

Artificial Intelligence Berbasis Deep Learning untuk Prediksi Efisiensi Energi pada Sistem WFA Menggunakan Data Sintetis

Dara Sawitri

Program Studi Teknik Elektro, Fakultas Teknik dan Komputer, Universitas Harapan Medan, Medan, Indonesia
dara.sawitri.24@gmail.com

Abstract-Penerapan sistem *Work From Anywhere* (WFA) telah mengubah pola distribusi konsumsi energi listrik yang sebelumnya terpusat di lingkungan perkantoran menjadi tersebar ke rumah, perangkat pribadi, ruang kerja bersama, dan berbagai layanan digital berbasis internet. Di Indonesia pada tahun 2026, kondisi ini mulai terlihat seiring meningkatnya aktivitas daring dan penggunaan perangkat elektronik rumah tangga yang ikut memengaruhi kebutuhan energi listrik nasional. Pada praktiknya, beberapa institusi dan perguruan tinggi mulai menghadapi tantangan baru dalam mengukur efisiensi energi karena penggunaan listrik tidak lagi berada pada satu lokasi terpusat. Penelitian ini mengembangkan model *Artificial Intelligence* berbasis *deep learning* untuk memprediksi tingkat efisiensi energi pada sistem WFA menggunakan data sintetis multivariat. Dataset dibangun dari beberapa variabel, seperti durasi kerja harian, jumlah perangkat aktif, temperatur ruangan, tingkat okupansi rumah, penggunaan pendingin udara, kualitas koneksi internet, tarif listrik, dan intensitas emisi listrik. Model yang digunakan terdiri dari Random Forest sebagai *baseline*, *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), dan Transformer ringan. Hasil simulasi menunjukkan bahwa model Transformer ringan memberikan performa terbaik dengan nilai MAE sebesar 0,041, RMSE sebesar 0,057, MAPE sebesar 5,31%, dan koefisien determinasi (R^2) sebesar 0,928. Nilai evaluasi diperoleh dari hasil simulasi model menggunakan data sintetis sistem WFA. Secara umum, hasil penelitian menunjukkan bahwa pendekatan *deep learning* berpotensi digunakan sebagai dasar pengembangan sistem monitoring dan pengambilan keputusan berbasis data untuk mendukung efisiensi energi pada lingkungan kerja digital modern.

Kata Kunci: Artificial Intelligence, Deep Learning, Efisiensi Energi, Work from Anywhere, Data Sintetis

Abstract-The implementation of the *Work from Anywhere* (WFA) system has shifted electricity consumption patterns from centralized office environments to distributed locations such as homes, personal devices, co-working spaces, and internet-based digital services. In Indonesia in 2026, this phenomenon has become increasingly visible due to the growth of online activities and household electronic device usage, which significantly affect national electricity demand. In practice, several institutions and universities have started facing challenges in measuring energy efficiency because electricity consumption is no longer concentrated in a single location. This study proposes an Artificial Intelligence-based deep learning approach to predict energy efficiency levels in WFA environments using multivariate synthetic data. The dataset was constructed from several variables, including daily working duration, number of active devices, room temperature, occupancy level, air conditioning usage, internet connection quality, electricity tariffs, and electricity emission intensity. Four models were evaluated, namely Random Forest as the baseline model, Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and a lightweight Transformer model. Simulation results indicate that the lightweight Transformer achieved the best performance with an MAE of 0.041, RMSE of 0.057, MAPE of 5.31%, and a coefficient of determination (R^2) of 0.928. The evaluation values were obtained from simulation results of the models using synthetic WFA system data. Overall, the findings demonstrate that deep learning approaches have strong potential to support data-driven monitoring systems and decision-making processes for improving energy efficiency in modern digital working environments.

Keywords: Artificial Intelligence, Deep Learning, Energy Efficiency, Work from Anywhere, Synthetic Data

1. PENDAHULUAN

Perkembangan Artificial Intelligence (AI), deep learning, Internet of Things (IoT), big data, dan cloud computing turut mengubah pola kerja organisasi serta cara penggunaan energi pada lingkungan kerja modern. Konsep Work From Anywhere (WFA) tidak lagi sekadar dipahami sebagai fleksibilitas kerja, tetapi juga berkaitan dengan perubahan distribusi konsumsi listrik pada berbagai lokasi aktivitas. Sebelumnya, kebutuhan energi lebih banyak terpusat di gedung perkantoran maupun fasilitas kampus melalui penggunaan pendingin ruangan (AC), pencahayaan, lift, laboratorium komputer, juga pada banyak perangkat digital lainnya [1]. Setelah penerapan WFA dan pembelajaran daring meningkat disektor pendidikan, maka sebagian penggunaan energi listrik beraktivitas ke rumah para pengguna, ruang kerja bersama seperti CoHive dan GoWork, perangkat

elektronik pribadi, jaringan internet, pusat data, hingga layanan konferensi ataupun rapat virtual. CoHive dan GoWork sendiri merupakan penyediaan ruang kerja bersama yang menawarkan fasilitas kerja fleksibel berbasis digital[2], termasuk didalamnya akses internet dan ruang rapat. Kondisi tersebut menyebabkan pengukuran efisiensi energi menjadi lebih kompleks karena penggunaan listrik tidak lagi terpusat pada satu lokasi, melainkan tersebar pada banyak perangkat dan aktivitas digital di rumah pengguna.

Pada Indonesia tahun 2026, isu efisiensi energi semakin sering dibahas hal ini dikarenakan kebutuhan listrik terus mengalami peningkatan. Hal-hal yang mempengaruhi adalah dikarenakan berkembangnya aktivitas digital berupa layanan berbasis data, dan penggunaan perangkat elektronik yang semakin tinggi dalam aktivitas sehari-hari. Di beberapa instansi pemerintah, kebijakan Work From Anywhere (WFA) mulai diterapkan satu kali dalam seminggu. Sebagai contoh, pegawai dapat bekerja dari rumah pada hari tertentu dengan memanfaatkan rapat online, penyimpanan data berbasis internet seperti Google Drive atau OneDrive, serta sistem administrasi digital lainnya[3].

