

## IMPLEMENTASI METODE ELBOW DAN K-MEANS CLUSTERING UNTUK MENGETAHUI KAPASITAS SOLAR PANEL

*Maria Mediatrix Sebatubun<sup>1</sup>, Adiyuda Prayitna<sup>2</sup>*

<sup>1,2</sup>Universitas Teknologi Digital Indonesia  
Jalan Raya Janti 143, Karangjambe, Banguntapan, Yogyakarta

*Email: <sup>1</sup>memey@utdi.ac.id, <sup>2</sup>yudha\_pr@utdi.ac.id*

### ABSTRAK

Menurut data pertumbuhan listrik, konsumsi listrik di Indonesia terus mengalami peningkatan. Pada tahun 2015 konsumsi listrik 910 kilowat jam (kWh) per kapita, kemudian meningkat menjadi 1.084 kWh/kapita pada tahun 2019. Saat ini Indonesia masih mengandalkan pembangkit thermal yaitu pembangkit dengan sumber energi utama berasal dari bahan bakar minyak, gas dan batubara. Dengan meningkatnya konsumsi listrik, perlu adanya peningkatan kapasitas pembangkit. Indonesia memiliki potensi pengembangan energi baru dan terbarukan untuk pengembangan pembangkit listrik Tenaga Matahari, karena letak Indonesia di daerah tropis dimana sinar matahari hampir bersinar sepanjang tahun.

Penelitian ini melakukan analisa untuk mengetahui seberapa besar kapasitas tenaga yang diperoleh *solar panel* yang terpasang, sehingga mampu memenuhi kebutuhan pada saat terjadi mendung dan hujan dalam waktu yang relatif lama. Data yang digunakan yaitu data yang dikumpulkan selama 2 hari dengan interval waktu pengumpulan setiap 15 detik. Penelitian dilakukan dengan praproses, kemudian mencari nilai k *cluster* menggunakan metode Elbow, setelah itu tahap *clustering* menggunakan metode k-means. Hasil penelitian menunjukkan bahwa kapasitas terbesar yang diperoleh *solar panel* adalah sekitar 680Watt, sedangkan kapasitas terkecil yaitu sekitar 17Watt.

**Keywords:** *Clustering, Elbow, K-Means, Solar Panel.*

### ABSTRACT

*According to electricity growth data, electricity consumption in Indonesia continues to increase. In 2015 electricity consumption was 910 kilowatt hours (kWh)/capita, then increased to 1,084 kWh/capita in 2019. Currently, Indonesia still relies on thermal power plants whose main energy sources come from fuel oil, gas and coal. With increasing electricity consumption, it is necessary to increase generating capacity. Indonesia has the potential to develop new and renewable energy, because Indonesia is located in the tropics where the sun shines almost all year round.*

*This study aims to determine how much power capacity is obtained by solar panels, so it can meet the demand when it is cloudy and raining for a relatively long time. The data used is data collected for 2 days with an interval of collection every 15 seconds. The research was carried out by preprocessing, then looking for k cluster values using the Elbow method, after that the clustering stage used the k-means method. The results showed that the largest capacity obtained by solar panels was around 60 Watts, while the smallest capacity was around 17 Watts.*

**Keywords:** *Clustering, Elbow, K-Means, Solar Panel.*

### 1. PENDAHULUAN

Kebutuhan energi listrik di Indonesia dari tahun ke tahun mengalami peningkatan. Pada tahun 2015 konsumsinya sekitar 910 kilowat jam (kWh) per kapita, kemudian meningkat menjadi 1.084 kWh/kapita pada tahun 2019. Peningkatan ini sejalan dengan rasio elektrifikasi yang juga menunjukkan kenaikan. Rasionya dari 84,35% pada tahun 2014 menjadi 98,89% pada tahun 2019 [1]. Kenaikan konsumsi listrik salah satunya dipengaruhi oleh

meningkatnya penggunaan peralatan elektronik khususnya elektronik rumah tangga. Saat ini, masyarakat mulai menggantikan peralatan rumah tangga konvensional menjadi elektronik, seperti penggunaan kompor listrik/induksi, *air fryer*, oven listrik, *blender*, *mixer*, dan peralatan rumah tangga lainnya. Tidak hanya peralatan rumah tangga, saat ini masyarakat juga mulai beralih dari kendaraan konvensional ke kendaraan listrik. Dengan adanya kenaikan konsumsi listrik ini perlu diikuti dengan peningkatan kapasitas pembangkit.

