient* dikarenakan kompleksitas arsitekturnya. Beberapa kasus penelitian lainnya menyatakan bahwa proses pelatihan dari dataset yang kecil dan terbatas dapat menyebabkan performa LSTM lebih rendah dibandingkan dengan GRU (Bousnguar et al., 2023; Cahuantzi et al., 2023; Yang, Yu, et al., 2020), sehingga untuk melakukan peningkatan akurasi model menggunakan LSTM diperlukan arsitektur berlapis dan tuning hyperparameter yang lebih rumit. Kemudian alasan kedua yaitu, dikarenakan LSTM memiliki kompleksitas model yang lebih tinggi dari GRU, dimana mekanisme *update* parameter LSTM memiliki tiga gerbang (*forget gate*, *input gate*, dan *output gate*), sedangkan GRU hanya memiliki 2 gerbang yaitu *update gate* dan *reset gate*. Hal ini memungkinkan GRU untuk memproses informasi dengan lebih cepat dan efisien dengan kemampuan yang juga dapat mengatasi masalah *vanishing gradient* (Seabe et al., 2023).

Pembangunan model prediksi berbasis *deep learning* pada penelitian ini menggunakan platform Google Colab dengan memanfaatkan library tensorflow dan keras yang telah menyediakan beberapa teknik komputasi *deep learning* termasuk GRU dan BiGRU. Paket *subscription* Google Colab Pro yang digunakan penulis memiliki *resource* mesin komputasi berupa CPU, TPU atau GPU (dapat diatur sesuai kebutuhan), RAM sistem hingga 51GB, RAM GPU hingga 12GB, Memori Penyimpanan hingga 225GB dan *runtime session* hingga 84 jam. Dengan data input mencapai 40.000+ *record* data yang penulis hasilkan dari proses pengumpulan data, Google Colab menawarkan kemudahan aksesibilitas hanya dengan bermodalkan koneksi internet yang baik. Dalam membangun model prediksi menggunakan arsitektur *deep learning* ini penulis menggunakan tiga proses yaitu pelatihan, validasi dan pengujian.

3.4.1 Pelatihan Model Prediksi

Proses pelatihan model prediksi melibatkan layer GRU dan BiGRU serta pengaturan *hyperparameter*-nya untuk mencapai hasil optimal pada masing-masing arsitektur. Penyesuaian (*tuning*) *hyperparameter* diperlukan pada tahap pelatihan agar model dapat mempelajari pola dalam dataset dengan lebih efektif. Tujuan utama dari proses ini adalah untuk mencapai akurasi prediksi yang tinggi dan meminimalisir kesalahan prediksi (Janiesch et al., 2023; Jiménez-Navarro et al., 2023). Tabel 3.5 menampilkan saran penyesuaian

hyperparameter yang digunakan untuk membangun model GRU dan BiGRU pada penelitian ini.

Tabel 3.5 Penyesuaian *Hyperparameter*

Hyperparameter	<i>Tuning</i>	Alasan
<i>Layer</i> GRU/BiGRU	Mulai dengan satu <i>layer</i> , lalu eksperimen dengan dua atau tiga <i>layer</i> .	Menambahkan lebih banyak <i>layer</i> dapat membantu model mempelajari representasi yang lebih kompleks, tetapi juga meningkatkan risiko <i>overfitting</i> .
Jumlah Unit pada <i>layer</i> GRU/BiGRU	Mulai dengan <i>default</i> 50, Eksperimen dengan 32, 64, dan 128 unit untuk melihat dampaknya terhadap kinerja model.	Dataset dengan 47,520 <i>record</i> cukup besar, sehingga jumlah unit yang lebih tinggi mungkin lebih baik dalam menangkap pola yang kompleks.
Fungsi Aktivasi	Menggunakan ReLU untuk <i>setting</i> fungsi aktivasi.	ReLU membantu mengatasi masalah <i>vanishing gradient</i> dan memperkenalkan non-linearitas yang diperlukan untuk mempelajari pola kompleks.
Jumlah Unit pada <i>layer Dense</i> Output	Karena target prediksi sebanyak 1 hari data, maka nilai nya akan diisi 1.440	<i>Layer dense</i> menggabungkan fitur yang telah dipelajari dan menghasilkan prediksi akhir.
<i>Optimizer</i>	Menggunakan Adam <i>optimizer</i> dengan eksperimen berbagai nilai <i>Learning rate</i> , diantaranya: 0.1, 0.01, 0.001, atau 0.0003.	Adam menggabungkan keuntungan dari AdaGrad dan RMSProp, yang biasanya memberikan performa yang baik. <i>Learning rate</i> mengontrol langkah yang diambil algoritma saat memperbarui parameter model selama proses pelatihan.
<i>Epoch</i>	Mulai dengan 20 <i>epoch</i> . Eksperimen dengan 30, 40, 50 dan 100 <i>epoch</i> untuk melihat	Lebih banyak <i>epoch</i> memungkinkan model belajar lebih banyak dari data, tetapi juga

	apakah kinerja model meningkat.	bisa meningkatkan risiko <i>overfitting</i> .
<i>Batch Size</i>	Mulai dengan 64 <i>batch size</i> . Eksperimen dengan 16, 32 dan 128 <i>batch size</i> .	<i>Batch size</i> memengaruhi kecepatan pelatihan dan stabilitas. <i>Batch size</i> yang lebih kecil cenderung lebih stabil, tetapi pelatihan lebih lambat.

3.4.2 Validasi Model Prediksi

Setelah proses pelatihan model prediksi, langkah berikutnya adalah validasi model untuk memastikan bahwa model dapat memprediksi konsumsi listrik dengan baik pada data yang belum pernah dilihat sebelumnya selama pelatihan. Dalam penelitian ini, data validasi digunakan sebanyak 10% dari keseluruhan data pelatihan. Proses validasi model prediksi melibatkan beberapa langkah berikut:

- **Evaluasi Model Menggunakan Data Validasi:** Setelah model dilatih pada data pelatihan, model hasil pelatihan dievaluasi menggunakan data validasi dimana target prediksi dari data validasi akan di bandingkan dengan data aktualnya sehingga dapat diukur validitas model pada tahap pelatihan. Metode evaluasi yang digunakan pada tahap validasi adalah *Mean Squared Error (MSE)*, yang mengukur seberapa besar rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual. MSE yang lebih rendah menunjukkan kinerja model yang lebih baik.
- ***Fine-Tuning Hyperparameter:*** Berdasarkan hasil evaluasi awal, *hyperparameter* model dapat disesuaikan lebih lanjut untuk meningkatkan kinerja. Misalnya, jika model menunjukkan tanda-tanda *overfitting*, *layer*, jumlah unit atau jumlah *epoch* dapat dikurangi. Sebaliknya, jika model kurang belajar, jumlah unit dalam *layer* atau jumlah *epoch* dapat ditingkatkan.

3.4.3 Pengujian Model Prediksi

Setelah model berhasil divalidasi dan kinerja optimal telah dicapai, langkah terakhir adalah pengujian model prediksi menggunakan data pengujian. Data pengujian ini berbeda dari data pelatihan dan data validasi, serta digunakan untuk menguji kinerja model dalam kondisi dunia nyata. Proses pengujian model prediksi melibatkan langkah-langkah berikut:

- **Persiapan Data Pengujian:** Data pengujian dalam penelitian ini diambil dari data pengukuran 8 hari berturut-turut, hal ini untuk memastikan kemampuan model dalam

melakukan prediksi 1 hari kedepan dari data kondisi internal dan eksternal 7 hari sebelumnya (teknik *sliding window*).

- Analisis Hasil Pengujian: Hasil prediksi pada waktu yang ditentukan akan dibandingkan dengan nilai aktual target pada hari ke-8 dari data pengujian. Analisis ini membantu untuk memahami akurasi model, serta area-area yang mungkin memerlukan perbaikan lebih lanjut.

3.5 Evaluasi Model

Dalam sub bahasan ini, penulis akan mengevaluasi kinerja dari arsitektur *deep learning* GRU dan BiGRU yang sudah dibangun. Evaluasi model dilakukan dengan menggunakan beberapa metrik evaluasi seperti MSE, RMSE, MAE, R^2 , serta perbandingan waktu yang dibutuhkan selama pelatihan dan jumlah parameter dari masing-masing model.

MSE mengukur rata-rata kuadrat dari selisih antara nilai prediksi dan nilai aktual. MSE memberikan penilaian yang lebih berat pada kesalahan besar karena mengkuadratkan selisih, sehingga lebih sensitif terhadap *outliers*. RMSE, yang merupakan akar dari MSE, memberikan interpretasi kesalahan dalam satuan yang sama dengan data asli dan memudahkan pemahaman mengenai besar kesalahan prediksi. MAE mengukur rata-rata absolut dari selisih antara nilai prediksi dan nilai aktual, memberikan penilaian yang lebih langsung terhadap kesalahan prediksi tanpa mengkuadratkan selisihnya. MAE lebih intuitif karena memberikan rata-rata kesalahan yang sesungguhnya dalam satuan data asli. *R-Squared* (R^2) mengukur proporsi variabilitas dalam data yang bisa dijelaskan oleh model prediksi. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan model yang lebih baik dalam menjelaskan variabilitas data.

Selain menggunakan metrik evaluasi, penelitian ini juga membandingkan waktu yang dibutuhkan untuk pelatihan dan jumlah parameter dari masing-masing model yang dibangun (GRU dan BiGRU). Waktu pelatihan diukur untuk mengevaluasi efisiensi model dalam menghasilkan model prediksi, sedangkan jumlah parameter dihitung untuk memahami kompleksitas model. Jumlah parameter diperlukan untuk menilai seberapa besar memori dan komputasi yang dibutuhkan oleh model. Model dengan jumlah parameter yang lebih besar cenderung lebih kompleks dan membutuhkan lebih banyak sumber daya komputasi.

Melalui tahap evaluasi model ini, penulis dapat memahami keunggulan dan keterbatasan masing-masing arsitektur *deep learning* GRU dan BiGRU dalam konteks prediksi konsumsi listrik. Hal ini akan membantu dalam memilih model yang paling sesuai dengan kebutuhan spesifik aplikasi, baik dari segi akurasi maupun efisiensi komputasi (Al Hamoud et al., 2022; J. Chen et al., 2022; González-Sopeña et al., 2021).

BAB 4

Hasil dan Pembahasan

4.1 Sistem Monitoring *Smart Office* Berbasis IoT

Pada penelitian ini, untuk menghasilkan model prediksi konsumsi listrik pada perkantoran dengan kearifan lokal di Indonesia maka diperlukan dataset hasil observasi kondisi perkantoran di Indonesia pula. Untuk itu sistem monitoring *smart office* berbasis IoT dibangun dengan tujuan untuk mendapatkan data konsumsi listrik perkantoran serta kondisi internal dan eksternal gedung kantor. Agar selanjutnya data yang terkumpul dapat diproses lebih lanjut pada tahap analisa dan prediksi konsumsi listrik. Seperti yang sebelumnya telah dijelaskan pada bab metodologi, bahwa sistem monitoring *smart office* berbasis IoT dibangun menggunakan konsep *physical* dan *virtual environment*. Pada bagian *physical environment* dibagi menjadi 2 jenis rangkaian sensor yang terpasang pada bangunan kantor, yaitu rangkaian sensor *indoor* dan rangkaian sensor *outdoor*. Selanjutnya, data observasi yang dihasilkan oleh sensor-sensor IoT yang terpasang disimpan pada bagian *virtual environment*. Bagian *virtual environment* yang dimaksud berupa penyimpanan data pada *cloud database* dan representasi data menggunakan *website* pada *web hosting*. Output dari sistem monitoring *smart office* berbasis IoT berupa 4 buah dataset hasil observasi yaitu: dataset monitoring kelistrikan, dataset monitoring *indoor*, dataset monitoring *outdoor* dan dataset monitoring kecepatan angin.

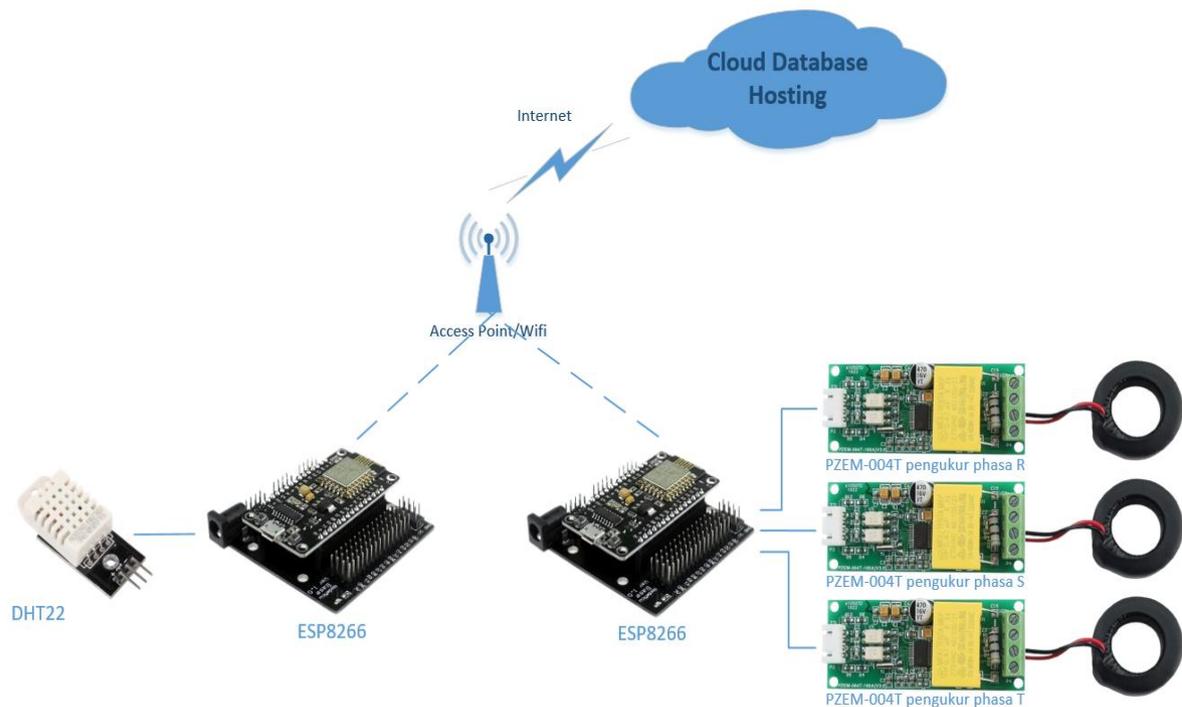
Meskipun sistem monitoring ini dibangun untuk memantau konsumsi listrik secara keseluruhan, namun masih ada keterbatasan dalam pengawasan detail terhadap penggunaan listrik oleh perangkat-perangkat spesifik, seperti AC (*Air Conditioner*), printer, kulkas, kompor listrik, dan peralatan listrik lain pada kantor PLN Icon Plus Jogja. Salah satunya seperti yang penulis temukan, bahwa penggunaan AC pada kantor ini menunjukkan kontribusi yang cukup signifikan terhadap total konsumsi listrik. Hal ini didasari pada kondisi dimana kantor ini memiliki 12 unit AC yang masing-masing memiliki kapasitas antara 1 hingga 2 pk. Jika diasumsikan bahwa 12 unit AC ini dihidupkan secara bersamaan, penggunaan listrik untuk AC saja bisa mencapai 10.000 watt. Angka ini hampir mendekati kapasitas kelistrikan utama kantor yang sebesar 16.500 watt, menunjukkan bahwa faktor pendingin ruangan ini sangat mempengaruhi total konsumsi listrik kantor. Pemahaman ini dapat menyoroti pentingnya memperhatikan efisiensi penggunaan AC dalam upaya mengelola konsumsi listrik secara lebih efektif dan ekonomis di kantor tersebut.

