

Integrasi *Teaching-Learning-Based Optimization* dan *K-Nearest Neighbors* untuk Prediksi Konsumsi Energi Listrik

Integration of Teaching-Learning-Based Optimization and K-Nearest Neighbors for Predicting Electrical Energy Consumption

Retno Wahyusari^{*1}, Aris Rakhmadi², Lastoni Wibowo³

¹. Program Studi Informatika, Sekolah Tinggi Teknologi Ronggolawe

²Jurusan Teknik Informatika, Fakultas Komunikasi dan Informatika, Universitas Muhammadiyah Surakarta

³Program Studi Teknik Elektro, Sekolah Tinggi Teknologi Ronggolawe

e-mail: *1retnowahyusari@gmail.com

Abstrak – Konsumsi energi listrik merupakan salah satu aspek krusial dalam manajemen energi, terutama di era modern di mana kebutuhan energi terus meningkat seiring dengan perkembangan teknologi dan pertumbuhan populasi. Maka perlu adanya prediksi konsumsi energi listrik yang akurat. Salah satu metode yang populer untuk prediksi adalah *K-Nearest Neighbors* (KNN). Berdasarkan hal tersebut maka penelitian ini bertujuan untuk meningkatkan kinerja prediksi konsumsi energi listrik dengan mengintegrasikan algoritma *Teaching-Learning-Based Optimization* (TLBO) dalam proses seleksi fitur dan algoritma *K-Nearest Neighbors* (KNN) sebagai model prediksi. Data yang digunakan merupakan dataset konsumsi energi publik dari Kaggle dengan total 1000 data. Data terlebih dahulu diproses melalui normalisasi *Min-Max Scaling* sebelum dilakukan seleksi fitur. TLBO digunakan untuk memilih subset fitur yang paling relevan, yaitu *Temperature*, *SquareFootage*, *HVACUsage*, dan *Holiday*. Model KNN kemudian dilatih menggunakan fitur terpilih tersebut. Evaluasi kinerja dilakukan menggunakan dua metrik utama: *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil menunjukkan bahwa model dengan fitur hasil TLBO menghasilkan MAPE sebesar 23.15% dan RMSE sebesar 0.1125, lebih baik dibandingkan model dengan seluruh fitur (MAPE 27.62%, RMSE 0.1297). Ini menunjukkan bahwa seleksi fitur dengan TLBO mampu menyederhanakan model sekaligus meningkatkan performa prediksi.

Kata kunci – KNN, *Min-Max Scaling*komponen, Prediksi Konsumsi Energi, Seleksi Fitur, TLBO.

Abstract - Electricity consumption is one of the crucial aspects in energy management, especially in the modern era where energy needs continue to increase along with technological developments and population growth. Therefore, it is necessary to have an accurate prediction of electricity consumption. One of the popular methods for prediction is *K-Nearest Neighbors* (KNN). Based on this, this study aims to improve the performance of electricity consumption prediction by integrating the *Teaching-Learning-Based Optimization* (TLBO) algorithm in the feature selection process and the *K-Nearest Neighbors* (KNN) algorithm as a prediction model. The data used is a public energy consumption dataset from Kaggle with a total of 1000 data. The data is first processed through *Min-Max Scaling* normalization before feature selection. TLBO is used to select the most relevant feature subsets, namely *Temperature*, *SquareFootage*, *HVACUsage*, and *Holiday*. The KNN model is then trained using the selected features. Performance evaluation is carried out using two main metrics: *Root Mean Square Error* (RMSE) and

Mean Absolute Percentage Error (MAPE). The results show that the model with TLBO feature results in a MAPE of 23.15% and an RMSE of 0.1125, better than the model with all features (MAPE 27.62%, RMSE 0.1297). This shows that feature selection with TLBO is able to simplify the model while improving prediction performance.

Keywords – KNN, Min-Max Scaling components, Energy Consumption Prediction, Feature Selection, TLBO.