Fenomena serupa juga mulai dapat dilihat di lingkungan kampus. Beberapa kegiatan akademik dilakukan secara hybrid melalui kuliah daring, rapat online, bimbingan skripsi virtual, hingga pengumpulan tugas menggunakan Learning Management System (LMS). Pada praktiknya, perubahan pola kerja dan pembelajaran tersebut ikut mengurangi mobilitas harian dosen, pegawai, maupun mahasiswa. Kondisi ini dinilai dapat membantu penghematan energi listrik dan bahan bakar minyak (BBM) karena perjalanan menuju kantor atau kampus menjadi lebih sedikit[4], [5].

Namun, di sisi lain, konsumsi energi listrik tidak benar-benar hilang. Sebagian penggunaan energi berpindah ke rumah masing-masing pengguna, terutama untuk perangkat komputer, pendingin ruangan, koneksi internet, dan aktivitas konferensi video. Kondisi tersebut menunjukkan bahwa pengukuran efisiensi energi pada sistem WFA menjadi lebih kompleks dibandingkan pola kerja konvensional. Oleh sebab itu, organisasi dan institusi pendidikan memerlukan pendekatan kuantitatif agar dapat mengetahui apakah kebijakan WFA benar-benar mampu menekan konsumsi energi secara menyeluruh atau hanya memindahkan penggunaan listrik dari kantor dan kampus ke lingkungan rumah tangga[6].

Prediksi efisiensi energi pada lingkungan Work From Anywhere (WFA) dapat dilakukan menggunakan pendekatan deep learning karena karakteristik datanya cenderung temporal, multivariat, dan memiliki hubungan yang tidak linier[2]. Dalam mengkonsumsi listrik hal-hal yang mempengaruhi ketidak efisienannya adalah dipengaruhi oleh banyak faktor yang saling berkaitan, seperti suhu ruangan, durasi rapat daring, penggunaan pendingin udara, jumlah perangkat elektronik aktif, tingkat okupansi ruangan atau yang sering dikenal dengan banyaknya orang yang berada didalam satu ruangan dan beraktivitas di dalam suatu ruangan tersebut, dan kualitas koneksi jaringan internet yang digunakan[7].

Dalam penelitian Artificial Intelligence Berbasis Deep Learning untuk Prediksi Efisiensi Energi pada Sistem WFA ini menggunakan data sintetis, pemilihan model prediksi menjadi hal penting karena pola konsumsi energi pada sistem Work From Anywhere (WFA) berubah terhadap waktu dan dipengaruhi banyak variabel secara bersamaan. Model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) cukup efektif dalam membaca pola data deret waktu karena mampu mempelajari perubahan konsumsi energi secara berurutan[8]. Sementara itu, model Transformer memiliki kemampuan yang lebih baik dalam mengenali hubungan antarvariabel jangka panjang melalui mekanisme attention. Mekanisme attention merukan sebuah mekanisme yang membuat model dapat memprioritaskan informasi tertentu yang dinilai paling berpengaruh dalam proses prediksi.

Karena itu, pendekatan deep learning dinilai lebih sesuai dibandingkan metode statistik konvensional. Dalam berbagai penelitian terkait energi bangunan, smart grid, dan konsumsi listrik rumah tangga, model deep learning menunjukkan kemampuan prediksi yang lebih akurat dan stabil[9]. Dalam penelitian ini untuk prediksi efisiensi energi listrik pada sistem WFA peneliti menggunakan data sintetis, hal ini dikarenakan dapat menghindari keterbatasan data aktual dan merupakan solusi metodologis yang digunakan sebagai alternatif dalam proses penelitian untuk mengatasi keterbatasan akses terhadap data asli sehingga dapat menguji rancangan model tanpa melanggar privasi. Penggunaan data sintetis pada penelitian ini tidak dimaksudkan untuk menggantikan data lapangan seutuhnya, melainkan digunakan sebagai lingkungan awal untuk merancang fitur, mengevaluasi arsitektur model, dan menguji skenario kebijakan sebelum dilakukan validasi pada data nyata. Adapun yang menjadi kontribusi penelitian adalah: melakukan penyusunan terhadap formulasi indeks efisiensi energi WFA; merancang dataset sintetis yang relevan dengan kondisi kerja digital di Indonesia serta melakukan perbandingan model LSTM, GRU, Transformer ringan, dan baseline machine learning. Baseline machine learning merupakan model acuan awal yang digunakan sebagai pembanding untuk mengevaluasi apakah model yang lebih kompleks mampu menghasilkan performa prediksi yang lebih baik[10]. Dalam penelitian AI berbasis deep learning, metode baseline machine learning umumnya digunakan sebagai model pembanding awal untuk mengevaluasi pada langkah selanjutnya dimana apakah pendekatan deep learning mampu memberikan hasil yang lebih optimal.

2. METODOLOGI PENELITIAN

2.1 Desain Penelitian

Dalam peneliti ini, peneliti menggunakan pendekatan eksperimen komputasional, dimana yang dimaksud dengan pendekatan eksperimen komputasional merupakan metode penelitian yang memanfaatkan simulasi dan pengolahan data berbasis komputer untuk menguji performa model secara sistematis. Sebagai contoh dari penelitian eksperimen komputasional adalah pembuatan data sintesis WFA, proses pelatihan model LSTM, GRU, dan Transformer, serta perbandingan performa menggunakan MAE, RMSE, MAPE, dan R^2 merupakan bagian dari pendekatan eksperimen komputasional berbasis AI dan deep learning. Unit analisis adalah sesi kerja WFA harian pada individu atau kelompok pekerja[11], [12].

Pada penelitian ini, unit analisis difokuskan pada aktivitas kerja harian dalam sistem Work from Anywhere (WFA), baik yang dilakukan oleh individu maupun kelompok pekerja. Setiap aktivitas kerja harian diperlakukan sebagai satu data pengamatan yang menggambarkan proses kerja jarak jauh selama satu hari. Data tersebut mencakup beberapa parameter, seperti lama waktu bekerja, jumlah perangkat elektronik yang digunakan, kondisi dan suhu ruangan, penggunaan pendingin udara, kualitas jaringan internet, serta konsumsi energi listrik selama kegiatan berlangsung[13].