4.1.1 Physical Environment

1. Rangkaian Sensor Indoor

Rangkaian sensor *indoor* dibagi menjadi 2 area pengukuran, yaitu area kelistrikan dan area ruangan tempat kerja, dimana 2 rangkaian sensor *indoor* merepresentasikan variabel-variabel kondisi internal bangunan kantor. Pada area kelistrikan dipasang 3 buah sensor PZEM-004T untuk mengukur nilai tegangan dan arus listrik pada *phasa* R, S dan T di ACPDB kelistrikan kantor dengan kapasitas 16.500 watt. Ketiga sensor PZEM-004T terhubung ke 1 buah mikrokontroller ESP8266 yang bertugas sebagai otak pemrosesan data. Selanjutnya, pada area ruangan tempat kerja dipasang 1 buah sensor DHT22 untuk mengukur nilai suhu dan kelembaban di dalam kantor. Sensor DHT22 ini juga terhubung ke 1 buah mikrokontroller ESP8266 yang bertugas sebagai otak pemrosesan data. Kemudian pada akhirnya, data yang di proses pada kedua ESP8266 melakukan pengiriman data historis hasil pengukuran setiap 1 menit sekali ke penyimpanan pada *cloud hosting* melalui jaringan internet wifi kantor. Proses pengumpulan dan pengiriman data ini memastikan bahwa informasi mengenai kondisi kelistrikan dan lingkungan dalam kantor selalu tersedia secara *real-time* untuk keperluan analisis lebih lanjut.

Rangkaian sensor *indoor* dapat dilihat pada Gambar 4.1 dimana sensor DHT22 dan sensor PZEM-004T terhubung ke ESP8266 yang juga terhubung ke *cloud database* melalui jaringan internet.

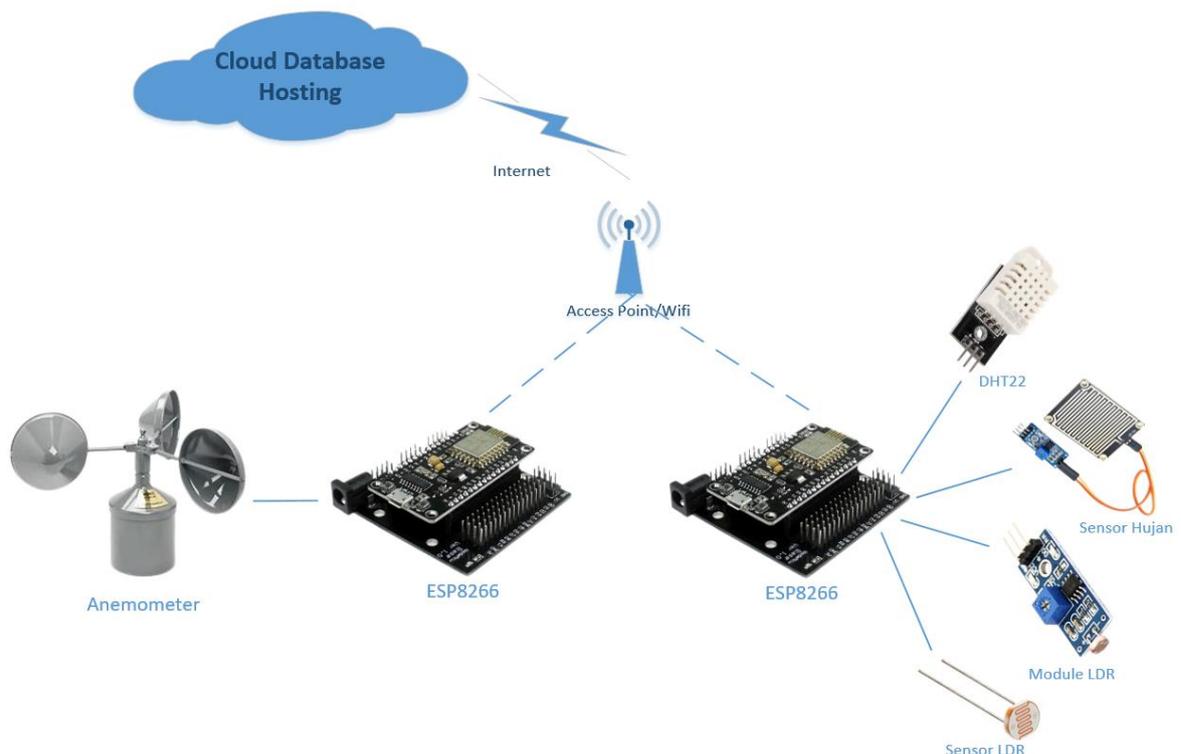


Gambar 4.1 Rangkaian Sensor Indoor

2. Rangkaian Sensor *Outdoor*

Rangkaian sensor *outdoor* mencakup pengukuran kondisi eksternal luar bangunan kantor, terutama kondisi cuaca lingkungan sekitar kantor. Rangkaian sensor outdoor ini akan menggunakan 2 buah ESP8266 yang bertugas untuk memproses data eksternal. ESP8266 yang pertama digunakan untuk melakukan pemrosesan data dari sensor DHT22 sebagai pengukur nilai suhu dan kelembababan, sensor hujan serta sensor LDR untuk menangkap data kondisi cahaya dan intensitas cahaya. Kemudian pada ESP8266 yang kedua digunakan untuk melakukan pemrosesan data dari anemometer untuk mengukur kecepatan angin. Selanjutnya, data yang di proses pada kedua ESP8266 *outdoor* dilakukan pengiriman data historis hasil pengukuran setiap 1 menit ke penyimpanan pada *cloud hosting* melalui jaringan internet wifi kantor. Proses pengumpulan dan pengiriman data secara *real-time* ini memastikan bahwa informasi mengenai kondisi cuaca di luar bangunan kantor selalu tersedia untuk analisis yang lebih mendalam.

Rangkaian sensor *outdoor* dapat dilihat pada Gambar 4.2 dimana anemometer, sensor LDR, sensor hujan, dan sensor DHT22 terhubung ke ESP8266 yang juga terhubung ke *cloud database* melalui jaringan internet. Untuk melihat dokumentasi lebih lanjut mengenai implementasi rangkaian sensor *indoor* dan *outdoor* dalam sistem monitoring berbasis IoT yang sudah terpasang pada kantor PLN Icon Plus Yogyakarta dapat dilihat pada lampiran A.



Gambar 4.2 Rangkaian Sensor Outdoor

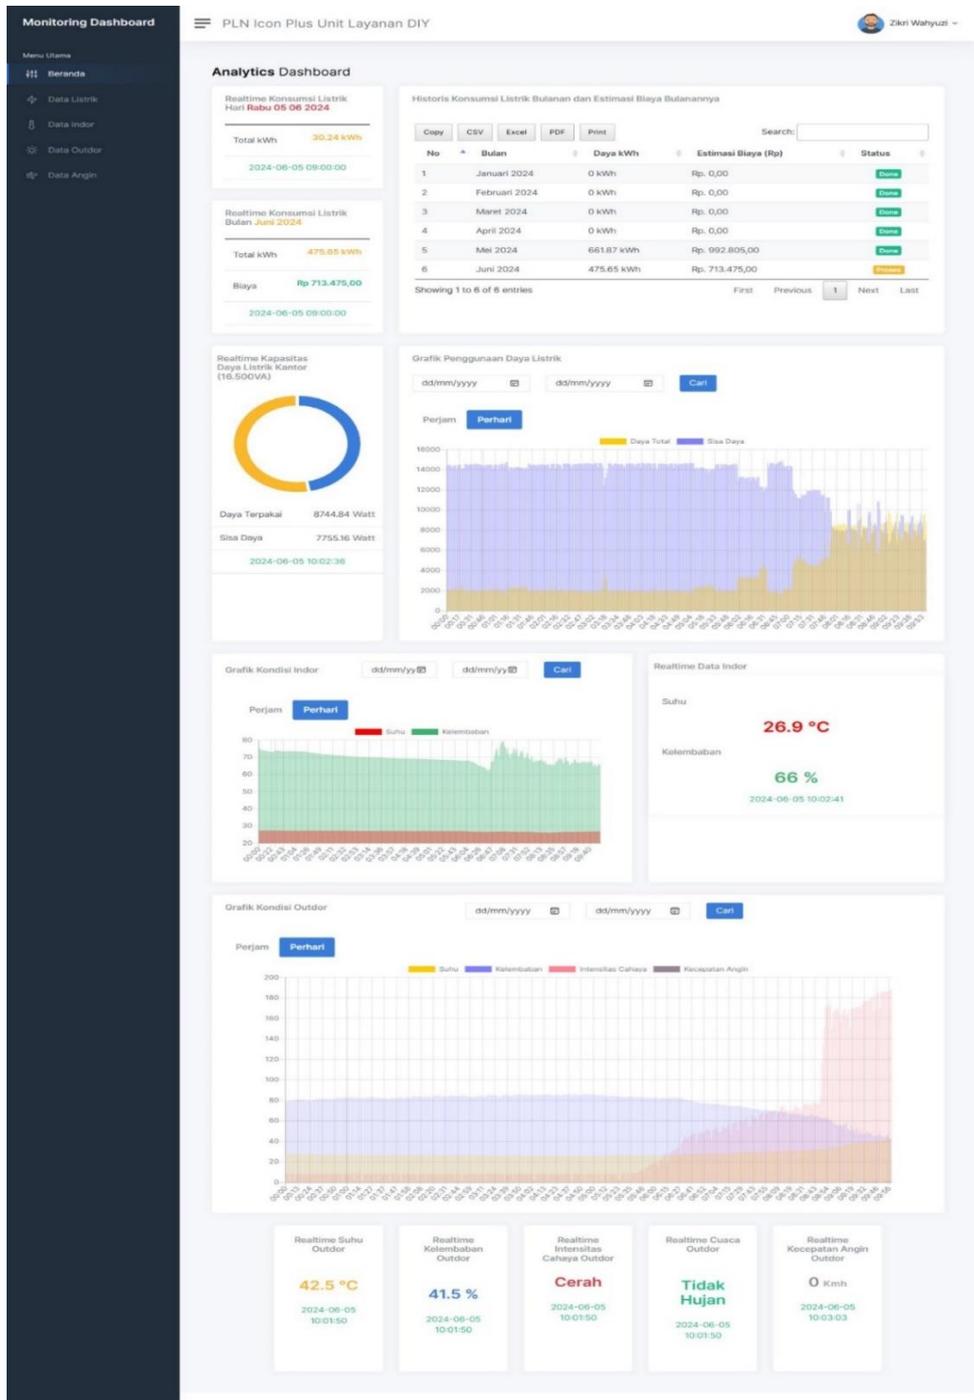
4.1.2 *Virtual Environment*

Virtual environment yang digunakan dalam penelitian ini merupakan komponen vital yang terdiri dari *cloud hosting*, di mana *cloud database* dan *web hosting* berada. Untuk keperluan ini, penulis memilih layanan dari penyedia *hosting* "Hostinger". Agar data historis yang dikirimkan dari *physical environment* dapat tersimpan dengan baik di *cloud database*, diperlukan adanya API yang berfungsi sebagai penghubung. API ini dirancang dan diimplementasikan oleh penulis pada *web hosting* menggunakan bahasa pemrograman PHP. API tersebut memungkinkan integrasi antara rangkaian alat IoT dan database MySQL, yang juga disediakan oleh penyedia *hosting*. MySQL dipilih karena keandalannya dalam menangani penyimpanan data yang besar serta kemudahan dalam manajemen data.

Lebih lanjut, di dalam *virtual environment* ini, penulis mengembangkan sebuah *website* menggunakan *framework* Laravel. *Framework* ini dipilih karena kemampuannya dalam membangun aplikasi web yang kuat dan skalabel. *Website* tersebut berfungsi untuk merepresentasikan data yang sudah terkumpul dalam bentuk *dashboard* visualisasi dan halaman untuk ekspor data. *Dashboard* ini memungkinkan pengguna untuk memantau dan menganalisis data dengan mudah. *Website* ini di-*hosting* secara *online* dengan domain khusus, yaitu kantorku.cloud, yang memudahkan aksesibilitas dari mana saja dan kapan saja. Dengan demikian, seluruh proses mulai dari pengumpulan data, penyimpanan hingga penyajian data dapat dilakukan secara efisien dan terpusat dalam satu sistem berbasis *cloud*.

Dashboard website yang dikembangkan dalam penelitian ini dirancang untuk menampilkan beragam data dan informasi yang terkait dengan kondisi kelistrikan serta kondisi internal dan eksternal bangunan kantor. Seperti yang digambarkan pada Gambar 4.3, *dashboard* ini menyajikan data dalam bentuk visualisasi grafik dan tabel yang interaktif. Fitur-fitur utama yang ditampilkan meliputi beberapa elemen penting. Pertama, data *real-time* konsumsi listrik pada hari berjalan dan akumulasi bulanan, yang memberikan wawasan langsung tentang penggunaan energi saat ini dan tren penggunaannya. Ini sangat membantu dalam memahami pola konsumsi listrik harian dan bulanan serta mengidentifikasi potensi penghematan energi. Kedua, *dashboard* menyajikan historis konsumsi listrik per bulan, yang berguna untuk melihat perkiraan penggunaan energi dan biaya pemakaian listrik untuk bulan berjalan dan bulan-bulan sebelumnya. Fitur ini memberikan gambaran yang jelas tentang bagaimana energi digunakan dari waktu ke waktu dan memungkinkan perencanaan yang lebih baik untuk kebutuhan energi di masa depan. Ketiga, data *real-time* dan grafik kapasitas listrik terpakai dan sisanya, yang penting untuk memastikan bahwa penggunaan energi tetap berada dalam batas kapasitas yang tersedia dan mencegah kelebihan beban listrik. Keempat,

data kondisi internal bangunan kantor seperti suhu dan kelembaban dalam waktu nyata, yang dapat membantu dalam mengelola kenyamanan lingkungan kerja. Kelima, data kondisi eksternal seperti suhu, kelembaban, intensitas cahaya, kondisi hujan, dan kecepatan angin, yang memberikan informasi tambahan untuk analisis kondisi lingkungan sekitar kantor. Semua fitur ini dirancang untuk memberikan pandangan yang komprehensif dan terkini mengenai penggunaan energi dan kondisi lingkungan, sehingga mendukung keputusan manajemen yang lebih baik dan efisien.



Gambar 4.3 Tampilan *Dashboard Website* kantorku.cloud

Selain itu, *website* kantorku.cloud juga menyediakan halaman khusus untuk mengekspor data historis dalam berbagai kategori, yaitu data historis kelistrikan, data historis *indoor*, data historis *outdoor*, dan data historis kecepatan angin. Pengguna memiliki opsi untuk mengekspor data ini dalam berbagai format seperti CSV, Excel, dan PDF, sesuai kebutuhan analisis dan dokumentasinya. Tampilan antarmuka untuk halaman ekspor data kelistrikan dapat dilihat pada Gambar 4.4, tampilan antarmuka untuk halaman ekspor data *indoor* dapat dilihat pada Gambar 4.5, tampilan antarmuka untuk halaman ekspor data *outdoor* dapat dilihat pada Gambar 4.6, dan tampilan antarmuka untuk halaman ekspor data kecepatan angin dapat dilihat pada Gambar 4.7.

The screenshot shows the 'Monitoring Data Listrik' dashboard. The sidebar menu is on the left, and the main content area is titled 'Data Sensor Tegangan'. Below the title, there is an 'Export' section with a date range selector (dd/mm/yyyy) and a 'Cari' button. Below the export section, there are buttons for 'Copy', 'CSV', 'Excel', 'PDF', and 'Print'. A search bar is also present. The main data table has the following columns: id, Tegangan 1, Arus 1, Daya 1, Tegangan 2, Arus 2, Daya 2, Tegangan 3, Arus 3, Daya 3, Total Daya, Sisa Daya, Day, and Datetir. The table contains two rows of data.

id	Tegangan 1	Arus 1	Daya 1	Tegangan 2	Arus 2	Daya 2	Tegangan 3	Arus 3	Daya 3	Total Daya	Sisa Daya	Day	Datetir
1	219.1	14.01	3069.37	215.4	19.8	4265.14	225.4	7.64	1721.15	9055.66	7444.34	Rabu	2024-06-05 10:59:00
2	220.5	13.73	3026.58	215.3	19.95	4295.67	224.1	11.35	2543.76	9866.01	6633.99	Rabu	2024-06-05 10:58:00

Gambar 4.4 Tampilan Halaman *Export* Data Kelistrikan

The screenshot shows the 'Monitoring Data Indoor' dashboard. The sidebar menu is on the left, and the main content area is titled 'Data Sensor Indoor'. Below the title, there is an 'Export' section with a date range selector (dd/mm/yyyy) and a 'Cari' button. Below the export section, there are buttons for 'Copy', 'CSV', 'Excel', 'PDF', and 'Print'. A search bar is also present. The main data table has the following columns: ID, Suhu Ind, Kelembaban Ind, Day, and Datetime. The table contains two rows of data.