Saat ini Indonesia masih mengandalkan pembangkit thermal yaitu pembangkit dengan sumber energi utama berasal dari bahan bakar minyak, gas dan batubara. Dalam dua tahun terakhir, Pemerintah Republik Indonesia telah memberikan isyarat akan memulai peralihan dari pembangkit listrik batubara (PLTU) ke pembangkit listrik sumber energi baru dan terbarukan. Namun demikian ketiadaan pembangkit nuklir dan rendahnya kapasitas Pembangkit Listrik Tenaga Air (PLTA), proses perubahan pembangkit listrik dari sumber energi thermal menjadi pembangkit listrik energi baru terbarukan masih belum bisa direalisasikan. Hal ini dapat mengancam keberlangsungan penyediaan energi listrik di Indonesia yang semakin meningkat. Sebenarnya, Indonesia memiliki potensi pengembangan energi baru dan terbarukan. Letak Indonesia di daerah tropis dimana sinar matahari hampir bersinar sepanjang tahun, memiliki potensi signifikan untuk pengembangan pembangkit listrik Tenaga Matahari (*Solar Photovoltaics*). Indonesia mendapatkan intensitas penyinaran matahari sebesar 3,6 – 6 kWh/M<sup>2</sup>/hari setara dengan kapasitas pembangkitan 1.170 – 1.530 kWh/kWp. Dengan adanya potensi tersebut akan membantu dalam arah pengembangan energi baru terbarukan di Indonesia. Namun demikian potensi tersebut perlu untuk didalami, mengingat Indonesia memiliki 2 (dua musim) yaitu musim kemarau dan musim penghujan. Terkadang, kedua musim ini tidak merata sepanjang tahun, ada masa-masa dimana lamanya sinar matahari sangat pendek. Masa-masa ini perlu diketahui, agar dapat diatur konsumsinya, supaya tetap bisa memenuhi kebutuhan utama.

Penelitian ini akan melakukan *clustering* data dari *solar panel* yang dipasang pada atap rumah untuk mengetahui besar kapasitas tenaga matahari yang diperoleh, sehingga nantinya dapat dihitung besar tenaga listrik yang dapat digunakan untuk kebutuhan sehari-hari. Proses penelitian diawali dengan praproses data untuk menyiapkan data agar siap diproses, kemudian mengimplementasikan metode Elbow untuk mencari jumlah k *cluster* terbaik. Selanjutnya, *clustering* menggunakan k-means.

## 2. TINJAUAN PUSTAKA

Terdapat beberapa penelitian terkait dengan analisis pembangkitan solar panel dengan

tujuan yang berbeda-beda. Salah satunya adalah [2] penelitian yang mengimplementasikan analisis *clustering* dalam prediksi pembangkit listrik energi matahari (*photovoltaic*) berbasis Neural Network. Berdasarkan tiga jenis cuaca yaitu cerah, berawan, dan hujan. Penelitian ini mengambil sampel data historis dengan metode analisis *clustering*. Setelah proses penyaringan, tahap selanjutnya yaitu menerapkan model prediksi yaitu neural network dengan algoritma backpropagation menggunakan data hasil penyaringan sebagai data latih. Kemudian membandingkan enam jenis model prediksi pembangkit listrik tenaga matahari sebelum dan sesudah penyaringan data. Hasil menunjukkan bahwa menggabungkan analisis *clustering* dan neural network adalah metode yang efektif untuk meningkatkan prediksi presisi pembangkit listrik tenaga matahari.

Penelitian lain juga dilakukan menggunakan teknik *clustering* untuk pengelompokan energi sinar matahari menggunakan metode *Conventional* dan *Swarm Clustering* [3]. Penelitian ini dilakukan menggunakan sekumpulan metode *clustering* dari beberapa kategori yang berbeda untuk menentukan jumlah *cluster* optimal untuk pola data energi sinar matahari. Penelitian ini mengusulkan metode optimasi bio-inspired Ant Colony and Bat. Selanjutnya, untuk mengetahui metode *clustering* yang efisien, maka terdapat enam algoritma *clustering* yang digunakan yaitu K-means, Hierarchical, Fuzzy C-means, Self-Organizing Maps, dan Ant Colony and Bat. Untuk evaluasi, terdapat sembilan metode evaluasi validitas digunakan yaitu Davies Bouldin, Dunn, Sihhouette, Bayesian Information Criterion, Xie-Beni, Mean Square Error, clustering dispersion indicator, mean index adequacy, dan rasio sum of squares. Hasil *clustering* menunjukkan bahwa metode bio-inspired sebanding dengan metode konvensional dan algoritma Bat adalah yang paling efisien dan mengungguli metode *clustering* lainnya.