I. PENDAHULUAN

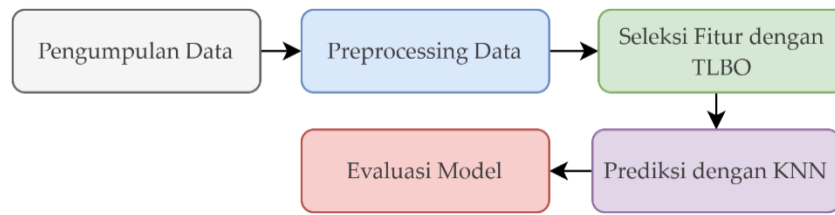
Konsumsi energi listrik merupakan salah satu aspek krusial dalam manajemen energi, terutama di era modern di mana kebutuhan energi terus meningkat seiring dengan perkembangan teknologi dan pertumbuhan populasi [1][2]. Prediksi konsumsi energi listrik yang akurat sangat diperlukan untuk perencanaan dan pengelolaan sumber daya energi yang efisien. Namun, prediksi ini sering kali menghadapi tantangan karena kompleksitas dan dimensi data yang besar, yang dapat mempengaruhi kinerja model prediksi [3], [4]. Oleh karena itu, seleksi fitur menjadi langkah krusial dalam mengurangi dimensi data dan meningkatkan akurasi prediksi [5], [6].

Salah satu metode yang populer untuk prediksi adalah K-Nearest Neighbors (KNN). Meskipun KNN dikenal sederhana dan efektif, kinerjanya sangat dipengaruhi oleh kualitas fitur yang digunakan [7], [8]. Hasil penelitian yang dilakukan Fan Li dan Guang Jin [9] menunjukkan bahwa metode peramalan beban energi listrik menggunakan algoritma KNN yang dirancang dapat menganalisis dan meramalkan beban listrik dalam waktu singkat dengan akurasi peramalan yang tinggi. Hasil penelitian juga memverifikasi validitas dan akurasi metode peramalan beban energi listrik. Dalam konteks perkembangan berkelanjutan industri listrik, teknologi konsumsi listrik di China bergerak menuju arah yang lebih beragam, terdistribusi, hemat energi, dan cerdas. Salah satu metode seleksi fitur adalah *Teaching-Learning-Based Optimization* (TLBO). TLBO adalah algoritma optimasi yang terinspirasi dari proses pembelajaran di kelas [10], [11]. TLBO telah terbukti efektif dalam menyelesaikan berbagai masalah optimasi karena kemampuannya dalam mengeksplorasi dan mengeksploitasi ruang pencarian secara efisien [12]. Dengan memanfaatkan TLBO, diharapkan proses seleksi fitur dapat dilakukan dengan lebih optimal, sehingga menghasilkan subset fitur yang meningkatkan kinerja prediksi konsumsi energi listrik menggunakan KNN. Gap penelitian ini menerapkan pemilihan fitur menggunakan metode TLBO. Integrasi TLBO dengan metode prediksi KNN, guna meningkatkan kinerja metode KNN dalam prediksi konsumsi energi listrik.

II. METODE

Seleksi fitur menggunakan algoritma *Teaching-Learning-Based Optimization* (TLBO) untuk prediksi konsumsi energi listrik berbasis *K-Nearest Neighbors* (KNN). Data yang digunakan merupakan data publik diambil dari kaggle, nama file *Energy Consumption*. Proses preprocessing data dilakukan dengan min-max scaling. Tahap selanjutnya pemilihan fitur menggunakan algoritma TLBO. Hasil seleksi fitur digunakan untuk prediksi konsumsi energi listrik. Model prediksi menggunakan KNN dan dievaluasi menggunakan matrik evaluasi

RMSE, MAPE, dan akurasi. Gambar 1 merupakan tahapan prediksi konsumsi energi listrik.



Gambar 1. Tahapan Prediksi Konsumsi Energi Listrik.

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian merupakan data kaggle berupa konsumsi energi listrik. Data sebanyak 1000 data, dengan atribut *Timestamp*, *Temperature*, *Humidity*, *SquareFootage*, *Occupancy*, *HVACUsage*, *LightingUsage*, *RenewableEnergy*, *DayOfWeek*, *Holiday*, *EnergyConsumption*.

2.2. Preprocessing Data

Proses pra-pemrosesan dilakukan agar data dapat diproses ke tahap selanjutnya. Pada proses ini, dilakukan proses normalisasi data dengan menggunakan metode normalisasi min-max scaling. Persamaan (1) merupakan perhitungan min-max scaling, dimana x' merupakan nilai data asli, x_{min} merupakan nilai data fitur minimum, dan x_{max} merupakan nilai data fitur tertinggi.