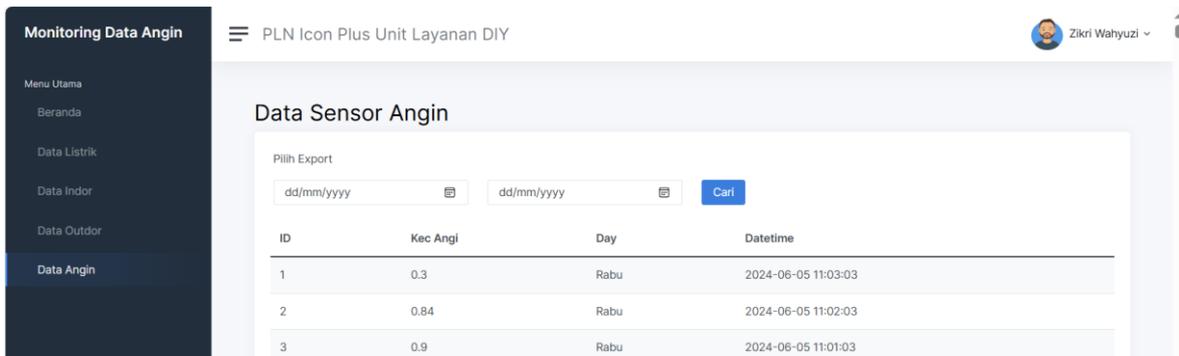
ID	Suhu Ind	Kelembaban Ind	Day	Datetime
1	27.2	63.2	Rabu	2024-06-05 11:00:50
2	27.2	64.1	Rabu	2024-06-05 10:59:50

Gambar 4.5 Tampilan Halaman *Export* Data Indoor

The screenshot shows the 'Monitoring Data Outdoor' dashboard. The sidebar menu is on the left, and the main content area is titled 'Data Sensor Outdoor'. Below the title, there is an 'Export' section with a date range selector (dd/mm/yyyy) and a 'Cari' button. Below the export section, there are buttons for 'Copy', 'CSV', 'Excel', 'PDF', and 'Print'. A search bar is also present. The main data table has the following columns: ID, Suhu Out, Kelembaban Out, Hujan, Kondisi Cahaya, Intensitas Cahaya, Day, and Datetime. The table contains two rows of data.

ID	Suhu Out	Kelembaban Out	Hujan	Kondisi Cahaya	Intensitas Cahaya	Day	Datetime
1	40.7	45.9	Not Rain	Bright	204	Rabu	2024-06-05 11:01:52
2	39.9	44.5	Not Rain	Bright	204	Rabu	2024-06-05 11:00:51

Gambar 4.6 Tampilan Halaman *Export* Data Outdoor



Gambar 4.7 Tampilan Halaman *Export* Data Angin

4.1.3 Output Infrastruktur Pengumpulan Data

Pada akhirnya, tujuan dari sistem monitoring *smart office* berbasis IoT agar menghasilkan dataset historis kondisi kelistrikan serta kondisi internal dan eksternal pada bangunan kantor. Dataset historis yang terkumpul akan diolah lebih lanjut melalui tahapan pemrosesan dataset agar dapat digunakan sebagai input pada model prediksi konsumsi listrik yang dibangun kemudian. Dari eksperimen yang dilakukan oleh penulis mulai dari bulan desember 2023 sampai bulan januari 2024, penulis berhasil melakukan penambangan data historis pada perkantoran selama 35 hari mulai dari tanggal 4 desember 2023 sampai dengan 7 januari 2024. Data historis ini terekam dalam 4 dataset berbentuk *file* excel yang berhasil di ekspor dari *website* kantorku.cloud dengan rinciannya dapat dilihat pada Tabel 4.1. Walaupun dapat dilihat ternyata jumlah *record* pada masing-masing dataset berbeda-beda, setelah penulis analisa lebih lanjut ternyata hal ini disebabkan kegagalan input data per menit pada sistem monitoring *smart office*. Sehingga untuk mengatasi jumlah *record* yang tidak sama, penulis akan melakukan beberapa teknik *pre-processing* seperti interpolasi linier dan imputasi data pada dataset output.

Tabel 4.1 Dataset Hasil *Export* dari Website

No.	Nama Dataset	Jumlah Record	Jumlah Variabel	Detail Variabel
1.	Electricity	40.034	13	Tegangan 1, Arus1, Daya 1, Tegangan 2, Arus 2, Daya 2, Tegangan 3, Arus 3, Daya 3, Total Daya, Sisa Daya, Day, Datetime

2.	Indoor	47.600	4	Suhu Ind, Kelembaban Ind, Day, Datetime
3.	Outdoor	41.006	7	Suhu out, Kelembaban out, Hujan, Kondisi Cahaya, Intensitas Cahaya, Day, Datetime
4.	Wind	43.530	3	Kec Angin, Day, Datetime

4.2 Pemrosesan Dataset

4.2.1 Data Pre-processing

Dataset dari hasil sistem monitoring *smart office* akan melalui tahap *pre-processing* agar dilakukan pembersihan data sesuai kebutuhan untuk proses eksplorasi dan analisa lebih lanjut. Proses ini dimulai dari memasukkan *library* yang diperlukan untuk pemrosesan data (*pandas*) dan dilanjutkan dengan mengimpor keempat dataset yang berbentuk excel ke penyimpanan Google Colab. Dari deskripsi masing-masing dataset ditemukan bahwa setiap dataset memiliki jumlah *record* data yang berbeda-beda. Sehingga agar dapat dilakukan penggabungan ke-4 dataset menjadi 1 dataset akhir untuk proses selanjutnya, maka *record* menit yang kosong akan di buat dengan mengisi nilai variabel yang kosong menggunakan teknik interpolasi linier (untuk variabel numerik) dan imputasi *back-forward* (untuk variabel kategori). Setelah keempat dataset memiliki sebaran data dengan menit yang lengkap selama periode jam 00:00 4 desember 2023 sampai jam 23:59 7 januari 2024, selanjutnya ke-4 dataset digabung menjadi satu buah dataset baru dengan nama 'df_combined'.

Kemudian dataset hasil penggabungan (df_combined) melalui proses pembersihan data lainnya seperti mengganti nama variabel pada dataset dengan nama yang sesuai (Total Daya menjadi realtime_daya), menghapus variabel yang redundan (Daya 1, Daya 2, Daya 3 dan Sisa Daya), mengganti tipe data variabel yang belum sesuai (Datetime), serta melakukan pemetaan manual agar variabel kategori (object) berubah bentuk menjadi numerik (Hujan Kondisi cahaya & Day). Deskripsi dari dataset gabungan dengan nama 'df_combined' dapat dilihat pada Gambar 4.8. Dimana dataset gabungan 'df_combined' memiliki ukuran dataframe 50.400 *record* dengan 17 variabel. Terdapat 16 variabel dengan tipe data numerik (float & int) serta 1 variabel dengan tipe data datetime.

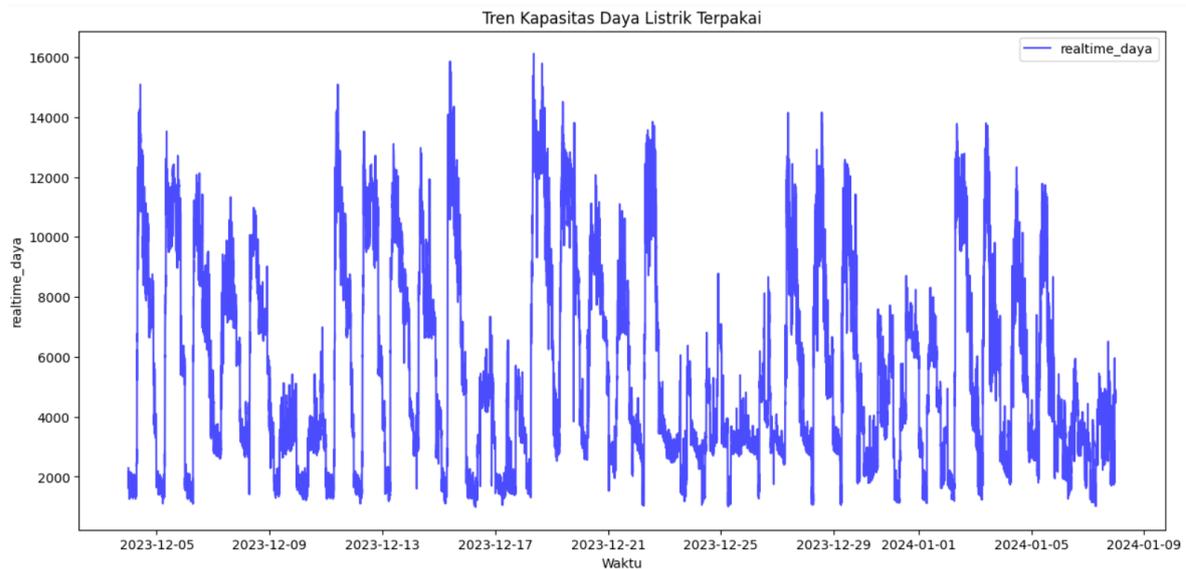
```
df_combined.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 50400 entries, 0 to 50399
Data columns (total 17 columns):
#   Column                Non-Null Count  Dtype
---  ---                -
0   realtime_daya         50400 non-null   float64
1   Datetime              50400 non-null   datetime64[ns]
2   Day                   48776 non-null   float64
3   Tegangan 1           50400 non-null   float64
4   Arus 1                50400 non-null   float64
5   Tegangan 2           50400 non-null   float64
6   Arus 2                50400 non-null   float64
7   Tegangan 3           50400 non-null   float64
8   Arus 3                50400 non-null   float64
9   Suhu Ind              50400 non-null   float64
10  Kelembaban Ind       50400 non-null   float64
11  Suhu Out              50400 non-null   float64
12  Kelembaban Out       50400 non-null   float64
13  Hujan                 50400 non-null   int64
14  Kondisi Cahaya       50400 non-null   int64
15  Intensitas Cahaya    50400 non-null   float64
16  kec_angin            50400 non-null   float64
dtypes: datetime64[ns](1), float64(14), int64(2)
memory usage: 6.5 MB
```

Gambar 4.8 Deskripsi dataset gabungan dengan nama 'df_combined'

4.2.2 Data Exploratory & Analysis

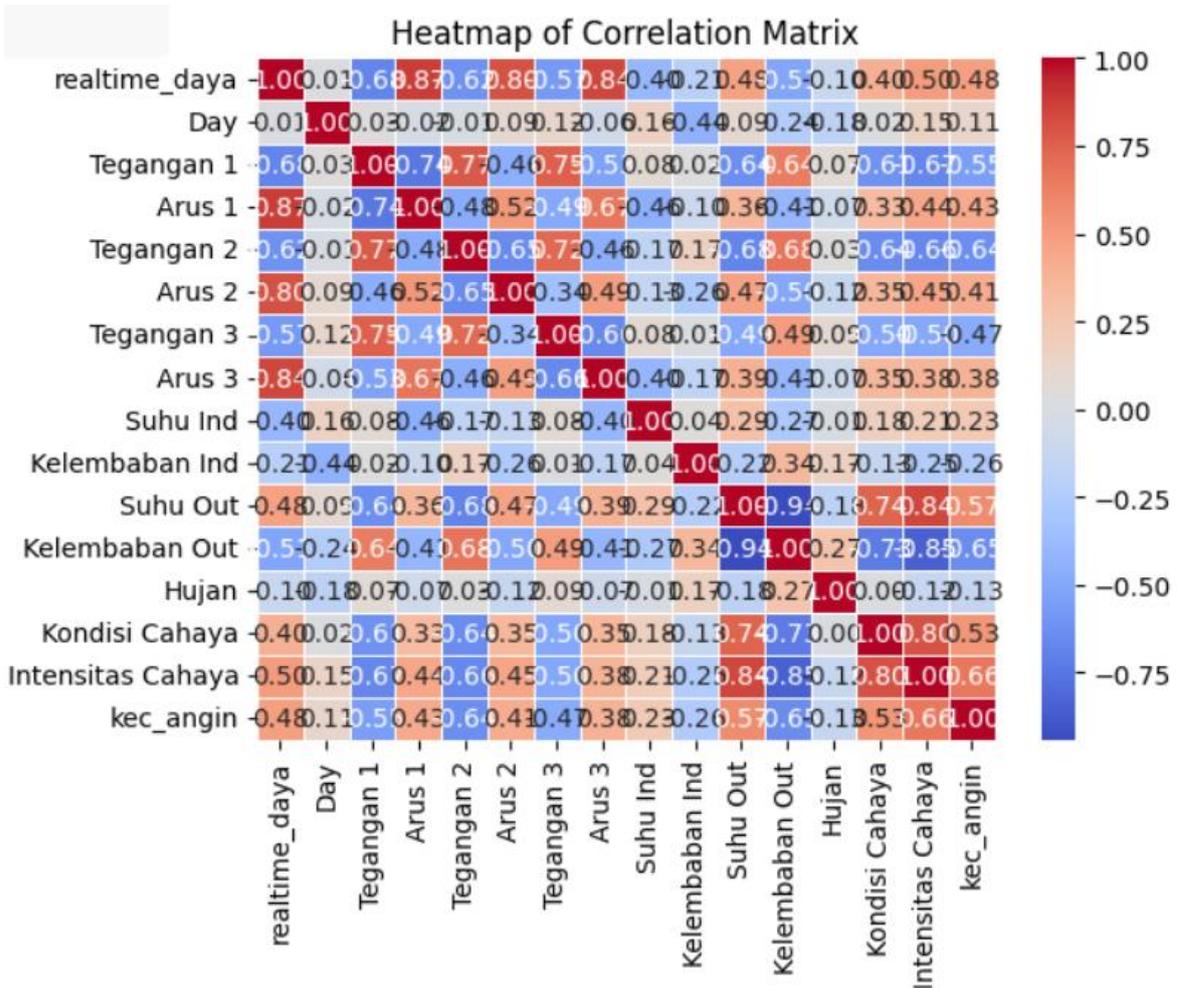
Setelah dataset gabungan terbentuk, maka selanjutnya penulis melakukan beberapa teknik visualisasi dalam proses eksplorasi dan analisis untuk dapat melihat pola tersembunyi dalam data menggunakan *library* matplotlib dan seaborn yang tersedia di Google Colab. Sebelum dilakukan analisa lebih lanjut, penulis menampilkan sebaran data pemakaian listrik dari periode waktu dataset seperti dapat dilihat pada Gambar 4.9. Visualisasi ini diperlukan bagi penulis untuk dapat melihat pemakaian listrik dari waktu ke waktu secara keseluruhan. Dari visualisasi menggunakan *line plot* ini dapat diartikan bahwa selama periode dari tanggal 4 desember 2023 sampai dengan 7 januari 2024, ditemukan bahwa penggunaan daya listrik terjadi diantara *range* 1.000 watt hingga 16.000 watt secara fluktuatif. Kenaikan dan penurunan pemakain listrik ini sangat menarik bagi penulis untuk dapat di analisa lebih lanjut terkait faktor-faktor apa saja yang mempengaruhinya.