Penelitian lain juga melakukan peramalan terhadap energi matahari menggunakan teknik *clustering* [4]. Penelitian ini melakukan prediksi energi matahari *photovoltaic* untuk hari berikutnya dengan menggunakan data energi matahari dan cuaca sebelumnya. Beberapa metode *clustering* diusulkan, dengan mengelompokkan hari berdasarkan data cuaca dan kemudian membangun model prediksi terpisah untuk setiap *cluster* menggunakan data energi matahari. Selanjutnya, metode yang

diusulkan dibandingkan dengan metode berbasis non-clustering yang membangun model prediksi tunggal untuk semua jenis hari. Tahap selanjutnya yaitu melakukan evaluasi secara komprehensif menggunakan data baru untuk dua tahun. Hasil menunjukkan bahwa model prediksi yang paling akurat adalah clustering berbasis Nearest Neighbor yang menggunakan data vector dari penyinaran matahari selama setengah jam.

Penelitian yang menggunakan teknik clustering juga dilakukan [5] untuk peramalan *Global Horizontal Irradiance* (GHI) jangka pendek. Metodologi terdiri dari tiga bagian yaitu, *time series unsupervised learning*, pengenalan pola, dan peramalan berbasis *Unsupervised Clustering* (UC). Tahap pertama, rangkaian waktu GHI harian dikelompokkan menggunakan metode Optimized Cross-validated Clustering (OCCUR), yang menentukan jumlah cluster optimal dan hasil clustering terbaik. Kemudian Support Vector Machine diterapkan untuk mengenali kategori hari tertentu menggunakan data beberapa jam pertama dalam tahap peramalan. Peramalan GHI diperoleh dari model yang paling sesuai di cluster yang berbeda, yang dibangun menggunakan kerangka kerja two-layer Machine Learning based Multi-modal (M3). Metodologi berbasis UC yang dikembangkan, kemudian divalidasi dengan menggunakan data 1 tahun dengan enam fitur. Hasil yang diperoleh menunjukkan bahwa: model berbasis UC lebih unggul 20% dibanding model non-UC dengan arsitektur M3 yang sama, model berbasis M3 juga mengungguli model single-algorithm machine learning sekitar 20%.

Penelitian lain [6] juga melakukan analisis terhadap tingkat efisiensi energi dalam penerapan *solar panel* pada atap rumah tinggal. Penelitian tersebut bertujuan untuk mengetahui solusi yang efektif dalam penerapan panel surya pada 2 tipe rumah yang berbeda, dilihat dari aspek ekonomi, efisiensi energi, dan usaha mengurangi CO<sub>2</sub> dengan menggunakan panel surya. Hasil dari analisis yang dilakukan dalam 25 tahun kedepan dengan cara membandingkan antara penggunaan listrik panel surya dengan penggunaan listrik PLN pada rumah tipe 62m<sup>2</sup> dapat menghemat biaya sebesar Rp 172.813.581,13 dan dapat mengurangi emisi CO<sub>2</sub> hingga 64,23%. Untuk tipe rumah 86m<sup>2</sup> dapat menghemat biaya sebesar Rp. 255.134.657,60 dan dapat mengurangi emisi CO<sub>2</sub> hingga 79,69%.

## 2.1 Metode Elbow

Metode Elbow merupakan suatu metode yang digunakan untuk menghasilkan informasi dalam menentukan jumlah *cluster* terbaik dengan cara melihat persentase hasil perbandingan antara jumlah *cluster* yang akan membentuk siku pada suatu titik [7]. Hasil persentase yang berbeda dari setiap nilai *cluster* dapat ditunjukkan dengan menggunakan grafik sebagai sumber informasinya. Gambar 1 mengilustrasikan metode Elbow [8], dimana jika nilai *cluster* pertama dengan nilai *cluster* kedua memberikan sudut dalam grafik atau nilainya mengalami penurunan paling besar maka nilai *cluster* tersebut yang terbaik [9]. Untuk mendapatkan perbandingannya adalah dengan menghitung SSE (*Sum of Square Error*) dari masing-masing nilai *cluster*. Karena semakin besar jumlah *cluster* K maka nilai SSE akan semakin kecil [10]. SSE dapat dihitung menggunakan (1)[11].

$$SSE = \sum_{K=1}^K \sum_{X_i} \|x_i - C_k\|^2 \quad (1)$$

dimana  $K = \text{cluster ke-}c$ ,  $X_i$  merupakan jarak data obyek ke- $i$ , dan  $C_k$  adalah pusat cluster ke- $i$ .