Setiap observasi merupakan gambaran dari satu hari kerja dengan fitur digital, lingkungan, perilaku kerja, dan konsumsi listrik. Karena data aktual WFA bersifat sensitif, penelitian menggunakan data sintesis yang dibangkitkan berdasarkan asumsi realistis dari pola kerja digital, konsumsi perangkat, dan karakteristik iklim Indonesia. Data sintesis kemudian dibagi menjadi data latih, validasi, dan uji dengan proporsi 70:15:15. Yang dimaksud dengan uji dengan proporsi 70:15:15 adalah jika ada 1.200 data sintesis maka dibagi ke dalam tiga kelompok, yaitu data pelatihan, validasi, dan pengujian dengan rasio 70:15:15 artinya 70% data latih (training data), 15% data validasi (validation data) dan Dari total data tersebut dan 15% data uji (testing data). Yang artinya dari 1.200 data sintesis maka sebanyak 840 data digunakan untuk proses pelatihan model, sementara 180 data dipakai pada tahap validasi, dan 180 data lainnya digunakan untuk mengevaluasi performa akhir model.

Tabel 1. Variabel Sintesis Sistem WFA

Kelompok Variabel	Contoh Fitur	Alasan Pemilihan
Aktivitas kerja	Durasi kerja, jumlah rapat daring, jam mulai, jam selesai	Mewakili intensitas WFA harian
Perangkat digital	Laptop, monitor, router, smartphone, printer	Mewakili beban listrik langsung
Lingkungan	Suhu, kelembapan, penggunaan AC	Berpengaruh pada konsumsi pendinginan
Okupansi	Jumlah penghuni rumah, luas ruangan kerja	Mewakili beban energi bersama
Kebijakan organisasi	Hari WFA, subsidi listrik, jadwal hibrida	Mewakili faktor manajerial
Energi dan emisi	Kwh harian, tarif, faktor emisi grid	Mewakili efisiensi dan dampak energi

Tabel 1 menunjukkan kelompok data yang digunakan untuk memprediksi efisiensi energi pada lingkungan *Work From Anywhere* (WFA). Variabel tersebut meliputi aktivitas kerja, perangkat digital, kondisi lingkungan, okupansi, kebijakan organisasi, serta energi dan emisi yang digunakan untuk merepresentasikan pola konsumsi listrik dan aktivitas kerja digital selama sistem WFA berlangsung.


2.2 Pembangkitan Data Sintesis

Data sintesis pada penelitian ini dibangun sebanyak 1.200 data sintesis untuk menggambarkan aktivitas Work From Anywhere (WFA) selama periode Januari hingga Mei 2026. Setiap observasi merepresentasikan satu aktivitas kerja harian yang dipengaruhi oleh beberapa faktor, seperti durasi kerja, jumlah perangkat elektronik yang aktif, suhu ruangan, penggunaan pendingin udara, kualitas koneksi internet, serta konsumsi energi listrik selama proses kerja berlangsung[14], [15].

Dalam proses pembentukan data dilakukan melalui simulasi numerik berbasis komputer dengan rentang nilai yang disesuaikan terhadap kondisi kerja digital dan karakteristik iklim tropis di Indonesia. Distribusi suhu dibuat cenderung lebih tinggi pada siang hari dan musim kemarau, sedangkan intensitas rapat daring disimulasikan meningkat pada hari kerja aktif. Konsumsi daya laptop diasumsikan berada pada rentang 45–90 watt, monitor

eksternal 20–40 watt, router internet 8–15 watt, dan pendingin udara (AC) menjadi komponen dengan konsumsi energi terbesar pada rentang 350–900 watt dimana sangat tergantung lama pemakaian. Untuk menggambarkan variasi perilaku pengguna maka pada penelitian menambahkan noise acak pada data sintesis yang dibangkitkan.

Target keluaran penelitian berupa *Energy Efficiency Index* (EEI) dengan skala nilai antara 0 sampai 1. Dimana semakin tinggi nilai EEI, maka semakin efisien penggunaan energi terhadap aktivitas kerja digital yang dilakukan. Secara konseptual, nilai EEI dihitung berdasarkan hubungan antara produktivitas digital dan total konsumsi energi selama aktivitas WFA berlangsung. Pada penelitian ini, *Energy Efficiency Index* (EEI) digunakan sebagai variabel utama untuk menunjukkan tingkat efisiensi energi pada system WFA. Nilai EEI menggambarkan perbandingan antara aktivitas kerja digital yang dihasilkan dengan jumlah energi listrik yang digunakan selama proses kerja berlangsung. Jika nilai EEI semakin tinggi, maka penggunaan energi dianggap lebih efisien terhadap aktivitas kerja yang dilakukan. Sebaliknya, nilai EEI yang rendah menunjukkan bahwa konsumsi listrik relatif lebih besar dibandingkan produktivitas kerja digital yang dihasilkan. *Energy Efficiency Index* (EEI) digunakan sebagai nilai target utama yang diprediksi oleh model AI/deep learning. Dataset sintesis selanjutnya dibagi menjadi data latih, validasi, dan data uji menggunakan rasio 70:15:15.



Gambar 1. Diagram proses data dan pelatihan model deep learning pada sistem WFA.

Sumber: Hasil rancangan peneliti, 2026.

Dari total 1.200 data, sebanyak 840 data digunakan untuk proses pelatihan model, 180 data digunakan pada tahap validasi, dan 180 data lainnya dipakai untuk pengujian performa akhir model. Pembagian dataset tersebut dilakukan agar proses evaluasi model dapat berlangsung lebih objektif serta membantu meminimalkan risiko overfitting pada model deep learning. Pada penelitian Artificial Intelligence Berbasis Deep Learning untuk Prediksi Efisiensi Energi pada Sistem WFA Menggunakan Data Sintesis, overfitting terjadi ketika model deep learning mampu menghasilkan performa yang sangat tinggi pada data pelatihan, tetapi kemampuan prediksinya menurun saat digunakan pada data baru yang belum pernah dikenali sebelumnya. Kondisi tersebut dapat memengaruhi tingkat akurasi model dalam memprediksi efisiensi energi pada berbagai skenario WFA[16], [17], [18].

Penjelasan Gambar 1. Diagram proses data dan pelatihan model deep learning pada sistem WFA adalah dimana diawali dengan pembentukan data sintesis berdasarkan variabel pada sistem WFA, kemudian dilanjutkan ke proses *preprocessing*, pembagian data menjadi data latih, validasi, dan pengujian, serta pelatihan model Random Forest, LSTM, GRU, dan Transformer ringan. Setelah itu, model digunakan untuk melakukan prediksi *Energy Efficiency Index* (EEI) dan hasilnya dievaluasi menggunakan MAE, RMSE, MAPE, dan R² untuk mengetahui performa model yang paling optimal.