Gambar 4.9 Tren Pemakaian Listrik 04/07/2023 - 07/01/2024

1. Analisis Korelasi Antar Variabel

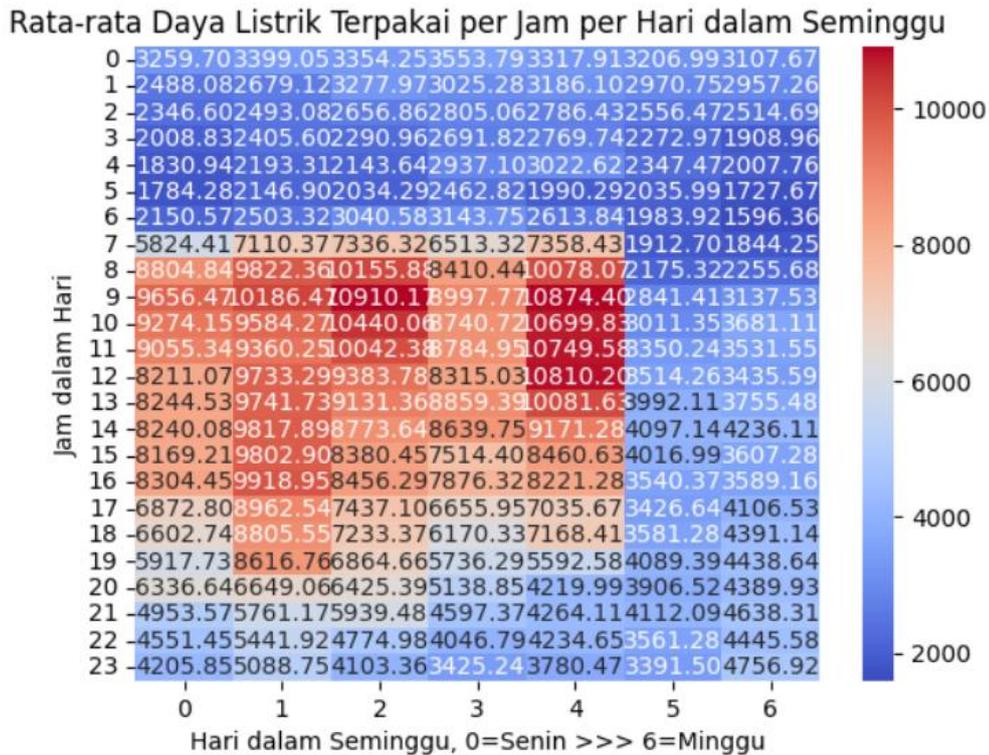
Untuk melihat hubungan antar variabel dalam dataset maka penulis menggunakan *heatmap* korelasi seperti yang dapat dilihat pada Gambar 4.10. Dari analisa visualisasi metrik korelasi tersebut dapat diambil beberapa kesimpulan terkait dataset yang penulis dapat dari penambahan data yang dilakukan. Dalam hal ini variabel ‘realtime_daya’ akan dianggap sebagai target dan variabel sisanya akan kita jadikan sebagai fitur input. Sehingga penting untuk melihat hubungan antara target dan fitur input ini yang akan menjadi salah satu latar belakang pemilihan fitur pada model prediksi. Dari *heatmap* korelasi pada Gambar 4.10 dapat dilihat bahwa yang memiliki korelasi positif terhadap target (realtime_daya) adalah ‘Arus 1’, ‘Arus 2’, ‘Arus 3’, ‘Intensitas Cahaya’, ‘kec_angin’, ‘Suhu Out’, ‘Kondisi Cahaya’, dan ‘Day’. Kebalikannya, fitur yang memiliki korelasi negatif terhadap target adalah ‘Hujan’, ‘Kelembaban Ind’, ‘Suhu Ind’, ‘Kelembaban Out’, ‘Tegangan 1’, ‘Tegangan 2’, dan ‘Tegangan 3’. Pada dasarnya, *heatmap* korelasi juga dapat melakukan analisa lebih lanjut terkait korelasi antar fitur input. Namun, dalam hal pembangunan model prediksi konsumsi listrik ini, penulis berfokus hanya pada analisa fitur input dan target prediksi. Pemilihan fitur input yang tepat ini akan berkontribusi signifikan terhadap keakuratan dan keefektifan model prediksi, karena fitur input yang memiliki korelasi kuat dengan target akan memberikan informasi lebih baik kepada model dalam proses pembelajaran dan prediksi. Dengan memahami bagaimana setiap variabel berhubungan dengan konsumsi listrik secara keseluruhan, *heatmap* korelasi ini dapat mengoptimalkan pemilihan fitur untuk mencapai prediksi yang lebih akurat dan efisien.



Gambar 4.10 Heatmap Korelasi Antar Variabel

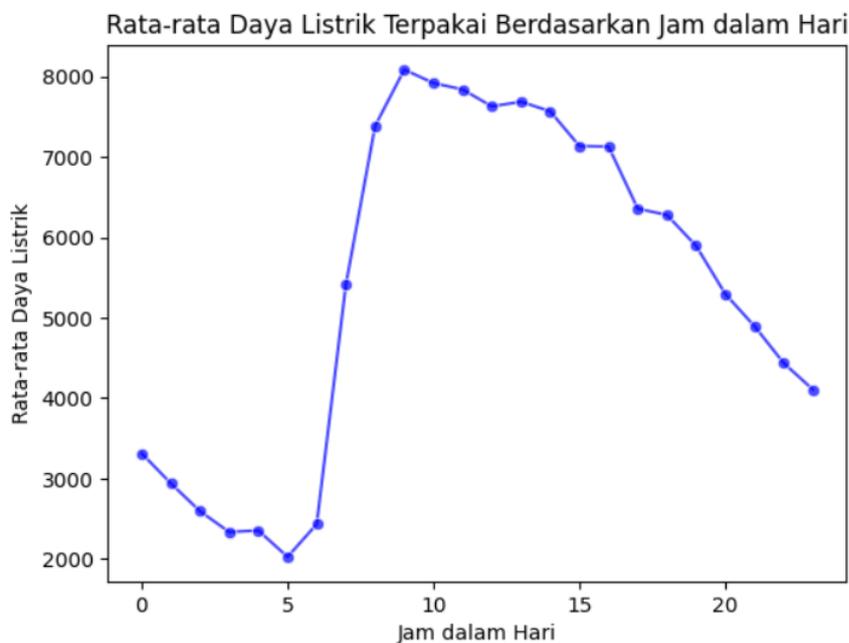
2. Analisis Tren Penggunaan Listrik Harian

Selanjutnya, berangkat dari hubungan korelasi antara fitur input dan target, dapat dilihat bahwa ternyata fitur ‘Day’ termasuk dalam korelasi positif terhadap target, yang menandakan diperlukannya analisa lanjutan terkait waktu. Dengan informasi waktu pada dataset yang tersedia, penulis melakukan analisa lebih lanjut terhadap tren penggunaan listrik hariannya. Pada Gambar 4.11 dapat dilihat visualisasi *heatmap* dari rata-rata penggunaan listrik per jam dalam seminggu. Dimana terlihat penggunaan listrik tinggi terletak pada kisaran jam 7 hingga jam 20 dan hari senin hingga hari jumat. Sehingga dapat disimpulkan bahwa ternyata periode waktu harian juga sangat berpengaruh terhadap pemakaian listrik, baik periode waktu dalam jam ataupun waktu dalam hari. Selain itu, pemahaman ini menggarisbawahi bahwa pola aktivitas rutin kantor dapat mempengaruhi konsumsi listrik secara signifikan. Wawasan ini dapat membantu merancang strategi pengelolaan energi yang lebih efisien, seperti mengatur penggunaan listrik berdasarkan waktu puncak dan mengurangi penggunaan listrik pada saat jam non-operasional.



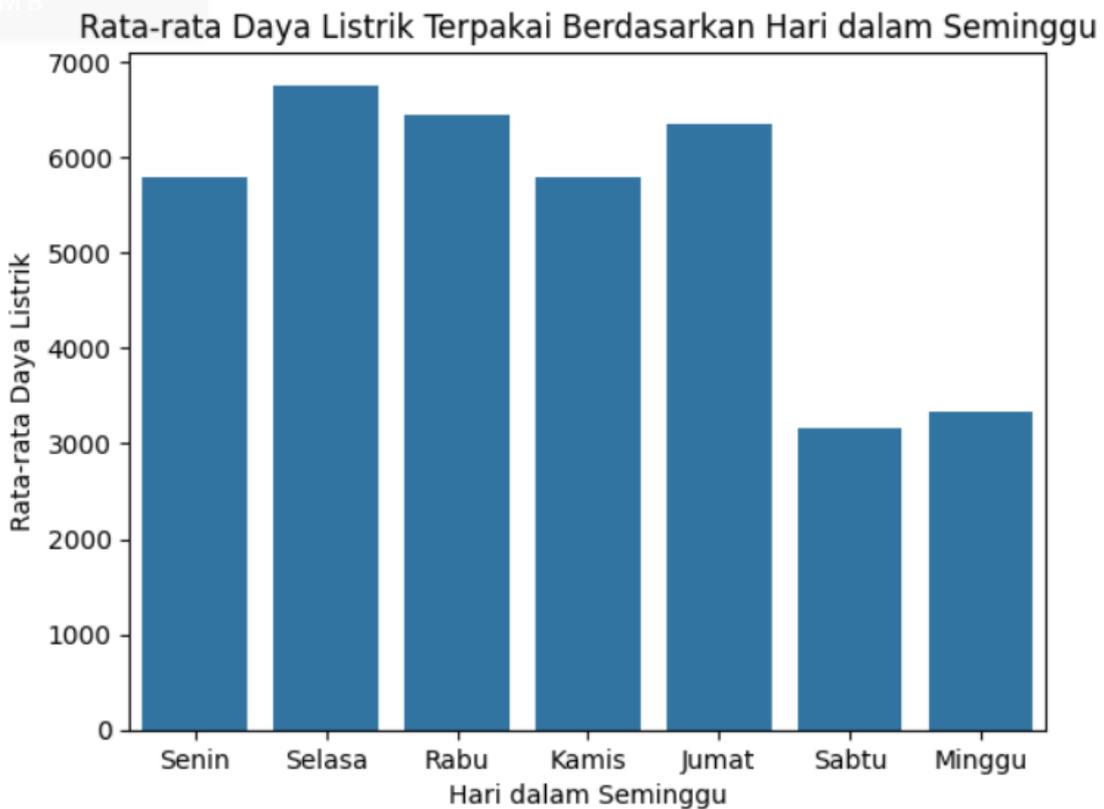
Gambar 4.11 Heatmap Rata-rata Penggunaan Listrik Per Jam Dalam Seminggu

Sebagai visualisasi lanjutan pada analisis tren penggunaan listrik harian, Gambar 4.12 menampilkan pola yang terbentuk dari rata-rata penggunaan listrik per jam selama masa pengukuran listrik pada dataset. Dimana penggunaan listrik kantor dari dini hari akan turun hingga jam 5:00 pagi, dan akan naik secara signifikan mulai dari jam 6:00 hingga puncaknya ada di sekitar jam 9:00 hingga jam 10:00. Kemudian dari jam 11 rata-rata penggunaan listrik perlahan turun kembali secara lambat hingga jam 24:00.



Gambar 4.12 Rata-rata Penggunaan Listrik Harian Dalam jam

Gambar 4.13 menampilkan rata-rata penggunaan listrik dari hari senin hingga hari minggu. Dimana penggunaan listrik pada hari kerja senin sampai jumat (*weekday*) lebih tinggi dibandingkan pada akhir pekan sabtu dan minggu (*weekend*). Jika dihitung dalam proporsi, bahwa rata-rata penggunaan listrik pada hari kerja akan meningkat hingga 2 kali lipat (100%) dari penggunaan listrik pada akhir pekan.



Gambar 4.13 Rata-rata Penggunaan Listrik Per Hari

3. Analisis Tren Penggunaan Listrik Jam Kerja dan Diluar Jam Kerja

Untuk analisis tren penggunaan listrik pada jam kerja dan diluar jam kerja, penulis membuat batasan terhadap jam kerja dalam sehari, yaitu dari jam 08:00 hingga jam 17:00 akan disebut sebagai jam kerja, dan sisanya dianggap sebagai diluar jam kerja. Tabel 4.2 menampilkan statistik deskriptif dari penggunaan listrik pada jam kerja dan diluar jam kerja. Dimana nilai *mean* dari penggunaan listrik dalam watt pada jam kerja lebih banyak hingga 2 kali lipat dari diluar jam kerja. Sehingga dapat ditarik kesimpulan bahwa, walaupun dengan jumlah jam harian yang lebih sedikit dibandingkan dengan diluar jam kerja, namun pemakaian listrik pada jam kerja tetap lebih tinggi. Hal ini dapat terjadi dikarenakan operasional pada perkantoran yang puncaknya dilakukan pada jam kerja, sehingga kegiatan pekerjaan yang dilakukan oleh karyawan di kantor sangat mempengaruhi konsumsi listrik kantor itu sendiri.

Tabel 4.2 Statistik Deskriptif Penggunaan Listrik Jam Kerja & Diluar Jam Kerja

Ukuran Statistik	Jam Kerja	Diluar Jam Kerja
Count (jumlah record)	21000,00	29400,00
Mean (dalam watt)	7473,62	3879,99
Standard Deviation (dalam watt)	3430,20	2280,64
Min (dalam watt)	1086,19	987,82
Q 1 (25%) (dalam watt)	4248,43	2168,16
Q 2 (50%) (dalam watt)	7817,50	3198,99
Q 3 (75%) (dalam watt)	10206,52	5097,88
Max (dalam watt)	16119,03	14086,93

4.2.3 Feature Engineering

Pada bagian *feature engineering* telah dilakukan implementasi dari temuan yang didapatkan pada proses eksplorasi dan analisis data sebelumnya. Dimana hal ini sangat bergantung kepada kemampuan dan kreatifitas penulis dalam mengolah data. Sehingga apa yang ditemukan pada tahap eksplorasi dan analisa dapat menjadi wawasan tambahan untuk dapat di terapkan sebelum masuk ke pemodelan model prediksi. Dari hasil analisa pada tahap eksplorasi bahwa variabel 'Datetime' memiliki pengaruh cukup besar terhadap penggunaan listrik kantor. Sehingga penulis akan melakukan ekstraksi fitur 'Datetime' sehingga menghasilkan fitur input tambahan diantaranya: 'Minute', 'Hour', 'Month', 'Year', 'DayOfWeek', 'IsWeekend', dan 'IsWorkingHour'. Kemudian, dikarenakan tujuan dari model prediksi yang dibangun oleh penulis adalah untuk memprediksi konsumsi listrik pada kantor, maka variabel target 'realtime_daya' dalam watt dirubah menjadi 'energy_kwh' yang satuannya berupa kWh. Dimana perhitungan matematika untuk merubah satuan watt ke kWh dalam data per menit dapat dilihat pada persamaan 4.1, yaitu nilai daya setiap menit (P) dikalikan dengan 1/60 dan dibagi 1.000.

$$\text{Energi dalam menit} = \frac{(P \times \frac{1}{60})}{1000} \quad (4.1)$$

Setelah informasi terhadap variabel dataset sudah cukup untuk dipahami, maka selanjutnya dilakukan pemilihan fitur dan target yang akan digunakan sebagai inputan model prediksi yang akan dibangun. Dimana fitur input akan menggunakan variabel 'IsWeekend', 'IsWorkingHour', 'Minute', 'Hour', 'Day', 'DayOfWeek', 'Arus 1', 'Arus 2', 'Arus 3', 'Suhu Out', 'Suhu Ind', 'Hujan', 'Kondisi Cahaya', 'Intensitas Cahaya', dan 'kec_angin'. Sedangkan target prediksi akan menggunakan variabel 'energy_kwh'.

Variabel fitur dan target yang dipilih diatas akan melewati proses normalisasi terhadap data menggunakan metode normalisasi MinMaxScaler, agar sebaran datanya menjadi lebih terkontrol dan lebih mudah dipahami oleh arsitektur *deep learning* GRU dan BiGRU. Setelah data fitur dan target berhasil dinormalisasi, kemudian dilanjutkan dengan membuat skema *sliding window* sebagai teknik pelatihan data. Dimana setiap *loop* pelatihan menggunakan data fitur (X) selama 7 hari sebelumnya (10080 record data) digunakan untuk memprediksi data target (y) 1 hari kedepannya (1440 record data). Setelah itu, dataset yang sudah dibuat *loop sliding window* akan dipisahkan menjadi data pelatihan (X_train & y_train) dan data validasi (X_val & y_val). Proporsi pembagian dataset yaitu 90% untuk data pelatihan dan 10% untuk data validasi. Hingga akhirnya, output akhir dari tahap *feature engineering* berupa *loop sliding window* dan proporsi data pelatihan dan validasi yang akan digunakan pada proses pelatihan model prediksi konsumsi listrik perkantoran menggunakan arsitektur *deep learning* GRU dan BiGRU.

4.3 Pembangunan Model Prediksi dan Evaluasi Model

4.3.1 Pelatihan dan Validasi Model

Pelatihan model dilakukan dalam dua tahap, yaitu dengan menggunakan arsitektur *deep learning* GRU dan BiGRU. Awalnya, penulis melakukan *tuning hyperparameter* melalui beberapa eksperimen untuk menemukan setelan optimal bagi model. Setelah beberapa kali percobaan, didapatkan kombinasi *hyperparameter* terbaik untuk membangun model prediksi dengan dataset pelatihan yang digunakan. Tabel 4.3 merangkum konfigurasi *hyperparameter* yang digunakan untuk model GRU dan BiGRU. Perbedaan utama di antara keduanya adalah pada panjang *epoch*: GRU diatur hingga 30 *epoch*, sedangkan BiGRU hingga 50 *epoch*. Pada saat pelatihan model GRU, penulis menemukan bahwa melampaui 30 *epoch* menyebabkan akurasi validasi menurun dan *loss* pelatihan menjadi tidak stabil, yang mengindikasikan *overfitting*. Oleh karena itu, *epoch* untuk model GRU dibatasi pada 30 untuk menghindari *overfitting* tersebut.