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \dots\dots\dots (1)$$

2.3. Seleksi Fitur dengan TLBO

Seleksi fitur menggunakan algoritma TLBO, adapun pseudocode TLBO sebagai berikut:

- a. Inisialisasi populasi:
 - Tentukan jumlah populasi (N), dimensi masalah (D), batas atas (ub), dan batas bawah (lb).
 - Bangun populasi awal secara acak:

$$X[i][j] = lb[j] + rand(0,1) * (ub[j] - lb[j]), \text{ untuk } i = 1, 2, \dots, N \text{ dan } j = 1, 2, \dots, D.$$
- b. Evaluasi fitness:
 - Hitung nilai fitness $f(X[i])$ untuk setiap individu $X[i]$.
- c. While (kriteria penghentian belum terpenuhi):
 - Fase Teaching:
 - Temukan individu terbaik (guru) $X_{teacher}$.
 - Hitung nilai rata-rata X_{mean} untuk setiap dimensi j :

$$X_mean[j] = (1/N) * \sum(X[i][j]), \text{ untuk } i = 1, 2, \dots, N.$$

- Perbarui setiap individu $X[i]$ menggunakan rumus:

$$X_new[i][j] = X[i][j] + \text{rand}(0,1) * (X_teacher[j] - T_F * X_mean[j]), \text{ untuk } j = 1, 2, \dots, D.$$

- Evaluasi fitness $f(X_new[i])$.
- Jika $f(X_new[i])$ lebih baik daripada $f(X[i])$, ganti $X[i]$ dengan $X_new[i]$.

- Fase Learning:

- Untuk setiap individu $X[i]$, pilih secara acak individu lain $X[k]$ ($k \neq i$).

- Perbarui $X[i]$ menggunakan rumus:

Jika $f(X[i]) < f(X[k])$:

$$X_new[i][j] = X[i][j] + \text{rand}(0,1) * (X[i][j] - X[k][j]), \text{ untuk } j = 1, 2, \dots, D.$$

Else:

$$X_new[i][j] = X[i][j] + \text{rand}(0,1) * (X[k][j] - X[i][j]), \text{ untuk } j = 1, 2, \dots, D.$$

- Evaluasi fitness $f(X_new[i])$.
- Jika $f(X_new[i])$ lebih baik daripada $f(X[i])$, ganti $X[i]$ dengan $X_new[i]$.

- d. Return solusi terbaik (individu dengan fitness terbaik).

2.4. Prediksi dengan KNN

Berikut adalah pseudocode untuk algoritma K-Nearest Neighbors (KNN) yang digunakan untuk prediksi:

- a. Input:

- Dataset latih (X_train, y_train): X_train adalah fitur, y_train adalah label.
- Data uji (X_test): Data yang akan diprediksi.
- Nilai k : Jumlah tetangga terdekat yang akan dipertimbangkan.

- b. Untuk setiap data uji x_test dalam X_test :

- Hitung jarak antara x_test dan setiap data latih x_train dalam X_train menggunakan metrik jarak.
- Urutkan data latih berdasarkan jarak dari yang terkecil ke terbesar.
- Pilih k data latih terdekat (k-nearest neighbors).
- Hitung frekuensi label dari k tetangga terdekat:
 - Untuk klasifikasi: Prediksi label dengan frekuensi terbanyak.
 - Untuk regresi: Prediksi nilai rata-rata dari label k tetangga terdekat.
- Simpan hasil prediksi untuk x_test .

c. Output:

- Hasil prediksi untuk semua data uji dalam X_{test} .

2.5. Evaluasi Model

Perhitungan nilai RMSE (Root Mean Square Error) dan MAPE (Mean Absolute Percentage Error) digunakan untuk mengetahui seberapa baik model dalam memprediksi nilai sebenarnya, mengidentifikasi potensi bias, serta mengukur tingkat kesalahan prediksi. RMSE mengukur seberapa jauh nilai prediksi dari nilai asli. Persamaan (6) merupakan RMSE.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \dots\dots\dots (6)$$

dimana y_i merupakan nilai asli, $\hat{y}_i$ merupakan nilai prediksi, dan n merupakan jumlah data.

MAPE adalah matrik evaluasi yang digunakan untuk mengukur rata-rata persentase kesalahan antara nilai prediksi dengan nilai aktual. Perhitungan nilai MAPE diperoleh dari rata-rata absolute dari presentase error ditunjukkan pada persamaan (7).

$$MAPE = \frac{1}{M} \sum_{t=1}^M \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad \dots\dots\dots (7)$$

dimana M merupakan jumlah data, y_t adalah nilai hasil aktual, dan $\hat{y}_t$ adalah nilai hasil prediksi.