2.3 Model Deep Learning

Pada penelitian Artificial Intelligence Berbasis Deep Learning untuk Prediksi Efisiensi Energi pada Sistem WFA Menggunakan Data Sintesis, proses pemodelan dilakukan menggunakan Random Forest, LSTM, GRU, dan

Transformer ringan untuk memprediksi Energy Efficiency Index (EEI) berdasarkan variabel sintesis sistem WFA. Dataset yang digunakan berjumlah 1.200 data dan dibagi menjadi data latih, validasi, dan data uji dengan rasio 70:15:15, yaitu 840 data untuk pelatihan, 180 data untuk validasi, dan 180 data untuk pengujian model. Random Forest digunakan sebagai baseline machine learning, sedangkan LSTM dan GRU dipakai untuk mempelajari pola temporal pada data konsumsi energi. Sementara itu, Transformer ringan digunakan untuk mengenali hubungan antarfitur dan dependensi waktu melalui mekanisme attention, yaitu mekanisme yang membantu model memprioritaskan informasi penting selama proses prediksi[19], [20].

Parameter pelatihan yang digunakan meliputi window 7 hari, batch size 64, maksimum 100 epoch, early stopping 10 epoch, optimizer Adam, dan learning rate sebesar 0,001. Parameter pelatihan (*training parameters*) digunakan untuk mengatur proses pembelajaran model deep learning dalam memprediksi efisiensi energi pada sistem WFA. Pada penelitian ini, model LSTM, GRU, dan Transformer dilatih menggunakan beberapa parameter, seperti *window*, *batch size*, *epoch*, *optimizer*, dan *learning rate* agar mampu mempelajari pola konsumsi energi dari data sintesis secara lebih akurat dan stabil.

Tabel 2. Parameter Pelatihan Model Deep Learning

Parameter	Penjelasan	Kaitan dengan Penelitian
Window 7 hari	Model mempelajari pola berdasarkan data selama 7 hari sebelumnya	Digunakan untuk mengenali pola konsumsi energi mingguan pada sistem WFA
Batch size 64	Sebanyak 64 data diproses dalam satu tahap pelatihan	Membantu proses pelatihan menjadi lebih efisien dan stabil
Epoch 100	Model melakukan proses pembelajaran hingga 100 kali terhadap seluruh data latih	Agar model dapat memahami pola efisiensi energi secara lebih optimal
Early stopping 10 epoch	Pelatihan dihentikan apabila tidak terdapat peningkatan selama 10 epoch berturut-turut	Membantu mengurangi kemungkinan overfitting pada model
Optimizer Adam	Metode optimasi yang digunakan untuk memperbarui parameter model	Membantu proses pembelajaran model menjadi lebih cepat dan stabil
Learning rate 0,001	Tingkat kecepatan model dalam memperbarui nilai pembelajaran	Digunakan untuk menjaga kestabilan selama proses training

Pada tabel 2, dimana parameter pelatihan digunakan untuk menjelaskan konfigurasi utama yang diterapkan selama proses *training* model deep learning pada prediksi efisiensi energi sistem WFA. Parameter tersebut membantu model dalam mempelajari pola konsumsi energi dari data sintesis secara lebih stabil dan optimal. Selain itu, konfigurasi pelatihan juga digunakan untuk meningkatkan akurasi prediksi serta membantu mengurangi risiko *overfitting* pada model deep learning.

2.4 Evaluasi Model

Pada penelitian Artificial Intelligence Berbasis Deep Learning untuk Prediksi Efisiensi Energi pada Sistem WFA Menggunakan Data Sintesis, dimana tahap evaluasi model dilakukan untuk mengetahui kemampuan Random Forest, LSTM, GRU, dan Transformer ringan dalam melakukan prediksi Energy Efficiency Index (EEI) pada lingkungan WFA. Evaluasi dilakukan dengan membandingkan nilai prediksi dan nilai aktual pada data pengujian menggunakan MAE, RMSE, MAPE, dan R^2 . Metrik evaluasi tersebut banyak digunakan pada penelitian deep learning dan prediksi konsumsi energi karena dapat menggambarkan tingkat kesalahan prediksi serta kemampuan model dalam memahami hubungan antarvariabel secara lebih baik[21], [22], [23].

Tabel 3 menunjukkan sebagian contoh data uji sintesis beserta hasil prediksi EEI yang dihasilkan oleh model Random Forest, LSTM, GRU, dan Transformer ringan. Data tersebut digunakan untuk menggambarkan proses evaluasi performa model pada sistem WFA. Tabel 3 tersebut merupakan data uji lengkap 180 data sintesis, dimana data uji lengkap tidak ditampilkan secara keseluruhan dikarenakan keterbatasan halaman dari jurnal ini, sehingga hanya ditampilkan 5 data sebagai sampel dari 180 data uji lengkap sintesis yang ada. Nilai konsumsi energi dan EEI aktual pada Tabel 3 merupakan hasil pembangkitan data sintesis berdasarkan skenario aktivitas WFA. Nilai tersebut tidak berasal dari pengukuran lapangan langsung, tetapi disusun melalui simulasi untuk merepresentasikan hubungan antara produktivitas digital, konsumsi energi, dan kondisi kerja jarak jauh[24], [25].

Tabel 3. Data Sintesis Konsumsi Energi dan EEI pada Sistem WFA

No	Produktivitas Digital	Konsumsi Energi (kWh)	Kondisi WFA	EEI Aktual
----	-----------------------	-----------------------	-------------	------------

1	Tinggi	2,8	Durasi kerja stabil, penggunaan AC rendah	0,82
2	Sedang	3,4	Aktivitas rapat daring moderat	0,74
3	Sedang	4,1	Penggunaan perangkat aktif cukup tinggi	0,69
4	Tinggi	2,5	Produktivitas tinggi dengan konsumsi energi rendah	0,88
5	Sedang	3,6	Penggunaan AC dan perangkat digital meningkat	0,77

Adapun perhitungan matematisnya menggunakan rumus sebagai berikut :

Rumus EEI

$$EEI = \frac{DP_n}{EC_n + EP}$$

Keterangan:

- EEI = *Energy Efficiency Index*
- DP_n = produktivitas digital ternormalisasi
- EC_n = konsumsi energi ternormalisasi
- EP = penalti emisi

Sebagai contoh untuk perhitungan data 1 adalah sebagai berikut misalnya produktivitas digital = 0,90, konsumsi energi ternormalisasi = 0,95 dan penalti emisi = 0,15 Maka:

$$EEI = \frac{0,90}{0,95 + 0,15}$$

$$EEI = \frac{0,90}{1,10}$$

$$EEI = 0,818$$

$$EEI \approx 0,82$$

Proses perhitungan yang sama dilakukan pada data berikutnya pada Tabel 3 sehingga diperoleh nilai EEI aktual seperti yang ditunjukkan pada Tabel 4.