Tabel 4.3 *Tuning Hyperparameter* Pada GRU & BiGRU

<i>Hyperparameter</i>	GRU	BiGRU
Jumlah <i>Layer</i>	2 layer GRU	2 Layer BiGRU
Jumlah Unit Pada <i>Layer</i>	128 masing-masing layer GRU	128 masing-masing layer BiGRU
Fungsi Aktivasi	RELU	RELU
<i>Optimizer</i>	Adam	Adam

<i>Learning Rate</i>	0,01	0,01
<i>Batch Size</i>	16	16
<i>Epoch</i>	30	50

Selain *tuning hyperparameter*, penulis juga menerapkan teknik penyesuaian panjang *loop sliding window* data historis. Tiga skema yang diuji adalah data historis 1 hari, 1 minggu, dan 2 minggu kebelakang. Tabel 4.4 menunjukkan bahwa model dengan *sliding window sequence* data 1 minggu kebelakang memberikan hasil validasi terbaik, ditandai dengan nilai MSE, RMSE dan MAE terendah dan nilai R2 tertinggi dibandingkan skema lainnya. Temuan ini menunjukkan bahwa menggunakan lebih banyak data historis tidak selalu meningkatkan akurasi prediksi dan harus mempertimbangkan waktu pelatihan yang lebih panjang. Hasil evaluasi juga menunjukkan bahwa semua metrik evaluasi yang digunakan, yaitu MSE, RMSE, MAE, dan R2, memberikan nilai lebih baik untuk BiGRU dibandingkan GRU. Namun, BiGRU memerlukan jumlah parameter yang lebih banyak dan waktu pelatihan yang lebih lama. Ini wajar karena BiGRU memproses data dalam dua arah, yaitu *forward* dan *backward*, sehingga memerlukan dua kali lebih banyak gerbang GRU daripada model GRU biasa. Dari hasil MAE skema historis 1 minggu kebelakang, kita dapat melihat bahwa rata-rata perbedaan antara prediksi dan data aktual adalah 0,0199 kWh untuk GRU dan 0,0146 kWh untuk BiGRU.

Tabel 4.4 Perbandingan Hasil Evaluasi Model Input Data Historis

<i>Evaluation Model</i>	Historis 1 Hari		Historis 1 Minggu		Historis 2 Minggu	
	GRU	BiGRU	GRU	BiGRU	GRU	BiGRU
MSE	0,0007	0,0017	0,0007	0,0003	0,0007	0,0005
RMSE	0,0292	0,0415	0,0279	0,0195	0,0269	0,0232
MAE	0,0221	0,0285	0,0199	0,0146	0,0221	0,0175
R ²	0,62	0,57	0,64	0,86	0,64	0,75
Jumlah Parameter	340128	777120	340128	777120	340128	777120
Lama Waktu Pelatihan (s)	237,90	1046,81	2966,01	3751,05	5939,15	6811,89

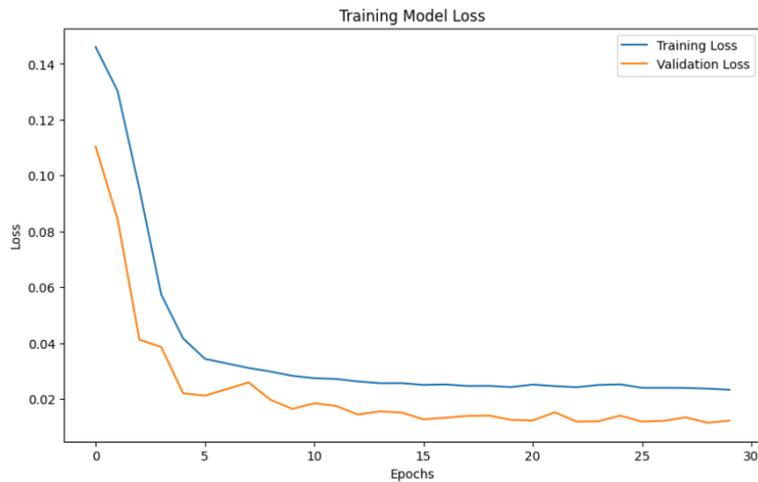
Selanjutnya, penulis juga melaksanakan eksperimen lanjutan untuk mengevaluasi kemampuan model yang telah dibangun dalam memprediksi konsumsi listrik. Pada eksperimen lanjutan ini, model terbaik yang dikembangkan menggunakan data historis

selama 1 minggu dipakai untuk memprediksi target konsumsi listrik tidak hanya untuk 1 hari ke depan, tetapi juga untuk 2 dan 3 hari ke depan. Pada Tabel 4.5, disajikan hasil eksperimen target prediksi yang mencakup prediksi untuk 1 hari, 2 hari, dan 3 hari ke depan. Evaluasi menunjukkan bahwa model memiliki performa yang lebih baik dalam memprediksi konsumsi listrik untuk 1 hari ke depan dibandingkan dengan 2 dan 3 hari ke depan, seperti yang dibuktikan oleh nilai MSE, RMSE, dan MAE yang lebih rendah serta nilai R² yang lebih tinggi. Hal ini mengindikasikan bahwa dataset dan model yang dibangun lebih cocok untuk memprediksi konsumsi listrik dalam jangka waktu 1 hari ke depan. Pada hasil eksperimen ini, penulis juga melihat bahwa prediksi untuk periode yang lebih panjang meningkatkan jumlah parameter model, yang menunjukkan bahwa kompleksitas model juga meningkat. Yang menarik adalah, meskipun jumlah parameter meningkat seiring target prediksi yang lebih panjang, namun lama waktu pelatihan model justru mengalami penurunan. Hal ini dapat berdampak akibat jumlah matriks *sliding window* yang dihasilkan dari dataset ternyata berkurang seiring bertambahnya hari target prediksi.

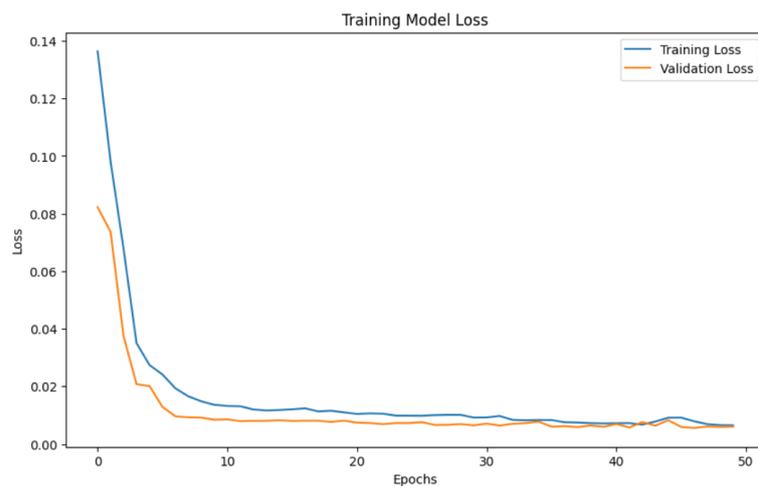
Tabel 4.5 Perbandingan Hasil Evaluasi Model Target Prediksi

<i>Evaluation Model</i>	Prediksi Target 1 Hari		Prediksi Target 2 Hari		Prediksi Target 3 Hari	
	GRU	BiGRU	GRU	BiGRU	GRU	BiGRU
MSE	0,0007	0,0003	0,0015	0,0012	0,0020	0,0014
RMSE	0,0279	0,0195	0,0392	0,0359	0,0452	0,0383
MAE	0,0199	0,0146	0,0290	0,0286	0,0362	0,0298
R ²	0,64	0,86	0,53	0,60	0,40	0,57
Jumlah Parameter	340128	777120	526272	1147968	712032	1518048
Lama Waktu Pelatihan (s)	2966,01	3751,05	1021,31	2289,62	993,03	2128,78
Jumlah Matriks <i>Sliding Windows</i>	62	62	31	31	20	20

Pada Gambar 4.14 menampilkan grafik *loss* pelatihan model GRU dan pada Gambar 4.15 menampilkan grafik *loss* pelatihan model BiGRU dengan *loop sliding window* 1 minggu ke belakang dan target 1 hari konsumsi listrik ke depan. Untuk histori *epoch* tahap pelatihan dapat dilihat pada Lampiran B.



Gambar 4.14 *Training Model Loss GRU*



Gambar 4.15 *Training Model Loss BiGRU*

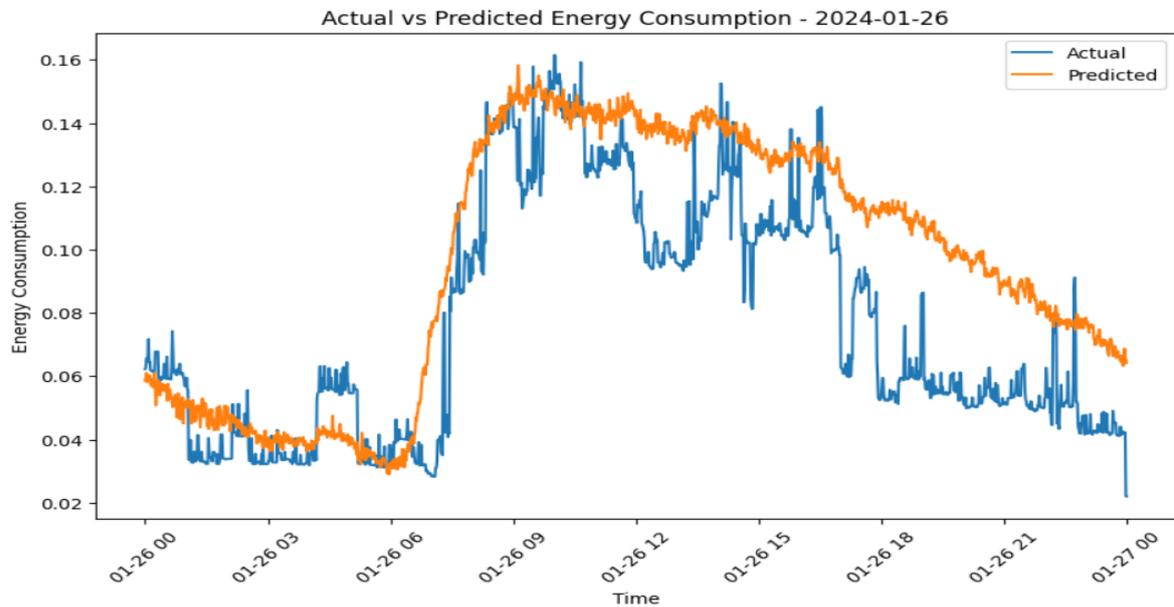
Setelah model dilatih dan dievaluasi, model dengan akurasi paling tinggi akan disimpan dalam bentuk *file* dengan nama ‘model_gru.m5’ dan ‘model_bigru.m5’. hal ini diperlukan saat selanjutnya ingin melakukan pengujian terhadap model dengan berbagai dataset, maka penulis tidak perlu melakukan pelatihan ulang yang memakan banyak waktu. Jadi hanya tinggal melakukan import file hasil pelatihan model ke sesi Google Colab yang baru kemudian dipanggil dalam proses pengujian menggunakan data uji yang baru.

4.3.2 Pengujian Model

Pada pengujian model, penulis menggunakan 1 dataset untuk membandingkan keberhasilan model prediksi GRU dan BiGRU. Dataset yang dipakai merupakan data hasil pengukuran penggunaan listrik serta faktor internal dan eksternal kantor pada periode tanggal 19 hingga 26 januari 2024. Dimana data 1 minggu pada 19 - 25 januari 2024 akan digunakan sebagai input model dan data konsumsi listrik pada 26 januari 2024 akan digunakan sebagai target prediksi.

1. Hasil Uji Model dengan GRU

Hasil prediksi model GRU menggunakan dataset pengujian kemudian dibandingkan dengan data aktual konsumsi listrik dalam bentuk grafik *line plot*. Gambar 4.16 menampilkan perbandingan data prediksi dan aktual pada tanggal 26 Januari 2024 menggunakan model GRU.



Gambar 4.16 Perbandingan Aktual & Prediksi Konsumsi Listrik 26/01/2024 - GRU

Pada Tabel 4.6 juga ditampilkan perbandingan data hasil prediksi model GRU dan data aktual konsumsi listrik per jam pada tanggal 26 Januari 2024. Dapat dilihat disana bahwa total prediksi konsumsi listrik hariannya 133,80 kWh dan konsumsi listrik harian aktualnya 110,12. Sehingga selisih harian antara prediksi dan aktualnya sebesar 23,68 kWh.

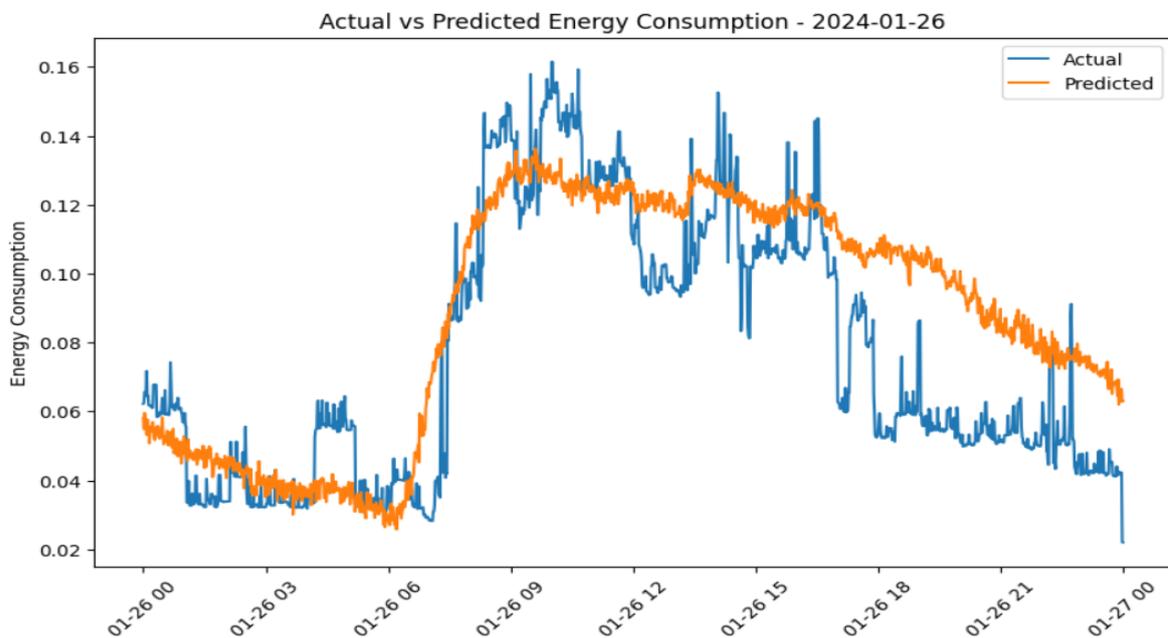
Tabel 4.6 Perbandingan Aktual & Prediksi Konsumsi Listrik Per Jam 26/01/2024 - GRU

Total Per Jam	Jumlah Aktual (kWh)	Jumlah Prediksi (kWh)
00:00	3.728821	3.968708
01:00	2.168277	3.627143
02:00	2.263783	2.993561
03:00	2.044033	2.733398
04:00	3.162000	2.816982
05:00	2.282558	2.018294
06:00	2.190723	2.200449
07:00	4.133812	4.247553
08:00	7.646734	7.713966
09:00	7.974902	8.563725

10:00	8.507153	8.582974
11:00	7.686384	8.496026
12:00	6.056016	9.534719
13:00	6.433897	8.932739
14:00	6.988327	8.306632
15:00	6.578542	7.684019
16:00	6.613079	7.449195
17:00	4.538207	6.668983
18:00	3.522014	6.429038
19:00	3.435718	5.165036
20:00	3.175536	3.753401
21:00	3.189020	4.137395
22:00	3.250575	4.125109
23:00	2.553721	3.660937
Jumlah	110.123832	133.809979

2. Hasil Uji Model dengan BiGRU

Hasil prediksi model BiGRU menggunakan dataset pengujian kemudian dibandingkan dengan data aktual konsumsi listrik dalam bentuk grafik *line plot*. Gambar 4.17 menampilkan perbandingan data prediksi dan aktual pada tanggal 26 Januari 2024 menggunakan model BiGRU.