Algoritma metode Elbow dalam menentukan nilai K pada K-means .

1. Mulai
2. Insialisasi awal nilai K
3. Naikkan nilai K
4. Hitung hasil SSE dari tiap nilai K
5. Melihat hasil SSE dari nilai K yang turun secara drastic
6. Tetapkan nilai K yang berbentuk siku
7. Selesai

## 2.2 K-Means

K-means merupakan salah satu metode pengelompokan data non hierarki (sekatian) yang berusaha mempartisi data ke dalam kelompok sehingga data berkarakteristik sama dimasukkan ke dalam satu kelompok yang sama dan data yang berkarakteristik berbeda dikelompokkan ke dalam kelompok yang lain [12]. Pengelompokan data menggunakan metode k-means ini dilakukan dengan algoritma sebagai berikut:

1. Tentukan pusat *cluster* secara acak :  $c_{ik}$  ( $i =$

- cluster ke-*I*,  $k = \text{feature ke } k$
2. Hitung jarak setiap data yang ada terhadap setiap pusat *cluster*, misal data pertama terhadap pusat *cluster* pertama, data pertama terhadap pusat *cluster* kedua, dan data pertama terhadap pusat *cluster* ketiga.
  3. Suatu data akan menjadi anggota dari suatu *cluster* yang memiliki jarak terdekat dari pusat *clusternya*.
  4. Perbarui pusat *cluster*: dapat dihitung dari rerata anggota-anggotanya dari iterasi terakhir.
  5. Ulangi menghitung kembali jarak tiap data dengan pusat *cluster* baru. Lakukan terus menerus sampai pusat *cluster* tidak berubah lagi.

Pada langkah 1, lokasi titik pusat *cluster* (*centroid*) setiap kelompok yang diambil dari rata-rata semua nilai data pada setiap fiturnya harus dihitung kembali. Jika  $M$  menyatakan jumlah data dalam sebuah kelompok,  $i$  menyatakan fitur ke- $i$  dalam sebuah kelompok, dan  $p$  menyatakan dimensi data, untuk menghitung *centroid* fitur ke- $i$  dapat menggunakan (2)

$$C_i = \frac{1}{M} \sum_{j=1}^M x_j \quad (2)$$

Langkah selanjutnya, hitung jarak setiap data terhadap pusat cluster dengan menggunakan (3).

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (3)$$

Kemudian kelompokan data ke dalam cluster dengan jarak terpendek menggunakan (4).

$$a_{i1} = \begin{cases} 1 & d \min \{D(x_i, c_1)\} 0 \end{cases} \quad (4)$$

Dimana  $a_{i1}$  adalah nilai keanggotaan titik  $x_i$  ke pusat cluster  $C_1$ ,  $d$  adalah jarak terpendek dari data  $x$  ke  $K$  kelompok setelah dibandingkan dan  $C_1$  adalah *centroid* ke- $i$ .

### 3. METODE PENELITIAN

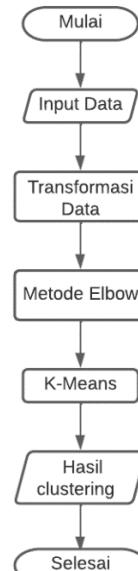
Penelitian ini terdiri dari beberapa tahap yaitu pengumpulan data, praproses, mencari nilai  $k$  *cluster* dan mengimplementasikan Teknik *clustering*.

#### 3.1 Sumber Data dan Teknik Pengumpulan Data

Penelitian ini menggunakan data yang didapat dari *solar panel* yang dipasang di atap, dengan sudut  $45^\circ$  menghadap ke barat, dengan kapasitas 300Wp. Pengumpulan data dilakukan dengan melakukan *data logging* direkam pada *TimeSeries Database*. Jumlah data yang digunakan yaitu data selama 2 hari dengan interval pengambilan data setiap 15 detik. Sistem pengendali pengisian aki menggunakan MPPt. Jumlah data yang digunakan adalah 200 data (diambil data sampel) dengan menggunakan atribut *pvpower* dan *time*. Logger pengambilan data menggunakan Coordinated Universal Time (UTC) sehingga jika dikonversi ke WIB, maka waktu UTC+7.