Tabel 4. Hasil Perhitungan EEI Aktual dari Data Sintetis WFA

No	Produktivitas Digital	Konsumsi Energi Ternormalisasi	Penalti Emisi	Hasil Perhitungan EEI	EEI Aktual
1	0,90	0,95	0,15	$0,90 / (0,95 + 0,15)$	0,82
2	0,78	0,90	0,15	$0,78 / (0,90 + 0,15)$	0,74
3	0,72	0,88	0,16	$0,72 / (0,88 + 0,16)$	0,69
4	0,95	0,93	0,15	$0,95 / (0,93 + 0,15)$	0,88
5	0,81	0,89	0,16	$0,81 / (0,89 + 0,16)$	0,77

Pada Tabel 4 dimana nilai *Energy Efficiency Index* (EEI) aktual pada penelitian ini dihitung berdasarkan hubungan antara tingkat produktivitas digital, konsumsi energi yang telah dinormalisasi, serta faktor penalti emisi pada sistem *Work From Anywhere* (WFA). Nilai EEI digunakan untuk menunjukkan tingkat efisiensi penggunaan energi selama aktivitas kerja berlangsung. Jika produktivitas kerja digital meningkat sementara konsumsi energi tetap rendah, maka nilai EEI akan menjadi lebih tinggi dan menggambarkan kondisi penggunaan energi yang lebih efisien. Sebaliknya, apabila konsumsi energi lebih besar dibandingkan aktivitas kerja yang dihasilkan, maka nilai EEI cenderung menurun.

3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Data Sintetis

Dalam penelitian Artificial Intelligence Berbasis Deep Learning untuk Prediksi Efisiensi Energi pada Sistem WFA Menggunakan Data Sintetis, nilai *Energy Efficiency Index* (EEI) digunakan sebagai parameter utama untuk menggambarkan tingkat efisiensi penggunaan energi pada sistem *Work From Anywhere* (WFA). Nilai tersebut dihitung berdasarkan hubungan antara produktivitas digital, konsumsi energi yang telah dinormalisasi, dan penalti emisi selama aktivitas kerja digital berlangsung.


Tabel 5 memperlihatkan contoh hasil perhitungan nilai EEI aktual yang diperoleh dari data sintetis sistem WFA pada penelitian ini.

Tabel 5. Hasil Perhitungan EEI Aktual dari Data Sintetis WFA

No	Produktivitas Digital	Konsumsi Ternormalisasi	Energi	Penalti Emisi	Hasil Perhitungan EEI	EEI Aktual
1	0,90	0,95		0,15	$0,90 / (0,95 + 0,15)$	0,82
2	0,78	0,90		0,15	$0,78 / (0,90 + 0,15)$	0,74
3	0,72	0,88		0,16	$0,72 / (0,88 + 0,16)$	0,69
4	0,95	0,93		0,15	$0,95 / (0,93 + 0,15)$	0,88
5	0,81	0,89		0,16	$0,81 / (0,89 + 0,16)$	0,77

Berdasarkan Tabel 5, nilai EEI paling tinggi terdapat pada data keempat dengan nilai sebesar 0,88. Kondisi ini menunjukkan bahwa aktivitas kerja digital yang memiliki produktivitas tinggi namun didukung konsumsi energi yang lebih rendah mampu menghasilkan efisiensi energi yang lebih baik. Sebaliknya, nilai EEI terendah terlihat pada data ketiga dengan nilai 0,69. Nilai tersebut dipengaruhi oleh konsumsi energi yang relatif lebih besar dibandingkan produktivitas digital selama aktivitas WFA berlangsung.

Secara keseluruhan, hasil tersebut memperlihatkan bahwa konsumsi energi memiliki pengaruh yang cukup besar terhadap perubahan nilai EEI. Apabila penggunaan energi meningkat tanpa diikuti peningkatan produktivitas digital yang sebanding, maka nilai EEI cenderung mengalami penurunan. Pada praktiknya, kondisi tersebut dapat disebabkan oleh penggunaan pendingin ruangan yang terlalu lama, durasi rapat daring yang tinggi, serta banyaknya perangkat elektronik yang aktif selama proses WFA berlangsung.


Gambar 2. Grafik Perhitungan Energy Efficiency Index (EEI) Aktual dari Data Sintetis WFA.

Sumber: Hasil olahan peneliti, 2026.

Gambar 2 menampilkan visualisasi hasil perhitungan EEI aktual dari data sintetis pada sistem WFA. Grafik utama memperlihatkan hubungan antara produktivitas digital, konsumsi energi ternormalisasi, dan nilai EEI pada setiap data pengamatan. Nilai EEI terlihat lebih tinggi ketika produktivitas digital meningkat dengan penggunaan energi yang relatif lebih rendah. Sebaliknya, konsumsi energi yang lebih besar tanpa peningkatan produktivitas yang seimbang menyebabkan nilai EEI mengalami penurunan.

Pada bagian lainnya, grafik penalti emisi menggambarkan kontribusi faktor emisi terhadap proses perhitungan EEI. Sementara itu, grafik EEI aktual menunjukkan pola distribusi nilai efisiensi energi dari masing-masing data sintesis. Secara keseluruhan, visualisasi tersebut menunjukkan bahwa produktivitas digital, konsumsi energi, dan penalti emisi saling memengaruhi dalam menentukan tingkat efisiensi energi pada sistem WFA.

3.2 Hasil Prediksi Model Deep Learning

EEI aktual yang dihasilkan dari data sintesis kemudian digunakan sebagai target pada proses prediksi menggunakan model Random Forest, LSTM, GRU, dan Transformer ringan. Tahap prediksi dilakukan untuk melihat kemampuan setiap model dalam mengenali dan mempelajari pola konsumsi energi pada sistem WFA.