Gambar 4.17 Perbandingan Aktual & Prediksi Konsumsi Listrik 26/01/2024 - BiGRU

Pada Tabel 4.7 juga ditampilkan perbandingan data hasil prediksi model BiGRU dan data aktual konsumsi listrik per jam pada tanggal 26 Januari 2024. Dapat dilihat disana bahwa total prediksi konsumsi listrik hariannya 121,88 kWh dan konsumsi listrik harian aktualnya 110,12. Sehingga selisih harian antara prediksi dan aktualnya sebesar 11,76 kWh.

Tabel 4.7 Perbandingan Aktual & Prediksi Konsumsi Listrik Per Jam 26/01/2024 - BiGRU

Total Per Jam	Jumlah Aktual (kWh)	Jumlah Prediksi (kWh)
00:00	3.728821	3.169949
01:00	2.168277	2.805325
02:00	2.263783	2.512352
03:00	2.044033	2.254873
04:00	3.162000	2.243603
05:00	2.282558	1.979378
06:00	2.190723	2.452326
07:00	4.133812	4.293243
08:00	7.646734	7.224429
09:00	7.974902	7.802963
10:00	8.507153	7.554271
11:00	7.686384	7.414445
12:00	6.056016	6.246501
13:00	6.433897	6.419096
14:00	6.988327	6.332092
15:00	6.578542	7.064052
16:00	6.613079	7.088050
17:00	4.538207	6.416568
18:00	3.522014	6.862642
19:00	3.435718	5.551931
20:00	3.175536	5.422718
21:00	3.189020	4.961106
22:00	3.250575	4.582928
23:00	2.553721	4.229899
Jumlah	110.123832	121.884743

4.3.3 Evaluasi Model

Evaluasi model *deep learning* pada data pengujian dilakukan menggunakan perbandingan hasil metrik evaluasi MSE, RMSE, MAE dan R^2 . Selain itu, evaluasi model

juga mencakup perbandingan jumlah parameter, waktu pelatihan, serta ukuran model untuk memberikan pandangan menyeluruh tentang performa dan efisiensi model prediksi. Tabel 4.8 menampilkan hasil evaluasi model dari pengujian yang dilakukan oleh model GRU dan BiGRU terhadap dataset pengujian. Hasil evaluasi menunjukkan bahwa model BiGRU memiliki performa yang lebih baik dibandingkan dengan model GRU pada tahap pengujian. Model BiGRU menghasilkan nilai MSE dan RMSE yang lebih rendah, yang berarti bahwa kesalahan prediksi yang dihasilkan oleh BiGRU lebih kecil dibandingkan dengan GRU. Selain itu, nilai R^2 yang lebih tinggi pada BiGRU (0,60) dibandingkan dengan GRU (0,44) mengindikasikan bahwa BiGRU lebih mampu menjelaskan variabilitas dalam data pengujian, sehingga memberikan gambaran yang lebih akurat tentang pola konsumsi listrik. Kemudian dalam hal kompleksitas, BiGRU memiliki hampir dua kali lipat jumlah parameter dibandingkan dengan GRU, yaitu 777,120 parameter untuk BiGRU berbanding 340,128 parameter untuk GRU. Ini mencerminkan kompleksitas arsitektur BiGRU yang lebih tinggi, yang memungkinkan model ini untuk menangkap lebih banyak informasi dari data. Konsekuensinya, waktu pelatihan untuk BiGRU juga lebih lama, yaitu sekitar 3,751.05 detik, dibandingkan dengan 2,966.01 detik untuk GRU. Ukuran model BiGRU setelah diekspor juga lebih besar (9.183 MB) dibandingkan dengan GRU (4.034 MB).

Tabel 4.8 Perbandingan Hasil Evaluasi Model Pada Tahap Pengujian

<i>Evaluation Model</i>	GRU	BiGRU
MSE	0,0008	0,0005
RMSE	0,0284	0,0234
MAE	0,0231	0,0188
R^2	0,44	0,60
Jumlah Parameter	340128	777120
Lama Waktu Pelatihan	2966,01 <i>second</i>	3751,05 <i>second</i>
Lama Waktu Pengujian	3 <i>second</i>	4 <i>second</i>
Ukuran Model Hasil <i>Export</i>	4,034 MB	9,183 MB

Namun, meskipun BiGRU memerlukan lebih banyak sumber daya komputasi dan waktu pelatihan yang lebih lama, peningkatan akurasi yang signifikan membuatnya menjadi pilihan yang lebih unggul untuk implementasi dalam sistem monitoring *smart office*. Arah *bidirectional* dari BiGRU memberikan keuntungan dalam mempertimbangkan informasi dari kedua arah dalam urutan data, yang sangat berguna dalam konteks konsumsi listrik yang dipengaruhi oleh pola masa lalu dan masa depan. Kemampuan ini memungkinkan BiGRU

untuk menangkap lebih baik redundansi informasi dalam urutan waktu, sehingga memberikan konteks tambahan yang memperbaiki akurasi prediksi.

Selain itu, perbedaan waktu pengujian antara kedua model cukup kecil (3 detik untuk GRU dan 4 detik untuk BiGRU), yang menunjukkan bahwa untuk aplikasi praktis dalam lingkungan operasional, perbedaan ini mungkin tidak terlalu signifikan. Dalam implementasinya, BiGRU dapat digunakan untuk memprediksi konsumsi listrik dengan lebih akurat, yang memungkinkan perusahaan untuk mengoptimalkan penggunaan energi secara lebih efisien. Misalnya, dengan prediksi yang lebih baik, perusahaan dapat menentukan waktu terbaik untuk mengurangi penggunaan energi di berbagai departemen atau menerapkan strategi efisiensi energi yang lebih spesifik, seperti pengelolaan penggunaan pendingin ruangan atau pencahayaan.

Keunggulan BiGRU dalam menangkap konteks temporal dari kedua arah dalam urutan data memberikan nilai tambah yang signifikan, khususnya dalam pengelolaan energi di lingkungan perkantoran yang memerlukan prediksi yang akurat untuk pengambilan keputusan yang lebih tepat. Kesimpulan dari evaluasi ini adalah bahwa meskipun BiGRU lebih kompleks dan memerlukan lebih banyak sumber daya, keunggulan dalam akurasi dan kemampuan prediksi menjadikannya pilihan yang lebih baik untuk sistem monitoring konsumsi listrik yang efisien dan efektif. Ke depan, penelitian lebih lanjut tentang tren okupansi dan integrasi faktor eksternal lainnya dapat semakin meningkatkan kemampuan prediksi dan efisiensi dari sistem monitoring yang dibangun.

4.4 Analisis Hasil dan Diskusi

Pada bagian ini, akan dibahas lebih lanjut mengenai manfaat dari hasil penelitian yang telah dilakukan serta implikasi dan batasan penelitian ini. Diskusi ini diharapkan dapat memberikan wawasan tambahan bagi perusahaan untuk memanfaatkan hasil prediksi konsumsi listrik secara lebih efektif dan efisien.

1. Manfaat Ekonomi dan Bisnis dari Hasil Penelitian

Penelitian ini telah berhasil mengembangkan sistem monitoring yang memanfaatkan teknologi IoT untuk memantau dan memprediksi konsumsi listrik di lingkungan perkantoran. Salah satu manfaat langsung yang diperoleh adalah peningkatan kemampuan kantor dalam monitoring dan prediksi kebutuhan energi secara akurat. Sistem ini mampu menghasilkan dataset historis yang detail dan kaya informasi, yang menjadi dasar untuk model prediksi yang dikembangkan.

Model prediksi berbasis BiGRU yang dihasilkan menunjukkan akurasi yang tinggi dalam memperkirakan konsumsi listrik masa depan. Dengan prediksi yang akurat, perusahaan dapat merencanakan penggunaan listrik dengan lebih efektif, sehingga dapat mengurangi biaya operasional secara signifikan. Misalnya, perusahaan dapat mengidentifikasi periode puncak konsumsi listrik dan merancang strategi untuk mengurangi penggunaan listrik selama periode tersebut. Salah satu strategi yang dapat diterapkan adalah mengalihkan aktivitas operasional non-krusial ke waktu di luar periode puncak, yang tidak hanya mengurangi biaya listrik tetapi juga meringankan beban pada sistem kelistrikan perusahaan.

Manfaat lain yang lebih strategis adalah perencanaan keuangan yang lebih baik. Dengan mengetahui estimasi biaya listrik di masa mendatang, perusahaan dapat mengalokasikan anggaran secara lebih efisien dan akurat. Hal ini sangat penting dalam dunia bisnis di mana pengendalian biaya merupakan kunci untuk menjaga profitabilitas. Selain itu, pemahaman yang lebih baik tentang pola konsumsi listrik memungkinkan perusahaan untuk mengevaluasi dan menyesuaikan strategi operasional mereka agar lebih efisien dalam penggunaan energi.

2. Tindak Lanjut dan Implikasi untuk Pengurangan Konsumsi Listrik

Hasil prediksi konsumsi listrik juga dapat digunakan untuk mengidentifikasi area-area yang berpotensi untuk penghematan energi. Sebagai contoh, jika ditemukan bahwa pendingin ruangan (AC) adalah salah satu penyumbang terbesar konsumsi listrik, maka perusahaan dapat mengambil langkah-langkah untuk mengoptimalkan penggunaan AC. Beberapa langkah yang dapat diambil antara lain:

- **Peningkatan Efisiensi AC:** Melakukan perawatan rutin dan berkala pada sistem pendingin ruangan untuk memastikan kinerjanya tetap optimal dan efisien. Hal ini dapat mencakup pembersihan filter, pengecekan refrigeran, dan perbaikan pada sistem yang mengalami kerusakan.
- **Penggunaan Teknologi Hemat Energi:** Mengganti unit AC lama dengan model yang lebih baru dan lebih efisien secara energi, seperti AC dengan teknologi inverter atau AC yang memiliki rating efisiensi energi yang tinggi. Investasi dalam teknologi hemat energi dapat memberikan penghematan biaya yang signifikan dalam jangka panjang.
- **Manajemen Penggunaan AC:** Mengatur jadwal operasional AC agar sesuai dengan jam kerja kantor, misalnya mematikan AC saat ruangan tidak digunakan atau di luar jam kerja. Penerapan sistem kontrol otomatis juga dapat membantu mengelola penggunaan AC berdasarkan kehadiran karyawan atau suhu ruangan.

Selain itu, perusahaan juga dapat melihat ke area lain seperti pencahayaan dan peralatan elektronik untuk mencari peluang penghematan energi. Mengadopsi teknologi pencahayaan LED atau mengimplementasikan sistem manajemen energi yang canggih bisa menjadi beberapa opsi yang dapat dipertimbangkan.

3. Batasan Penelitian dan Arah Penelitian Lanjutan

Meskipun penelitian ini telah memberikan hasil yang bermanfaat, ada beberapa batasan yang perlu diakui. Pertama, model prediksi yang dikembangkan masih bergantung pada data historis dan tidak memperhitungkan perubahan kebijakan atau inovasi teknologi yang dapat mempengaruhi pola konsumsi listrik di masa depan. Sebagai contoh, adopsi teknologi baru atau kebijakan penghematan energi yang lebih ketat dapat mengubah pola konsumsi yang saat ini tidak tercermin dalam data historis. Kedua, penelitian ini tidak mempertimbangkan faktor eksternal seperti perubahan harga energi atau gangguan pada pasokan listrik yang dapat mempengaruhi konsumsi listrik perusahaan. Fluktuasi harga energi atau kejadian yang mengganggu pasokan listrik dapat memiliki dampak signifikan pada biaya dan penggunaan energi, yang seharusnya juga menjadi pertimbangan dalam model prediksi. Sedangkan, untuk penelitian lanjutan, beberapa arah yang dapat diambil meliputi:

- **Pengintegrasian Faktor Eksternal:** Mengembangkan model yang dapat mempertimbangkan variabel eksternal seperti harga energi atau perubahan kebijakan lingkungan.
- **Penggunaan Data *Real-time*:** Menggunakan data *real-time* untuk memperbarui prediksi konsumsi listrik secara terus-menerus dan memberikan wawasan yang lebih tepat waktu.
- **Analisis Dampak Kebijakan Penghematan Energi:** Meneliti bagaimana implementasi berbagai kebijakan penghematan energi dapat mempengaruhi konsumsi listrik dan biaya operasional perusahaan.

Dengan mempertimbangkan batasan dan potensi pengembangan ini, perusahaan dapat terus meningkatkan efisiensi penggunaan energi dan menjadikan hasil penelitian ini sebagai landasan untuk inovasi dan pengambilan keputusan strategis di masa depan.

BAB 5

Kesimpulan dan Saran

5.1 Kesimpulan

Penelitian ini berhasil mengintegrasikan teknologi *Internet of Things* (IoT) dalam sebuah sistem monitoring *smart office* untuk memantau dan menganalisis konsumsi listrik di lingkungan perkantoran. Melalui eksperimen dan analisis yang mendalam, sistem ini menunjukkan kemampuan untuk menghasilkan dataset historis yang kaya informasi, yang kemudian digunakan sebagai dasar pembangunan model prediksi konsumsi listrik. Dataset yang diperoleh melalui proses pengumpulan dan pemrosesan data yang sistematis menjadi lebih terstruktur dan siap untuk dianalisis lebih lanjut.

Analisis eksplorasi data yang dilakukan memungkinkan identifikasi pola-pola tersembunyi, seperti korelasi antar variabel dan tren penggunaan listrik harian. Evaluasi model prediksi yang menggunakan arsitektur GRU dan BiGRU mengungkapkan bahwa model BiGRU memiliki performa yang lebih superior dalam memprediksi konsumsi listrik dibandingkan dengan GRU. Model BiGRU menghasilkan nilai MSE dan RMSE yang lebih rendah, serta nilai R^2 yang lebih tinggi, yang menandakan kesalahan prediksi yang lebih kecil dan kemampuan yang lebih baik dalam menjelaskan variabilitas data pengujian.

Meskipun BiGRU memiliki jumlah parameter yang lebih besar dan memerlukan waktu pelatihan yang lebih lama dibandingkan dengan GRU, peningkatan akurasi yang signifikan menjadikannya pilihan yang lebih baik untuk implementasi dalam sistem monitoring *smart office*. Kompleksitas tambahan dari BiGRU, yang mampu mempertimbangkan informasi dari kedua arah dalam urutan data, memberikan keuntungan dalam menangkap konteks temporal secara lebih menyeluruh, sehingga mampu memberikan prediksi yang lebih akurat dan relevan.

Secara keseluruhan, sistem monitoring berbasis IoT dan penggunaan model prediksi BiGRU memberikan manfaat signifikan dalam hal efisiensi energi dan penghematan biaya operasional bagi perusahaan. Penerapan sistem ini memungkinkan perusahaan untuk mengambil langkah-langkah yang lebih tepat dalam mengelola konsumsi listrik, baik melalui optimalisasi penggunaan energi maupun melalui identifikasi dan penanganan area-area yang membutuhkan efisiensi tambahan.

5.2 Saran

Berdasarkan hasil evaluasi yang telah dilakukan, beberapa saran dapat diberikan untuk pengembangan dan implementasi lebih lanjut dari sistem monitoring *smart office* ini.

Pertama, disarankan untuk menerapkan model BiGRU dalam sistem monitoring yang telah dibangun, mengingat performa prediksi yang lebih akurat dibandingkan dengan GRU. Peningkatan akurasi ini akan membantu perusahaan dalam mengambil keputusan yang lebih tepat terkait pengelolaan energi, yang pada akhirnya dapat mengarah pada penghematan biaya operasional yang signifikan.

Selain itu, penelitian lanjutan diperlukan untuk memperluas cakupan penggunaan teknologi IoT dalam lingkungan perkantoran. Misalnya, penggunaan IoT dapat dioptimalkan untuk manajemen inventaris, pengaturan otomatis suhu dan pencahayaan, serta implementasi strategi optimalisasi lainnya yang dapat meningkatkan efisiensi operasional. Eksperimen lebih lanjut dengan pengumpulan data yang lebih ekstensif, seperti pengamatan selama setahun penuh, juga sangat disarankan. Hal ini akan membantu dalam mengidentifikasi tren jangka panjang dan pola musiman yang mungkin tidak terlihat selama periode observasi yang lebih pendek, sehingga dapat meningkatkan akurasi dan *robustness* model prediksi.