III. HASIL DAN PEMBAHASAN

3.1. Preprocessing Data

Dataset terdapat variaabel yang masih berupa nilai alphanumeric, maka dilakukan konversi data agar data dapat diolah lebih lanjut. Data yang dikonversi adalah data HVAC Usage, Lighting Usage, Holiday. Data bernilai On/ Yes dikonversi kedalam nilai 1, sedangkan Off/ No dikonversi keddalam nilai 0. Variable DayOfWeek dirubah menjadi Monday= 0, Tuesday= 1, Wednesday= 2, Thursday= 3, Friday= 4, Saturday= 5, Sunday= 6. Tabel 1 merupakan data hasil konversi.

Tabel 1. Data hasil konversi

Timestamp	Temperature	Humidity	Square Footage	Occupancy	HVAC Usage	Lighting Usage	Renewable Energy	DayOf Week	Holiday	Energy Consumption
2022-01-01 00:00:00	25,139	43,432	1565,69 4	5	1	0	2,775	1	0	75,364
2022-01-01 01:00:00	27,732	54,226	1411,06 5	1	1	1	21,831	2	0	83,402

Timestamp	Temperature	Humidity	Square Footage	Occupancy	HVAC Usage	Lighting Usage	Renewable Energy	DayOf Week	Holiday	Energy Consumption
2022-01-01 02:00:00	28,704	58,908	1755,715	2	0	0	6,765	3	0	78,271
2022-01-01 03:00:00	20,08	50,372	1452,316	1	0	1	8,623	6	0	56,52
...	...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...	...
2022-02-11 14:00:00	25,138	31,306	1309,08	3	1	0	20,425	4	1	76,95
2022-02-11 15:00:00	23,051	42,615	1018,141	6	0	1	2,456	2	0	71,545

Setelah dilakukan prapengolahan data, fitur-fitur numerik pada dataset dinormalisasi menggunakan metode Min-Max Scaling. Normalisasi ini bertujuan untuk memastikan semua fitur memiliki skala yang seragam, sehingga tidak ada fitur yang mendominasi proses pemodelan akibat perbedaan rentang nilai yang signifikan. Tabel 2 merupakan data hasil normalisasi min-max scaling.


Tabel 2. Data Hasil Min-Max Scaling

Temperature	Humidity	Square Footage	Occupancy	HVAC Usage	Lighting Usage	Renewable Energy	DayOf Week	Holiday	Energy Consumption
0.514	0.448	0.565	0.556	1.0	0.0	0.092	0.167	0.0	0.481
0.773	0.808	0.4108	0.111	1.0	1.0	0.729	0.333	0.0	0.656
0.870	0.965	0.756	0.222	0.0	0.0	0.226	0.5	0.0	0.544
0.007	0.679	0.452	0.111	0.0	1.0	0.287	1.0	0.0	0.071
...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...
0.514	0.043	0.309	0.333	1.0	0.0	0.682	0.667	1.0	0.516
0.305	0.421	0.018	0.667	0.0	1.0	0.082	0.333	0.0	0.398

3.2. Seleski Fitur dengan TLBO

Hasil pemilihan fitur menggunakan algoritma TLBO menghasilkan fitur terpilih Temperature, SquareFootage, HVACUsage, dan Holiday. Fitur Temperature memiliki korelasi tertinggi sebesar 0.70, yang menandakan hubungan linier positif yang kuat dengan konsumsi energy. Semakin tinggi suhu, maka kebutuhan energi meningkat, terutama pada sistem pendingin ruangan. Fitur HVACUsage juga memperlihatkan korelasi yang moderat sebesar 0.29, yang sesuai dengan logika bahwa sistem pemanas dan pendingin merupakan penyumbang utama konsumsi energi di berbagai bangunan. Sedangkan SquareFootage dan Holiday menunjukkan korelasi yang lebih rendah (sekitar 0.19 dan 0.057), namun tetap relevan secara kontekstual;

luas bangunan memengaruhi beban energi dasar, dan hari libur mempengaruhi pola operasional bangunan. Korelasi antar fitur saji pada Gambar 1.



Gambar 1. *Feature Corelastion Heatmap.*

3.3. Prediksi dengan KNN


Proses prediksi dimulai dengan pemisahan fitur dan target dari dataset yang telah dinormalisasi menggunakan teknik *Min-Max Scaling*. Target prediksi adalah variabel *EnergyConsumption*, sementara fitur input terdiri dari variabel-variabel seperti *Temperature*, *SquareFootage*, *HVACUsage*, *Holiday*, dan lainnya. Model KNN menggunakan parameter k pada model ditetapkan sebesar 5 (default).