Tabel 6 Hasil Prediksi Model terhadap EEI Aktual

No	EEI Aktual	Random Forest	LSTM	GRU	Transformer
1	0,82	0,75	0,79	0,78	0,81
2	0,74	0,68	0,72	0,71	0,73
3	0,69	0,61	0,66	0,65	0,68
4	0,88	0,79	0,84	0,83	0,87
5	0,77	0,70	0,74	0,73	0,76

Berdasarkan hasil prediksi pada Tabel 6, model Transformer ringan menunjukkan hasil yang paling mendekati nilai EEI aktual dibandingkan model lainnya. Sebagai contoh, pada data pertama nilai EEI aktual sebesar 0,82, sementara hasil prediksi Transformer sebesar 0,81. Nilai tersebut memiliki selisih yang lebih kecil dibandingkan model Random Forest yang menghasilkan prediksi sebesar 0,75. Nilai 0,75 merupakan hasil prediksi yang dihasilkan oleh model Random Forest terhadap data pertama pada sistem WFA setelah proses pelatihan model dilakukan menggunakan dataset sintesis.

Model LSTM dan GRU juga memberikan performa prediksi yang cukup baik karena mampu mempelajari pola temporal pada data konsumsi energi sistem WFA. Akan tetapi, model Transformer menghasilkan prediksi yang lebih stabil karena mampu memahami hubungan antarvariabel melalui mekanisme *attention*. Di sisi lain, Random Forest masih memiliki performa yang cukup baik pada data tabular, namun belum optimal dalam menangkap pola hubungan temporal jangka panjang.

Tahap prediksi dilakukan menggunakan model Random Forest, LSTM, GRU, dan Transformer ringan. Model tersebut digunakan untuk mempelajari hubungan antara produktivitas digital, konsumsi energi, penggunaan perangkat elektronik, serta variabel lain pada sistem WFA dalam menghasilkan prediksi *Energy Efficiency Index* (EEI). Tahap evaluasi dilakukan melalui proses perhitungan aritmatika dengan membandingkan nilai EEI aktual dan hasil prediksi dari setiap model. Perhitungan evaluasi menggunakan MAE, RMSE, MAPE, dan R² untuk mengetahui tingkat kesalahan prediksi serta kemampuan model dalam memahami pola konsumsi energi pada sistem WFA. Sebagai contoh misalnya data pertama memiliki input sebagai berikut pada Tabel 7 data input yang dibaca oleh setiap *Decision Tree* :

Tabel 7 Prediksi Setiap Decision Tree pada Model Random Forest

Variabel	Nilai
Produktivitas Digital	0,90
Konsumsi Energi	0,95
Penggunaan AC	Tinggi
Perangkat Aktif	5
Suhu Ruangan	30°C

Prediksi setiap decision tree pada model random forest berasal dari data latih (*training data*) yang diambil dari dataset sintesis sistem WFA. Karena Random Forest tersusun dari banyak *Decision Tree*, maka setiap tree mempelajari pola hubungan antarvariabel yang berbeda berdasarkan data latih sintesis yang dipilih secara acak. Pada proses *Decision Tree*, model membentuk aturan (*rule*) berdasarkan data training sintesis.

Contoh sederhana aturan Tree 1:

IF KonsumsiEnergi > 0,90

dan

IF PenggunaanAC = Tinggi

maka:

EEI = 0,74

Dimana artinya dikarenakan konsumsi energi tinggi maka penggunaan AC tinggi, dan suhu ruangan tinggi. Oleh sebab itu maka Tree 1 memprediksi efisiensi energi lebih rendah sehingga menghasilkan 0,74. (Sesuai Tabel 5 Hasil Perhitungan EEI Aktual dari Data Sintetis WFA). Sedangkan prediksi akhir Random Forest dihitung menggunakan rata-rata seluruh tree:

$$\hat{y} = \frac{1}{K} \sum_{k=1}^K T_k(x)$$

Contoh:

$$\hat{y} = \frac{0,74 + 0,76 + 0,75 + 0,73 + 0,77}{5}$$

$$\hat{y} = 0,75$$

Nilai 0,75 adalah hasil prediksi akhir dari model Random Forest terhadap *Energy Efficiency Index* (EEI). Nilai tersebut diperoleh dari rata-rata prediksi beberapa *Decision Tree* yang mempelajari pola variabel pada sistem WFA.

Pada model *Long Short-Term Memory* (LSTM), proses prediksi dilakukan dengan mempelajari pola temporal dari data sistem *Work From Anywhere* (WFA), seperti produktivitas digital, konsumsi energi, penggunaan pendingin udara, dan suhu ruangan. LSTM memanfaatkan mekanisme memori (*cell state*) untuk menyimpan informasi penting dari data sebelumnya sehingga model dapat menghasilkan prediksi *Energy Efficiency Index* (EEI) secara lebih stabil dan konsisten.

Sebagai ilustrasi, model LSTM membaca pola data pada beberapa waktu sebelumnya dan menghasilkan beberapa nilai *hidden state* pada Tabel 8 berikut :

Tabel 8. Data Input Temporal pada Model LSTM

Waktu	Produktivitas Digital	Konsumsi Energi	Penggunaan AC	Perangkat Aktif	Hidden State
t-3	0,84	0,88	Sedang	4	0,76
t-2	0,87	0,91	Tinggi	5	0,78
t-1	0,90	0,95	Tinggi	5	0,79

Data input temporal pada model LSTM berasal dari rangkaian data sintetis sistem WFA yang disusun secara berurutan berdasarkan waktu sehingga model mampu mempelajari pola perubahan konsumsi energi dan produktivitas digital dari periode sebelumnya. Berdasarkan pola yang telah dipelajari tersebut, model menghasilkan prediksi akhir *Energy Efficiency Index* (EEI) sebesar:

$$\hat{y} = 0,79$$

Nilai 0,79 menunjukkan hasil prediksi model LSTM terhadap data pertama sistem WFA setelah proses pembelajaran pola temporal dari data sintetis sebelumnya dilakukan.

Pada model *Gated Recurrent Unit* (GRU), proses prediksi dilakukan dengan mempelajari pola temporal dari data sistem WFA, seperti produktivitas digital, konsumsi energi, penggunaan AC, dan suhu ruangan. GRU memanfaatkan mekanisme *update gate* untuk menyimpan informasi penting dari data sebelumnya sehingga proses prediksi EEI dapat dilakukan lebih efisien dibandingkan LSTM. Sebagai contoh, model GRU membaca pola data pada beberapa waktu sebelumnya dan menghasilkan beberapa nilai *hidden state* sebagai berikut pada Tabel 9 berikut, dimana data berasal dari data sintetis sistem WFA yang disusun berdasarkan urutan waktu sebagai input model GRU untuk mempelajari pola konsumsi energi dan produktivitas digital.