Selain itu, analisis tren okupansi di lingkungan perkantoran juga perlu dieksplorasi lebih lanjut. Memahami bagaimana tren okupansi mempengaruhi konsumsi listrik dapat memberikan wawasan tambahan yang sangat berharga. Dengan mengetahui pola okupansi yang lebih rinci, perusahaan dapat merancang strategi efisiensi energi yang lebih efektif, misalnya dengan mengurangi penggunaan energi di area atau waktu tertentu yang memiliki tingkat okupansi rendah.

Langkah-langkah ini tidak hanya akan memperbaiki performa sistem monitoring yang ada, tetapi juga membuka peluang untuk penelitian lebih lanjut di bidang manajemen energi dan teknologi IoT dalam lingkungan perkantoran. Penerapan saran-saran ini diharapkan dapat membawa manfaat jangka panjang yang signifikan dalam upaya mengelola konsumsi energi secara lebih efisien dan ekonomis, serta mendukung peran perusahaan dalam keberlanjutan lingkungan.

Daftar Pustaka

- Abidi, M. H., Mohammed, M. K., & Alkhalefah, H. (2022). Predictive Maintenance Planning for Industry 4.0 Using Machine Learning for Sustainable Manufacturing. *Sustainability (Switzerland)*, *14*(6). <https://doi.org/10.3390/su14063387>
- Abumohsen, M., Owda, A. Y., & Owda, M. (2023). Electrical Load Forecasting Using LSTM, GRU, and RNN Algorithms. *Energies*, *16*(5), 1–31. <https://doi.org/10.3390/en16052283>
- Ahuja, S., Shelke, N. A., & Singh, P. K. (2022). A deep learning framework using CNN and stacked Bi-GRU for COVID-19 predictions in India. *Signal, Image and Video Processing*, *16*, 579–586. <https://doi.org/10.1007/s11760-021-01988-1>
- Aisyah, S., Simaremare, A. A., Adytia, D., Aditya, I. A., & Alamsyah, A. (2022). Exploratory Weather Data Analysis for Electricity Load Forecasting Using SVM and GRNN, Case Study in Bali, Indonesia. *Energies*, *15*(10), 1–17. <https://doi.org/10.3390/en15103566>
- Al Hamoud, A., Hoenig, A., & Roy, K. (2022). Sentence subjectivity analysis of a political and ideological debate dataset using LSTM and BiLSTM with attention and GRU models. *Journal of King Saud University - Computer and Information Sciences*, *34*(10), 7974–7987. <https://doi.org/10.1016/j.jksuci.2022.07.014>
- Ali, S., Zhang, J., Azeem, A., & Mahmood, A. (2020). Impact Of Electricity Consumption On Economic Growth: An Application Of Vector Error Correction Model and Artificial Neural Networks. *The Journal of Developing Areas*, *54*(4). <https://doi.org/10.1353/jda.2020.0039>
- Alomoush, W., Khan, T. A., Nadeem, M., Janjua, J. I., Saeed, A., & Athar, A. (2022). Residential Power Load Prediction in Smart Cities using Machine Learning Approaches. *2022 International Conference on Business Analytics for Technology and Security, ICBATS 2022, February*. <https://doi.org/10.1109/ICBATS54253.2022.9759024>
- Asif Karim, Rootul Patel, B. I. S. (2021). Weather based Electricity Consumption Prediction using Big Data Analytics Model. *International Journal of Engineering Research and Technology (IJERT)*, *10*(4), 158–163.
- Barisic, A., Amaral, V., & Challenger, M. (2020). Enhancing occupants comfort and well-being through a smart office setup. *2020 43rd International Convention on Information,*

- Communication and Electronic Technology, MIPRO 2020 - Proceedings, September*, 1825–1830. <https://doi.org/10.23919/MIPRO48935.2020.9245212>
- Berawi, M. A., Kim, A. A., Naomi, F., Basten, V., Miraj, P., Medal, L. A., & Sari, M. (2023). Designing a smart integrated workspace to improve building energy efficiency: an Indonesian case study. *International Journal of Construction Management*, 23(3), 410–422. <https://doi.org/10.1080/15623599.2021.1882747>
- Bousnguar, H., Nadji, L., & Battou, A. (2023). Gated Recurrent units (GRU) for Time Series Forecasting in Higher Education. *International Journal of Engineering Research & Technology*, 12(03), 152–154.
- Brahim, G. Ben. (2021). Weather Conditions Impact on Electricity Consumption in Smart Homes: Machine Learning Based Prediction Model. *2021 8th International Conference on Electrical and Electronics Engineering, ICEEE 2021*, 1, 93–98. <https://doi.org/10.1109/ICEEE52452.2021.9415917>
- Bunn, D., & Farmer, E. D. (1985). *Comparative models for electrical load forecasting*. <https://www.osti.gov/biblio/6256333>
- Cahuantzi, R., Chen, X., & Güttel, S. (2023). *A Comparison of LSTM and GRU Networks for Learning Symbolic Sequences BT - Intelligent Computing* (K. Arai (ed.); pp. 771–785). Springer Nature Switzerland. https://doi.org/https://doi.org/10.1007/978-3-031-37963-5_53
- Chen, J., Chen, S., Fu, R., Li, D., Jiang, H., Wang, C., Peng, Y., Jia, K., & Hicks, B. J. (2022). Remote Sensing Big Data for Water Environment Monitoring: Current Status, Challenges, and Future Prospects. *Earth's Future*, 10(2), 1–33. <https://doi.org/10.1029/2021EF002289>
- Chen, S., Ren, Y., Friedrich, D., Yu, Z., & Yu, J. (2021). Prediction of office building electricity demand using artificial neural network by splitting the time horizon for different occupancy rates. *Energy and AI*, 5(May), 100093. <https://doi.org/10.1016/j.egyai.2021.100093>
- Chitalia, G., Pipattanasomporn, M., Garg, V., & Rahman, S. (2020). Robust short-term electrical load forecasting framework for commercial buildings using deep recurrent neural networks. *Applied Energy*, 278(June), 115410. <https://doi.org/10.1016/j.apenergy.2020.115410>
- Chou, J. S., Hsu, S. C., Ngo, N. T., Lin, C. W., & Tsui, C. C. (2019). Hybrid Machine Learning System to Forecast Electricity Consumption of Smart Grid-Based Air Conditioners. *IEEE Systems Journal*, 13(3), 3120–3128.

<https://doi.org/10.1109/JSYST.2018.2890524>

- Danial, C. E., Mahmoud, A. H. A., & Tawfik, M. Y. (2023). Methodology for retrofitting energy in existing office buildings using building information modelling programs. *Ain Shams Engineering Journal*, *14*(6), 102175. <https://doi.org/10.1016/j.asej.2023.102175>
- Dey, P., Dev, S., & Phelan, B. S. (2023). BiLSTM–BiGRU: A Fusion Deep Neural Network For Predicting Air Pollutant Concentration. *IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium*, 5166–5169. <https://doi.org/10.1109/IGARSS52108.2023.10282742>
- Direktorat Jendral Energi Baru Terbarukan Dan Konservasi Energi (EBTKE). (2019). *Gedung Perkantoran*. https://simebtke.esdm.go.id/sinergi/sektor_pengguna_energi/detail/18/gedung-perkantoran
- Duboue, P. (2020). *The Art of Feature Engineering: Essentials for Machine Learning*. <https://doi.org/10.1017/9781108671682>
- Fan, C., Chen, M., Wang, X., Wang, J., & Huang, B. (2021). A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data. *Frontiers in Energy Research*, *9*(March), 1–17. <https://doi.org/10.3389/fenrg.2021.652801>
- Fan, C., Sun, Y., Zhao, Y., Song, M., & Wang, J. (2019). Deep learning-based feature engineering methods.pdf. *Applied Energy*, *240*(1), 35–45. <https://doi.org/10.1016/j.apenergy.2019.02.052>
- Feng, Y., Duan, Q., Chen, X., Yakkali, S. S., & Wang, J. (2021). Space cooling energy usage prediction based on utility data for residential buildings using machine learning methods. *Applied Energy*, *291*(December 2020), 116814. <https://doi.org/10.1016/j.apenergy.2021.116814>
- Floris, A., Porcu, S., Girau, R., & Atzori, L. (2021). An iot-based smart building solution for indoor environment management and occupants prediction. *Energies*, *14*(10), 1–17. <https://doi.org/10.3390/en14102959>
- González-Sopeña, J. M., Pakrashi, V., & Ghosh, B. (2021). An overview of performance evaluation metrics for short-term statistical wind power forecasting. *Renewable and Sustainable Energy Reviews*, *138*(October 2020), 110515. <https://doi.org/10.1016/j.rser.2020.110515>
- Hwang, J., Suh, D., & Otto, M. O. (2020). Forecasting electricity consumption in commercial buildings using a machine learning approach. *Energies*, *13*(22).

<https://doi.org/10.3390/en13225885>

- Ilbeigi, M., Ghomeishi, M., & Dehghanbanadaki, A. (2020). Prediction and optimization of energy consumption in an office building using artificial neural network and a genetic algorithm. *Sustainable Cities and Society*, *61*, 102325. <https://doi.org/10.1016/j.SCS.2020.102325>
- Janiesch, C., Zschech, P., & Heinrich, K. (2023). Machine Learning and Deep Learning. *Electronic Markets*, *103*, 347–384. https://doi.org/10.1007/978-3-031-26845-8_8
- Jiménez-Navarro, M. J., Martínez-Ballesteros, M., Martínez-Álvarez, F., & Asencio-Cortés, G. (2023). PHILNet: A novel efficient approach for time series forecasting using deep learning. *Information Sciences*, *632*(June 2022), 815–832. <https://doi.org/10.1016/j.ins.2023.03.021>
- Jogunola, O., Adebisi, B., Van Hoang, K., Tsado, Y., Popoola, S. I., Hammoudeh, M., & Nawaz, R. (2022). CBLSTM-AE: A Hybrid Deep Learning Framework for Predicting Energy Consumption. *Energies*, *15*(3), 1–16. <https://doi.org/10.3390/en15030810>
- Joshi, A. P., & Patel, B. V. (2021). Data Preprocessing: The Techniques for Preparing Clean and Quality Data for Data Analytics Process. *Oriental Journal of Computer Science and Technology*, *13*(0203), 78–81. <https://doi.org/10.13005/ojst13.0203.03>
- Li, L., Ota, K., & Dong, M. (2017). When Weather Matters: IoT-Based Electrical Load Forecasting for Smart Grid. *IEEE Communications Magazine*, *55*(10), 46–51. <https://doi.org/10.1109/MCOM.2017.1700168>
- Li, Y., Wang, K., Zhai, Y., & Zhang, Q. (2021). Performance Analysis of CPU, GPU and TPU for Deep Learning Applications. *INTERNATIONAL JOURNAL OF DESIGN, ANALYSIS AND TOOLS FOR INTERGRATED CIRCUITS AND SYSTEMS*, *10*(1), 12–18.
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, *379*(2194). <https://doi.org/10.1098/rsta.2020.0209>
- Lin, S. H., Zhang, H., Li, J. H., Ye, C. Z., & Hsieh, J. C. (2022). Evaluating smart office buildings from a sustainability perspective: A model of hybrid multi-attribute decision-making. *Technology in Society*, *68*(August 2021), 101824. <https://doi.org/10.1016/j.techsoc.2021.101824>
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, *3*(1), 91–99. <https://doi.org/10.1016/j.gltp.2022.04.020>

- Mahjoub, S., Chrifi-Alaoui, L., Marhic, B., & Delahoche, L. (2022). Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks. *Sensors*, 22(11), 1–20. <https://doi.org/10.3390/s22114062>
- Mantesi, E., Chmutina, K., & Goodier, C. (2022). The office of the future: Operational energy consumption in the post-pandemic era. *Energy Research and Social Science*, 87(June 2021), 102472. <https://doi.org/10.1016/j.erss.2021.102472>
- Martínez-Peláez, R., Ochoa-Brust, A., Rivera, S., Félix, V. G., Ostos, R., Brito, H., Félix, R. A., & Mena, L. J. (2023). Role of Digital Transformation for Achieving Sustainability: Mediated Role of Stakeholders, Key Capabilities, and Technology. *Sustainability (Switzerland)*, 15(14). <https://doi.org/10.3390/su151411221>
- Mateus, B. C., Mendes, M., Farinha, J. T., Assis, R., & Cardoso, A. M. (2021). Comparing LSTM and GRU models to predict the condition of a pulp paper press. *Energies*, 14(21), 1–21. <https://doi.org/10.3390/en14216958>
- Mukhiya, S. K., & Ahmed, U. (2020). *Hands-On Exploratory Data Analysis with Python: Perform EDA techniques to understand, summarize, and investigate your data*. Packt Publishing Ltd.
- Nabavi, S. A., Motlagh, N. H., Zaidan, M. A., Aslani, A., & Zakeri, B. (2021). Deep Learning in Energy Modeling: Application in Smart Buildings with Distributed Energy Generation. *IEEE Access*, 9, 125439–125461. <https://doi.org/10.1109/ACCESS.2021.3110960>
- Nielsen, A. (2019). *Practical Time Series Analysis: Prediction with Statistics and Machine Learning* (Vol. 1). O'Reilly Media, Inc. [https://books.google.co.id/books?hl=en&lr=&id=odCwDwAAQBAJ&oi=fnd&pg=PR2&dq=data+exploratory+in+deep+learning+prediction&ots=OVihq8g7BO&sig=MdH3BFM1DTUZCBWU8e81Moi9RIU&redir_esc=y#v=onepage&q=data exploratory in deep learning prediction&f=false](https://books.google.co.id/books?hl=en&lr=&id=odCwDwAAQBAJ&oi=fnd&pg=PR2&dq=data+exploratory+in+deep+learning+prediction&ots=OVihq8g7BO&sig=MdH3BFM1DTUZCBWU8e81Moi9RIU&redir_esc=y#v=onepage&q=data%20exploratory%20in%20deep%20learning%20prediction&f=false)
- Niu, D., Yu, M., Sun, L., Gao, T., & Wang, K. (2022). Short-term multi-energy load forecasting for integrated energy systems based on CNN-BiGRU optimized by attention mechanism. *Applied Energy*, 313(February), 118801. <https://doi.org/10.1016/j.apenergy.2022.118801>
- Paul, J., & Barari, M. (2022). Meta-analysis and traditional systematic literature reviews—What, why, when, where, and how? In *Psychology and Marketing* (Vol. 39, Issue 6, pp. 1099–1115). John Wiley and Sons Inc. <https://doi.org/10.1002/mar.21657>
- Peng, L., Wang, L., Xia, D., & Gao, Q. (2022). Effective energy consumption forecasting

- using empirical wavelet transform and long short-term memory. *Energy*, 238, 121756.
<https://doi.org/10.1016/j.energy.2021.121756>
- Pusat Database BMKG. (2024). *Data Online Pusat Database-BMKG*.
<https://dataonline.bmkg.go.id>
- Putpuek, N., Putpuek, A., & Sungthong, A. (2023). A Comparative Study of LSTM, GRU, BiLSTM and BiGRU to Predict Dissolved Oxygen. *2023 20th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, 67–72.
<https://doi.org/10.1109/JCSSE58229.2023.10202128>
- Putra, I. D. G. A., Nimiya, H., Sopaheluwakan, A., Kubota, T., Lee, H. S., Pradana, R. P., Alfata, M. N. F., Perdana, R. B., Permana, D. S., & Riama, N. F. (2022). Development of climate zones for passive cooling techniques in the hot and humid climate of Indonesia. *Building and Environment*, 226(2), 109698.
<https://doi.org/10.1016/j.buildenv.2022.109698>
- Ramos, D., Faria, P., Morais, A., & Vale, Z. (2022). ScienceDirect Using decision tree to select forecasting algorithms in distinct electricity consumption context of an office building. *Energy Reports*, 8, 417–422. <https://doi.org/10.1016/j.egyr.2022.01.046>
- Rick, R., & Berton, L. (2022). Energy forecasting model based on CNN-LSTM-AE for many time series with unequal lengths. *Engineering Applications of Artificial Intelligence*, 113(March), 104998. <https://doi.org/10.1016/j.engappai.2022.104998>
- Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach. *Fractal and Fractional*, 7(February 2023), 1–18. <https://doi.org/10.3390/fractalfract7020203>
- Setiawan, B. I. (2020). A simple method to determine patterns of wet and dry seasons. *IOP Conference Series: Earth and Environmental Science*, 542(1).
<https://doi.org/10.1088/1755-1315/542/1/012055>
- Shaikh, A. K., Nazir, A., Khalique, N., Shah, A. S., & Adhikari, N. (2023). A new approach to seasonal energy consumption forecasting using temporal convolutional networks. *Results in Engineering*, 19(July), 101296.
<https://doi.org/10.1016/j.rineng.2023.101296>
- Shapi, M. K. M., Ramli, N. A., & Awal, L. J. (2021). Energy consumption prediction by using machine learning for smart building: Case study in Malaysia. *Developments in the Built Environment*, 5(December 2020), 100037.
<https://doi.org/10.1016/j.dibe.2020.100037>
- Sun, M., Han, C., Nie, Q., Xu, J., Zhang, F., & Zhao, Q. (2022). Understanding building