### 3.2 Rancangan Penelitian

Berikut alur penelitian yang ditunjukkan pada Gambar 2.



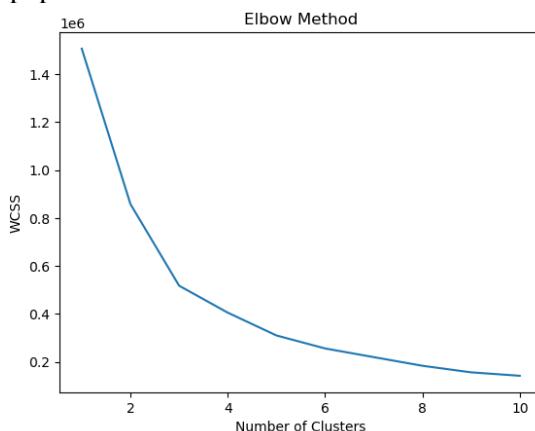
Gambar 1. Alur penelitian

Data yang digunakan sebagai masukkan adalah data yang diperoleh dari Solar Panel yang dikumpulkan selama 2 hari yang diambil setiap 15 detik. Data tersebut kemudian ditransformasi menjadi file \*.csv. Atribut yang digunakan adalah *time* dan *pvpower*. Atribut *time* terdiri dari *hour*, *minute* dan *second*. Oleh karena itu, perlu ditransformasi lagi menjadi tiga atribut yang berbeda sehingga atribut yang digunakan sebagai input yaitu *hour*, *minute*, *second* dan *pvpower*. Proses ini dilakukan agar data tersebut dapat dikenali di tools yang digunakan dalam penelitian, yaitu Python dengan editor Jupyter Notebook. Tahap

selanjutnya yaitu menerapkan metode Elbow untuk mencari jumlah *cluster* terbaik. Selanjutnya data dikelompokkan menggunakan metode K-means. Hasil *clustering* ini kemudian dievaluasi untuk mengetahui waktu kapan saja *solar panel* mendapatkan energi matahari paling banyak.

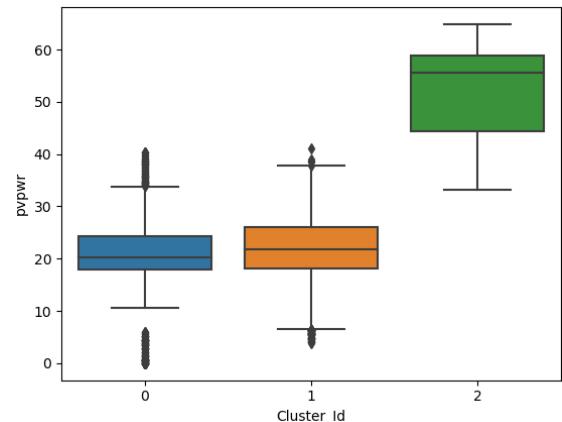
#### 4. PEMBAHASAN

Pada bagian pembahasan tuliskan hasil analisis, temuan penelitian, dan pembahasannya secara ilmiah. Sertakan juga data-data yang menunjang hasil tersebut. Penelitian diawali dengan pengumpulan data, kemudian dilanjutkan dengan proses transformasi data yaitu memisahkan atribut *time* menjadi tiga atribut yang berbeda yaitu *minute*, *hour* dan *second*. Proses ini dilakukan untuk mempermudah proses klastering karena atribut *time* ini terdiri dari *hour*, *minute* dan *second*. Oleh karena itu, perlu dipisahkan menjadi atribut yang berbeda. Tahap selanjutnya adalah mencari jumlah *cluster* terbaik berdasarkan atribut *minute* dan *pvpower*. Hasil yang diperoleh dapat dilihat pada Gambar 2 dimana grafik mengalami patahan atau memberikan sudut dalam grafik (nilainya mengalami penurunan paling besar) yang membentuk *elbow* atau siku pada saat  $k=3$ , maka dapat disimpulkan nilai  $k$  optimal adalah pada saat  $k=3$ . Selanjutnya yaitu melakukan *clustering* menjadi 3 kelas menggunakan atribut *minute* dan *pvpower*.



Gambar 2. Hasil pencarian jumlah *cluster* (atribut *minute* dan *pvpower*)

Hasil klasterisasi ini dapat dilihat pada Gambar 3, dimana *cluster* 3 menunjukkan posisi paling tinggi dengan perolehan kurang lebih 45 – 60 Watt. Hal ini menandakan bahwa *cluster* 3 dapat memperoleh tenaga matahari yang paling banyak dibanding *cluster* 2 dan *cluster* 1.