Selanjutnya, dilakukan seleksi fitur menggunakan algoritma *Teaching-Learning-Based Optimization* (TLBO). TLBO bekerja dengan meniru proses pembelajaran antara guru dan murid untuk secara iteratif mencari kombinasi fitur terbaik yang meminimalkan kesalahan prediksi (MSE). Fitur yang terpilih adalah *Temperature*, *SquareFootage*, *HVACUsage*, dan *Holiday*, yang kemudian digunakan sebagai input untuk model KNN. Hasil evaluasi menunjukkan bahwa model KNN dengan fitur terpilih memiliki nilai MAPE sebesar 23.15% dan RMSE sebesar 0.1125, lebih baik dibandingkan model dengan seluruh fitur (MAPE 27.62%, RMSE 0.1297). Ini membuktikan bahwa proses seleksi fitur berhasil menyederhanakan model tanpa kehilangan akurasi, bahkan mampu meningkatkan presisi prediksi terhadap konsumsi energi. Hasil prediksi konsumsi energy listrik tersaji pada Tabel 3.

Tabel 3. Hasil Prediksi Konsumsi Energi Listrik.

Actual	Predicted Full Features	Predicted TLBO Features
0,733	0,725	0,646
0,764	0,635	0,615
0,57	0,428	0,514
0,8	0,705	0,73
...	...	...
...	...	...
...	...	...
0,525	0,522	0,406
0,543	0,416	0,452
0,649	0,645	0,704

Model KNN dengan fitur hasil seleksi TLBO menunjukkan kinerja yang stabil dan presisi tinggi, lebih baik dibandingkan model dengan seluruh fitur. Gambar 2 menunjukkan grafik perbandingan hasil prediksi menggunakan semua fitur dan menggunakan pemilihan fitur berbasis metaheuristik seperti TLBO mampu meningkatkan performa model prediksi energi.



Gambar 2. Perbandingan Hasil Prediksi

3.4. Evaluasi Model

Hasil evaluasi menunjukkan bahwa pemilihan fitur menggunakan TLBO mampu meningkatkan kinerja model KNN dalam memprediksi *EnergyConsumption*. Penurunan nilai MAPE sebesar 4.47%, dari 27.62% menjadi 23.15%. RMSE turun sebesar 0.0172 dari 0.1297 menjadi 0.1125, hal ini mengindikasikan peningkatan akurasi dan presisi prediksi. TLBO berhasil mengidentifikasi fitur-fitur paling relevan, sehingga model menjadi lebih efisien tanpa kehilangan performa. Pendekatan ini terbukti efektif dalam mengoptimalkan kualitas

prediksi melalui seleksi fitur yang tepat. Table 3 merupakan hasil evaluasi model prediksi.

Tabel 3. Hasil Evaluasi Model Prediksi

Kondisi	MAPE (%)	RMSE
Sebelum Seleksi Fitur	27.62	0.1297
Sesudah Seleksi Fitur (TLBO)	23.15	0.1125

Penurunan kedua metrik ini mengonfirmasi bahwa TLBO efektif dalam mengeliminasi fitur yang tidak relevan dan mempertahankan fitur-fitur yang memiliki kontribusi signifikan terhadap target prediksi. Hal ini sesuai dengan pernyataan R. Venkata Rao [13] dan Zhibo Zhai dkk, [14] bahwa TLBO selain sederhana, juga mampu memberikan solusi optimum global atau mendekati global dalam jumlah evaluasi fungsi yang relatif lebih sedikit.

IV. KESIMPULAN

Berdasarkan nilai evaluasi model menggunakan MAPE dan RMSE, proses seleksi fitur menggunakan algoritma Teaching-Learning-Based Optimization (TLBO) berhasil meningkatkan kinerja model prediksi EnergyConsumption. Setelah diterapkannya TLBO, nilai MAPE menurun dari 27.62% menjadi 23.15%, menunjukkan adanya peningkatan akurasi sebesar sekitar 4.5% dalam hal kesalahan relatif. Selain itu, RMSE turut menurun dari 0.1297 menjadi 0.1125, yang mengindikasikan bahwa prediksi model menjadi lebih presisi dan lebih mendekati nilai aktual.