- energy efficiency with administrative and emerging urban big data by deep learning in Glasgow. *Energy and Buildings*, 273, 112331. <https://doi.org/10.1016/j.enbuild.2022.112331>
- Suryadi, Y., Sugianto, D. N., & Hadiyanto. (2018). Climate Change in Indonesia (Case Study: Medan, Palembang, Semarang). *E3S Web of Conferences*, 31, 3–8. <https://doi.org/10.1051/e3sconf/20183109017>
- Tian, Y., Yu, J., & Zhao, A. (2020). Predictive model of energy consumption for office building by using improved GWO-BP. *Energy Reports*, 6, 620–627. <https://doi.org/10.1016/j.egy.2020.03.003>
- Tosepu, R., Effendy, D. S., Ahmad, L. O. A. I., Lestari, H., Bahar, H., Asfian, P., & Sakka, A. (2020). Vulnerability of Weather on Covid-19 Pandemic in West Java, Indonesia. *Public Health of Indonesia*, 6(4), 123–128. <https://doi.org/10.36685/phi.v6i4.357>
- Tuzcuoğlu, D., Yang, D., de Vries, B., Sungur, A., & Appel-Meulenbroek, R. (2021). The phases of user experience during relocation to a smart office building: A qualitative case study. *Journal of Environmental Psychology*, 74(July 2020). <https://doi.org/10.1016/j.jenvp.2021.101578>
- Ullah, F. U. M., Ullah, A., Khan, N., Lee, M. Y., Rho, S., & Baik, S. W. (2022). Deep Learning-Assisted Short-Term Power Load Forecasting Using Deep Convolutional LSTM and Stacked GRU. *Complexity*, 2022(August 2022), 1–15. <https://doi.org/10.1155/2022/2993184>
- Vijendar Reddy, G., Aitha, L. J., Poojitha, C., Naga Shreya, A., Krithika Reddy, D., & Sai Meghana, G. (2023). Electricity Consumption Prediction Using Machine Learning. *E3S Web of Conferences*, 391, 1–9. <https://doi.org/10.1051/e3sconf/202339101048>
- Wang, C., Song, J., Shi, D., Reyna, J. L., Horsey, H., Feron, S., Zhou, Y., Ouyang, Z., Li, Y., & Jackson, R. B. (2023). Impacts of climate change, population growth, and power sector decarbonization on urban building energy use. *Nature Communications*, 14(1), 1–16. <https://doi.org/10.1038/s41467-023-41458-5>
- Wu, M., & Wu, F. (2024). Predicting Residential Electricity Consumption Using CNN-BiLSTM-SA Neural Networks. *IEEE Access*, PP, 1–7. <https://doi.org/10.1109/ACCESS.2024.3400972>
- Yang, S., Wan, M. P., Chen, W., Ng, B. F., & Dubey, S. (2020). Model predictive control with adaptive machine-learning-based model for building energy efficiency and comfort optimization. *Applied Energy*, 271, 115147. <https://doi.org/10.1016/J.APENERGY.2020.115147>

- Yang, S., Yu, X., & Zhou, Y. (2020). LSTM and GRU Neural Network Performance Comparison Study: Taking Yelp Review Dataset as an Example. *2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)*, 98–101. <https://doi.org/10.1109/IWECAI50956.2020.00027>
- Yuniarti, E., Nurmaini, S., & Suprpto, B. Y. (2022). Indonesian load prediction estimation using long short term memory. *IAES International Journal of Artificial Intelligence*, *11*(3), 1026–1032. <https://doi.org/10.11591/ijai.v11.i3.pp1026-1032>
- Zaheer, S., Anjum, N., Hussain, S., Algarni, A. D., Iqbal, J., Bourouis, S., & Ullah, S. S. (2023). A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model. *Mathematics*, *11*(3), 1–24. <https://doi.org/10.3390/math11030590>
- Zameer, A., Jaffar, F., Shahid, F., Muneeb, M., Khan, R., & Nasir, R. (2023). Short-term solar energy forecasting: Integrated computational intelligence of LSTMs and GRU. *PloS One*, *18*(10), e0285410. <https://doi.org/10.1371/journal.pone.0285410>
- Zekić-Sušac, M., Mitrović, S., & Has, A. (2021). Machine learning based system for managing energy efficiency of public sector as an approach towards smart cities. *International Journal of Information Management*, *58*, 102074. <https://doi.org/10.1016/j.ijinfomgt.2020.102074>

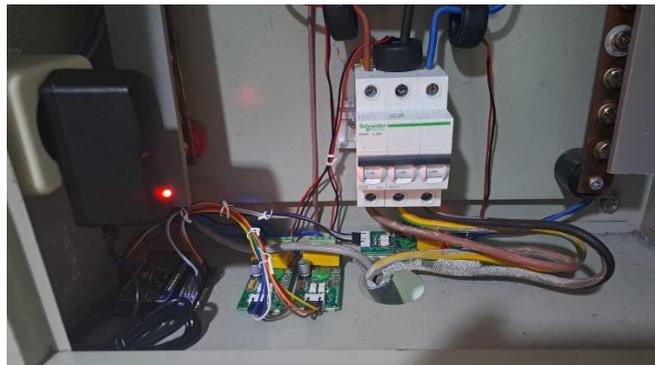
LAMPIRAN A

Dokumentasi Rangkaian Sensor:

1. Rangkaian sensor indor penempatan pada ruangan tempat kerja



2. Rangkaian sensor indor penempatan pada ACPDB kelistrikan kantor



3. Rangkaian sensor outdoor penempatan pada atap bangunan kantor



LAMPIRAN B

Histori Epoch Pelatihan GRU:

```
Epoch 1/30
4/4 [=====] - 103s 25s/step - loss: 0.1460 -
val_loss: 0.1103
Epoch 2/30
4/4 [=====] - 96s 24s/step - loss: 0.1303 -
val_loss: 0.0845
Epoch 3/30
4/4 [=====] - 100s 25s/step - loss: 0.0952 -
val_loss: 0.0413
Epoch 4/30
4/4 [=====] - 107s 27s/step - loss: 0.0574 -
val_loss: 0.0386
Epoch 5/30
4/4 [=====] - 99s 24s/step - loss: 0.0417 -
val_loss: 0.0220
Epoch 6/30
4/4 [=====] - 101s 25s/step - loss: 0.0344 -
val_loss: 0.0212
Epoch 7/30
4/4 [=====] - 100s 25s/step - loss: 0.0327 -
val_loss: 0.0235
Epoch 8/30
4/4 [=====] - 99s 25s/step - loss: 0.0311 -
val_loss: 0.0259
Epoch 9/30
4/4 [=====] - 103s 25s/step - loss: 0.0298 -
val_loss: 0.0197
Epoch 10/30
4/4 [=====] - 96s 24s/step - loss: 0.0283 -
val_loss: 0.0165
Epoch 11/30
4/4 [=====] - 96s 24s/step - loss: 0.0274 -
val_loss: 0.0184
Epoch 12/30
4/4 [=====] - 94s 23s/step - loss: 0.0272 -
val_loss: 0.0175
Epoch 13/30
4/4 [=====] - 101s 25s/step - loss: 0.0263 -
val_loss: 0.0144
Epoch 14/30
4/4 [=====] - 103s 26s/step - loss: 0.0256 -
val_loss: 0.0156
Epoch 15/30
4/4 [=====] - 100s 25s/step - loss: 0.0257 -
val_loss: 0.0151
Epoch 16/30
4/4 [=====] - 98s 25s/step - loss: 0.0250 -
val_loss: 0.0127
Epoch 17/30
4/4 [=====] - 95s 24s/step - loss: 0.0252 -
val_loss: 0.0133
Epoch 18/30
```

```

4/4 [=====] - 98s 24s/step - loss: 0.0247 -
val_loss: 0.0139
Epoch 19/30
4/4 [=====] - 99s 25s/step - loss: 0.0247 -
val_loss: 0.0141
Epoch 20/30
4/4 [=====] - 98s 25s/step - loss: 0.0243 -
val_loss: 0.0125
Epoch 21/30
4/4 [=====] - 98s 25s/step - loss: 0.0252 -
val_loss: 0.0123
Epoch 22/30
4/4 [=====] - 100s 25s/step - loss: 0.0246 -
val_loss: 0.0152
Epoch 23/30
4/4 [=====] - 101s 25s/step - loss: 0.0242 -
val_loss: 0.0119
Epoch 24/30
4/4 [=====] - 100s 25s/step - loss: 0.0250 -
val_loss: 0.0120
Epoch 25/30
4/4 [=====] - 98s 25s/step - loss: 0.0252 -
val_loss: 0.0140
Epoch 26/30
4/4 [=====] - 96s 24s/step - loss: 0.0240 -
val_loss: 0.0119
Epoch 27/30
4/4 [=====] - 97s 24s/step - loss: 0.0240 -
val_loss: 0.0122
Epoch 28/30
4/4 [=====] - 95s 24s/step - loss: 0.0239 -
val_loss: 0.0134
Epoch 29/30
4/4 [=====] - 97s 25s/step - loss: 0.0237 -
val_loss: 0.0115
Epoch 30/30
4/4 [=====] - 95s 24s/step - loss: 0.0233 -
val_loss: 0.0123

```

Histori Epoch Pelatihan BiGRU:

```

Epoch 1/50
4/4 [=====] - 78s 19s/step - loss: 0.1364 -
val_loss: 0.0822
Epoch 2/50
4/4 [=====] - 75s 19s/step - loss: 0.0981 -
val_loss: 0.0737
Epoch 3/50
4/4 [=====] - 74s 18s/step - loss: 0.0678 -
val_loss: 0.0375
Epoch 4/50
4/4 [=====] - 76s 19s/step - loss: 0.0350 -
val_loss: 0.0208
Epoch 5/50
4/4 [=====] - 74s 18s/step - loss: 0.0274 -
val_loss: 0.0201
Epoch 6/50

```

```
4/4 [=====] - 74s 19s/step - loss: 0.0241 -  
val_loss: 0.0129  
Epoch 7/50  
4/4 [=====] - 74s 19s/step - loss: 0.0193 -  
val_loss: 0.0096  
Epoch 8/50  
4/4 [=====] - 75s 19s/step - loss: 0.0165 -  
val_loss: 0.0093  
Epoch 9/50  
4/4 [=====] - 75s 19s/step - loss: 0.0148 -  
val_loss: 0.0092  
Epoch 10/50  
4/4 [=====] - 75s 18s/step - loss: 0.0136 -  
val_loss: 0.0084  
Epoch 11/50  
4/4 [=====] - 75s 19s/step - loss: 0.0132 -  
val_loss: 0.0086  
Epoch 12/50  
4/4 [=====] - 74s 18s/step - loss: 0.0131 -  
val_loss: 0.0079  
Epoch 13/50  
4/4 [=====] - 74s 19s/step - loss: 0.0120 -  
val_loss: 0.0080  
Epoch 14/50  
4/4 [=====] - 75s 19s/step - loss: 0.0116 -  
val_loss: 0.0081  
Epoch 15/50  
4/4 [=====] - 75s 19s/step - loss: 0.0118 -  
val_loss: 0.0082  
Epoch 16/50  
4/4 [=====] - 74s 18s/step - loss: 0.0120 -  
val_loss: 0.0080  
Epoch 17/50  
4/4 [=====] - 76s 19s/step - loss: 0.0124 -  
val_loss: 0.0081  
Epoch 18/50  
4/4 [=====] - 74s 18s/step - loss: 0.0113 -  
val_loss: 0.0081  
Epoch 19/50  
4/4 [=====] - 76s 19s/step - loss: 0.0116 -  
val_loss: 0.0077  
Epoch 20/50  
4/4 [=====] - 75s 19s/step - loss: 0.0110 -  
val_loss: 0.0081  
Epoch 21/50  
4/4 [=====] - 75s 19s/step - loss: 0.0104 -  
val_loss: 0.0074  
Epoch 22/50  
4/4 [=====] - 75s 19s/step - loss: 0.0106 -  
val_loss: 0.0073  
Epoch 23/50  
4/4 [=====] - 75s 19s/step - loss: 0.0105 -  
val_loss: 0.0069  
Epoch 24/50  
4/4 [=====] - 75s 19s/step - loss: 0.0098 -  
val_loss: 0.0072  
Epoch 25/50
```

```
4/4 [=====] - 73s 18s/step - loss: 0.0098 -  
val_loss: 0.0073  
Epoch 26/50  
4/4 [=====] - 76s 19s/step - loss: 0.0098 -  
val_loss: 0.0076  
Epoch 27/50  
4/4 [=====] - 76s 19s/step - loss: 0.0100 -  
val_loss: 0.0066  
Epoch 28/50  
4/4 [=====] - 78s 20s/step - loss: 0.0101 -  
val_loss: 0.0067  
Epoch 29/50  
4/4 [=====] - 79s 20s/step - loss: 0.0101 -  
val_loss: 0.0069  
Epoch 30/50  
4/4 [=====] - 76s 19s/step - loss: 0.0092 -  
val_loss: 0.0065  
Epoch 31/50  
4/4 [=====] - 76s 19s/step - loss: 0.0092 -  
val_loss: 0.0071  
Epoch 32/50  
4/4 [=====] - 75s 19s/step - loss: 0.0097 -  
val_loss: 0.0064  
Epoch 33/50  
4/4 [=====] - 75s 19s/step - loss: 0.0084 -  
val_loss: 0.0070  
Epoch 34/50  
4/4 [=====] - 75s 19s/step - loss: 0.0083 -  
val_loss: 0.0073  
Epoch 35/50  
4/4 [=====] - 75s 19s/step - loss: 0.0083 -  
val_loss: 0.0078  
Epoch 36/50  
4/4 [=====] - 74s 18s/step - loss: 0.0083 -  
val_loss: 0.0060  
Epoch 37/50  
4/4 [=====] - 75s 19s/step - loss: 0.0076 -  
val_loss: 0.0062  
Epoch 38/50  
4/4 [=====] - 75s 19s/step - loss: 0.0075 -  
val_loss: 0.0059  
Epoch 39/50  
4/4 [=====] - 74s 19s/step - loss: 0.0072 -  
val_loss: 0.0064  
Epoch 40/50  
4/4 [=====] - 75s 19s/step - loss: 0.0071 -  
val_loss: 0.0060  
Epoch 41/50  
4/4 [=====] - 74s 19s/step - loss: 0.0072 -  
val_loss: 0.0069  
Epoch 42/50  
4/4 [=====] - 74s 19s/step - loss: 0.0072 -  
val_loss: 0.0057  
Epoch 43/50  
4/4 [=====] - 74s 18s/step - loss: 0.0067 -  
val_loss: 0.0076  
Epoch 44/50
```

```
4/4 [=====] - 75s 19s/step - loss: 0.0078 -  
val_loss: 0.0064  
Epoch 45/50  
4/4 [=====] - 74s 18s/step - loss: 0.0091 -  
val_loss: 0.0083  
Epoch 46/50  
4/4 [=====] - 74s 19s/step - loss: 0.0091 -  
val_loss: 0.0059  
Epoch 47/50  
4/4 [=====] - 75s 19s/step - loss: 0.0079 -  
val_loss: 0.0056  
Epoch 48/50  
4/4 [=====] - 75s 19s/step - loss: 0.0069 -  
val_loss: 0.0061  
Epoch 49/50  
4/4 [=====] - 76s 19s/step - loss: 0.0065 -  
val_loss: 0.0059  
Epoch 50/50  
4/4 [=====] - 76s 19s/step - loss: 0.0065 -  
val_loss: 0.0060
```