Tabel 9. Data Input Temporal pada Model GRU

Waktu	Produktivitas Digital	Konsumsi Energi	Penggunaan AC	Perangkat Aktif	Hidden State
t-3	0,82	0,86	Sedang	4	0,74
t-2	0,85	0,89	Tinggi	5	0,76
t-1	0,88	0,92	Tinggi	5	0,78

Proses utama pada GRU dapat dituliskan sebagai berikut:

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t$$

Keterangan:

- h_t = hidden state pada waktu ke- t
- z_t = *update gate*
- h_{t-1} = hidden state sebelumnya
- $\tilde{h}_t$ = kandidat hidden state baru

Pada model GRU, data temporal sebelumnya digunakan untuk mempelajari pola konsumsi energi dan produktivitas digital pada sistem WFA sehingga menghasilkan prediksi akhir EEI sebesar: $\hat{y} = 0,78$. Dimana nilai 0,78 berasal dari hidden state terakhir pada Tabel 9 yang digunakan sebagai hasil prediksi akhir model GRU.

Pada model Transformer ringan, proses prediksi dilakukan dengan mempelajari hubungan antar variabel pada WFA, seperti produktivitas digital, konsumsi energi, penggunaan AC, dan suhu ruangan. Model Transformer memanfaatkan mekanisme *attention* untuk memberikan fokus yang lebih besar pada variabel yang dianggap paling berpengaruh terhadap prediksi EEI. Sebagai contoh, model Transformer menghasilkan beberapa bobot *attention* sebagai berikut: pada Tabel 10 berikut ini:

Tabel 10 Bobot Attention pada Model Transformer Ringan

Variabel	Attention Weight
Konsumsi Energi	0,42
Penggunaan AC	0,31
Produktivitas Digital	0,19
Perangkat Aktif	0,08

Data pada Tabel 10 berasal dari data sintesis sistem WFA yang diproses menggunakan mekanisme *attention* pada model Transformer untuk menentukan variabel yang memiliki pengaruh terbesar terhadap prediksi EEI. Proses utama pada Transformer dapat dituliskan sebagai berikut:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

Keterangan:

- Q = query
- K = key
- V = value
- d_k = dimensi vektor

Pada model Transformer ringan, variabel yang memiliki bobot *attention* lebih besar dianggap memberikan pengaruh yang lebih tinggi terhadap hasil prediksi EEI. Berdasarkan proses tersebut, model menghasilkan prediksi akhir $\hat{y} = 0,81$. Dimana nilai 0,81 merupakan hasil prediksi akhir model Transformer ringan terhadap data pertama pada sistem WFA.

HASIL EVALUASI PERFORMA MODEL				
Perbandingan Model Berdasarkan MAE, RMSE, MAPE, dan R ²				
Model	MAE (lebih kecil lebih baik)	RMSE (lebih kecil lebih baik)	MAPE (lebih kecil lebih baik)	R ² (lebih besar lebih baik)
 Random Forest	0,062	0,081	7,85%	0,842
 LSTM	0,049	0,066	6,27%	0,901
 GRU	0,053	0,071	6,88%	0,887
 Transformer Ringan	0,041	0,057	5,31%	0,928

Gambar 3. Hasil Evaluasi Performa Model Prediksi EEI pada Sistem WFA

Gambar 3 memperlihatkan perbandingan hasil evaluasi performa antara model Random Forest, LSTM, GRU, dan Transformer ringan berdasarkan nilai MAE, RMSE, MAPE, dan koefisien determinasi (R²). Dari hasil pengujian, model Transformer ringan memperoleh hasil terbaik dengan nilai MAE 0,041, RMSE 0,057, MAPE 5,31%, serta R² sebesar 0,928. Hasil tersebut menunjukkan bahwa model Transformer ringan memiliki tingkat kesalahan prediksi yang lebih rendah dan tingkat akurasi yang lebih tinggi dalam memprediksi nilai *Energy Efficiency Index* (EEI) pada sistem WFA.

4. KESIMPULAN

Penelitian mengenai Artificial Intelligence berbasis deep learning untuk prediksi efisiensi energi pada sistem Work from Anywhere (WFA) menunjukkan bahwa pendekatan ini mampu memodelkan dan memprediksi nilai Energy Efficiency Index (EEI) secara efektif menggunakan data sintesis yang dibangun dari variabel produktivitas digital, konsumsi energi, penggunaan AC, suhu ruangan, dan jumlah perangkat aktif. Hasil simulasi menunjukkan bahwa Random Forest menghasilkan prediksi EEI sebesar 0,75, LSTM sebesar 0,79, GRU sebesar 0,78, dan Transformer ringan sebesar 0,81, yang merupakan nilai paling mendekati EEI aktual sebesar 0,82. Berdasarkan evaluasi menggunakan MAE, RMSE, MAPE, dan koefisien determinasi (R^2), model Transformer ringan memberikan kinerja terbaik dengan MAE 0,041, RMSE 0,057, MAPE 5,31%, dan R^2 0,928, yang mengindikasikan tingkat kesalahan prediksi yang rendah serta kemampuan yang lebih baik dalam menangkap hubungan antar variabel dibandingkan model lainnya. Temuan ini menunjukkan bahwa metode deep learning memiliki potensi yang signifikan dalam mendukung pengelolaan dan prediksi efisiensi energi pada lingkungan kerja digital berbasis WFA. Namun demikian, penelitian ini masih memiliki keterbatasan karena menggunakan data sintesis yang belum sepenuhnya merepresentasikan kondisi nyata, jumlah variabel yang relatif terbatas, serta belum memanfaatkan data real-time dari perangkat IoT atau smart meter. Oleh karena itu, penelitian selanjutnya disarankan menggunakan data aktual dengan cakupan variabel dan ukuran dataset yang lebih besar agar hasil prediksi menjadi lebih akurat, robust, dan representatif terhadap kondisi operasional yang sesungguhnya.