DAFTAR PUSTAKA

- [1] A. Yang, W. Li, and X. Yang, "Short-term electricity load forecasting based on feature selection and Least Squares Support Vector Machines," *Knowledge-Based Syst.*, vol. 163, pp. 159–173, 2019, doi: <https://doi.org/10.1016/j.knosys.2018.08.027>.
- [2] L. Pan, S. Wang, J. Wang, M. Xiao, and Z. Tan, "Research on Central Air Conditioning Systems and an Intelligent Prediction Model of Building Energy Load," *Energies*, vol. 15, no. 24, 2022, doi: 10.3390/en15249295.
- [3] S. R. Bhatnagar *et al.*, "An analytic approach for interpretable predictive models in high-dimensional data in the presence of interactions with exposures," *Genet. Epidemiol.*, vol. 42, no. 3, pp. 233–249, 2018, doi: 10.1002/gepi.22112.
- [4] X. Liu, D. Lu, A. Zhang, Q. Liu, and G. Jiang, "Data-Driven Machine Learning in Environmental Pollution: Gains and Problems," *Environ. Sci. Technol.*, vol. 56, no. 4, pp. 2124–2133, Feb. 2022, doi: 10.1021/acs.est.1c06157.
- [5] N. Pudjihartono, T. Fadason, A. W. Kempa-Liehr, and J. M. O'Sullivan, "A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction," *Front. Bioinforma.*, vol. 2, no. June, pp. 1–17, 2022, doi: 10.3389/fbinf.2022.927312.
- [6] P. Ray, S. S. Reddy, and T. Banerjee, "Various dimension reduction techniques for high dimensional data analysis: a review," *Artif. Intell. Rev.*, vol. 54, no. 5, pp. 3473–3515, 2021, doi: 10.1007/s10462-020-09928-0.
- [7] D. Eko Waluyo *et al.*, "Implementasi Algoritma Regresi pada Machine Learning untuk Prediksi Indeks Harga Saham Gabungan," *J. Inform. J. Pengemb. IT*, vol. 9, no. 1, pp. 12–17, 2024.
- [8] O. H. Kombo, S. Kumaran, Y. H. Sheikh, A. Bovim, and K. Jayavel, "Long-term groundwater

- level prediction model based on hybrid KNN-RF technique," *Hydrology*, vol. 7, no. 3, pp. 1–24, 2020, doi: 10.3390/HYDROLOGY7030059.
- [9] F. Li and G. Jin, "Research on power energy load forecasting method based on KNN," *Int. J. Ambient Energy*, vol. 43, no. 1, pp. 946–951, 2022, doi: 10.1080/01430750.2019.1682041.
- [10] L. Abualigah *et al.*, "5 - Teaching-learning-based optimization algorithm: analysis study and its application," L. B. T.-M. O. A. Abualigah, Ed., Morgan Kaufmann, 2024, pp. 59–71. doi: <https://doi.org/10.1016/B978-0-443-13925-3.00016-9>.
- [11] E. Akbari, G. Mojtaba, G. Milad, R. Abolfazl, and S. and Andrew Gadsden, "Optimal Power Flow via Teaching-Learning-Studying-Based Optimization Algorithm," *Electr. Power Components Syst.*, vol. 49, no. 6–7, pp. 584–601, Feb. 2022, doi: 10.1080/15325008.2021.1971331.
- [12] M. A. Eirgash, "Optimization of time–cost–quality–CO2 emission trade-off problems via super oppositional TLBO algorithm," *Asian J. Civ. Eng.*, vol. 26, no. 4, pp. 1743–1755, 2025, doi: 10.1007/s42107-025-01282-2.
- [13] R. Venkata Rao, "Review of applications of tlbo algorithm and a tutorial for beginners to solve the unconstrained and constrained optimization problems," *Decis. Sci. Lett.*, vol. 5, no. 1, pp. 1–30, 2016, doi: 10.5267/j.dsl.2015.9.003.
- [14] Z. Zhai, Y. Dai, and Y. Xue, "A Novel Teaching-Learning-Based Optimization with Laplace Distribution and Experience Exchange," *Math. Probl. Eng.*, vol. 2022, 2022, doi: 10.1155/2022/4177405.
- [15] L. B. Becker, M. Gergeleit, S. Schemmer, and E. Nett, "Using a flexible real-time scheduling strategy in a distributed embedded application," in *IEEE International Conference on Emerging Technologies and Factory Automation, ETFA*, Apr. 2003, pp. 652–657. doi: 10.1109/ETFA.2003.1248760.