REFERENSI

- [1] R. Morcillo-Jimenez, J. Mesa, J. Gómez-Romero, M. A. Vila, and M. J. Martin-Bautista, "Deep learning for prediction of energy consumption: an applied use case in an office building," *Applied Intelligence*, vol. 54, no. 7, pp. 5813–5825, Apr. 2024, doi: 10.1007/s10489-024-05451-9.
- [2] S. A. Nabavi, N. H. Motlagh, M. A. Zaidan, A. Aslani, and B. Zakeri, "Deep Learning in Energy Modeling: Application in Smart Buildings with Distributed Energy Generation," *IEEE Access*, vol. 9, pp. 125439–125461, 2021, doi: 10.1109/ACCESS.2021.3110960.
- [3] K. Elhabyb, A. Baina, M. Bellafkih, and A. F. Deifalla, "Machine Learning Algorithms for Predicting Energy Consumption in Educational Buildings," *Int. J. Energy Res.*, vol. 2024, 2024, doi: 10.1155/2024/6812425.
- [4] D. Sawitri, "Paradigma Smart City Dalam Memanfaatkan Potensi Big Data," vol. 11, no. 4, pp. 271–282, 2024, [Online]. Available: <http://jurnal.mdp.ac.id>
- [5] M. Tzelepi *et al.*, "Deep Learning for Energy Time-Series Analysis and Forecasting," Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.09129>
- [6] R. Olu-Ajayi and H. Alaka, "Building energy consumption prediction using deep learning."
- [7] D. Sawitri, "JISA (Jurnal Informatika dan Sains) Cloud Computing Technology in Supporting the Implementation of One Data Indonesia," 2024.
- [8] D. Sawitri, "PERAN DEEP LEARNING DAN BIG DATA DALAM MENDEKTEKSI MASALAH KEUANGAN," *Jurnal Teknologi Informasi*, vol. 6, no. 1, 2025, doi: 10.46576/djtechno.
- [9] A. B. Owolabi, A. Yahaya, M. Amir, A. O. Yakub, M. Kavgic, and D. Suh, "Predicting energy consumption of building clusters at the design stage using machine learning models," *Ain Shams Engineering Journal*, vol. 16, no. 8, Aug. 2025, doi: 10.1016/j.asej.2025.103481.
- [10] Y. Duan, "A Novel Interval Energy-Forecasting Method for Sustainable Building Management Based on Deep Learning," *Sustainability (Switzerland)*, vol. 14, no. 14, Jul. 2022, doi: 10.3390/su14148584.
- [11] O. Bouhamed, M. Dissem, M. Amayri, and N. Bouguila, "Transformer-based deep probabilistic network for load forecasting," *Eng. Appl. Artif. Intell.*, vol. 152, Jul. 2025, doi: 10.1016/j.engappai.2025.110781.
- [12] A. Binbusayyis and M. Sha, "Energy consumption prediction using modified deep CNN-Bi LSTM with attention mechanism," *Heliyon*, vol. 11, no. 1, Jan. 2025, doi: 10.1016/j.heliyon.2024.e41507.
- [13] F. Saeed, A. Rehman, H. A. Shah, M. Diyan, C. Jie, and J.-M. Kang, "SmartFormer: Graph-Based Transformer Model for Energy Load Forecasting." [Online]. Available: <https://ssrn.com/abstract=4893923>
- [14] S. Moveh, E. A. Merchán-Cruz, M. Abuhussain, Y. A. Dodo, S. Alhumaid, and A. H. Alhamami, "Deep Learning Framework Using Transformer Networks for Multi Building Energy Consumption Prediction in Smart Cities," *Energies (Basel)*, vol. 18, no. 6, Mar. 2025, doi: 10.3390/en18061468.



- [15] T. A. Woldegiyorgis *et al.*, “Harnessing Artificial Intelligence to improve building performance and energy use: innovations, challenges, and future perspectives,” *Energy Informatics*, vol. 8, no. 1, Dec. 2025, doi: 10.1186/s42162-025-00589-3.
- [16] R. Mathumitha, P. Rathika, and K. Manimala, “Intelligent deep learning techniques for energy consumption forecasting in smart buildings: a review,” *Artif. Intell. Rev.*, vol. 57, no. 2, Feb. 2024, doi: 10.1007/s10462-023-10660-8.
- [17] Y. Wang, “Application of Deep Learning Model in Building Energy Consumption Prediction,” *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/4835259.
- [18] A. Kala, O. Torkul, T. Tunacan Yıldız, and I. H. Selvi, “Early Prediction of Students’ Performance Through Deep Learning: A Systematic and Bibliometric Literature Review,” Mar. 28, 2025, *Sakarya University*. doi: 10.35377/saucis...1635558.
- [19] A. Nanjar, R. E. Saputro, and B. Berlilana, “Machine Learning and Deep Learning Approaches for Energy Prediction: A Systematic Literature Review,” *sinkron*, vol. 8, no. 4, pp. 2603–2614, Nov. 2024, doi: 10.33395/sinkron.v8i4.14208.
- [20] J. Huang and S. Kaewunruen, “Forecasting Energy Consumption of a Public Building Using Transformer and Support Vector Regression,” *Energies (Basel)*, vol. 16, no. 2, Jan. 2023, doi: 10.3390/en16020966.
- [21] R. Mathumitha, P. Rathika, and K. Manimala, “Intelligent deep learning techniques for energy consumption forecasting in smart buildings: a review,” *Artif. Intell. Rev.*, vol. 57, no. 2, Feb. 2024, doi: 10.1007/s10462-023-10660-8.
- [22] D. Sawitri, K. D. April, M. Sayuti, G. Ramdahan, and B. Suwanda, “IoT-Based Cassava Slicing Machine Using ESP32 with Smartphone Monitoring,” *Jurnal Nasional Teknik Elektro*, vol. 15, no. 1, 2026, doi: 10.25077/jnte.v15n1.1440.2026.
- [23] G. Chen *et al.*, “A Systematic Review of Building Energy Consumption Prediction: From Perspectives of Load Classification, Data-Driven Frameworks, and Future Directions,” Mar. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/app15063086.
- [24] L. Moosbrugger, V. Seiler, G. Huber, and P. Kepplinger, “Improve Load Forecasting in Energy Communities through Transfer Learning using Open-Access Synthetic Profiles,” Jul. 2024, [Online]. Available: <http://arxiv.org/abs/2407.08434>
- [25] D. Sawitri, “Big Data Challenges And Opportunities In The Development Of Digital Technology,” *Informatika dan Sains*, vol. 14, no. 02, p. 2024, doi: 10.58471/infosains.v14i02.