Gambar 3. Hasil *Clustering* berdasarkan atribut *minute* dan *pvpower*

Hasil yang diperoleh menunjukkan *cluster* 3 memiliki posisi paling tinggi dibandingkan dengan *cluster* 1 dan 2, dengan perolehan kurang lebih 45 – 60 Watt. Sementara *cluster* 1 hanya memperoleh sekitar 17 – 25 Watt, dan *cluster* 2 memperoleh sekitar 18 – 26 Watt. Kemudian, uji coba juga dilakukan dengan menggunakan atribut *Hour* dan *pvpower*. Dari hasil metode Elbow menggunakan kedua atribut ini, diperoleh jumlah  $k$  klaster=2. Tahap selanjutnya yaitu melakukan *clustering* menggunakan atribut *minute* dan *pvpower* dan diperoleh *cluster* 2 yang lebih tinggi dibanding *cluster* 1.

Berdasarkan hasil yang diperoleh tersebut, dapat dilihat bahwa jumlah tenaga matahari paling besar yang diperoleh *solar panel* yaitu kurang lebih 45 – 60 Watt. Sedangkan pada *cluster* 1, *solar panel* memperoleh sekitar 17 – 25 Watt.

#### 5. KESIMPULAN

Berdasarkan hasil penelitian, dengan menggunakan data yang dikumpulkan selama 2 hari dengan interval pengambilan data setiap 15 detik, dapat disimpulkan bahwa jumlah tenaga matahari maksimal yang dapat diperoleh adalah 60 Watt. Sementara, jumlah tenaga matahari paling sedikit yang diperoleh yaitu 17 Watt.

Untuk penelitian selanjutnya, sebaiknya dapat menambah jumlah data dan dapat mengetahui rentang waktu atau jam berapa saja *solar panel* mendapatkan tenaga matahari paling banyak.

**DAFTAR PUSTAKA**

- [1] “databoks.katadata.co.id,” 2021. <https://databoks.katadata.co.id/>
- [2] K. Cheng, L. M. Guo, Y. K. Wang, and M. T. Zafar, “Application of clustering analysis in the prediction of photovoltaic power generation based on neural network,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 93, no. 1, 2017, doi: 10.1088/1755-1315/93/1/012024.
- [3] A. A. Munshi and Y. A. R. I. Mohamed, “Photovoltaic power pattern clustering based on conventional and swarm clustering methods,” *Sol. Energy*, vol. 124, pp. 39–56, 2016, doi: 10.1016/j.solener.2015.11.010.
- [4] Z. Wang, I. Koprinska, and M. Rana, “Clustering based methods for solar power forecasting,” in *Proceedings of the International Joint Conference on Neural Networks*, 2016, vol. 2016-Octob, no. July, pp. 1487–1494. doi: 10.1109/IJCNN.2016.7727374.
- [5] C. Feng, M. Cui, B.-M. Hodge, S. Lu, H. F. Hamann, and J. Zhang, “An Unsupervised Clustering-Based Short-Term Solar Forecasting Methodology Using Multi-Model Machine Learning Blending,” *Comput. Sci. Math.*, pp. 1–11, 2018, doi: <https://doi.org/10.48550/arXiv.1805.04193>.
- [6] E. Sulistiawati and B. E. Yuwono, “Analisis Tingkat Efisiensi Energi dalam Penerapan Solar Panel Pada Atap Rumah Tinggal,” in *Prosiding Seminar Intelektual Muda #2, Peningkatan Kualitas Hidup dan Peradaban Dalam Konteks IPTEKSEN*, 2019, no. 9, pp. 325–330.
- [7] A. T. Rahman, Wiranto, and A. Rini, “Coal Trade Data Clustering Using K-Means (Case Study Pt. Global Bangkit Utama),” *ITSMART J. Teknol. dan Inf.*, vol. 6, no. 1, pp. 24–31, 2017, doi: DOI: <https://doi.org/10.20961/itsmart.v6i1.11296>.
- [8] T. M. Kodinariya and D. P. R. Makwana, “Review on determining of cluster in K-means clustering,” *Int. J. Adv. Res. Comput. Sci. Manag. Stud.*, vol. 1, no. 6, pp. 90–95, 2013, [Online]. Available: [www.ijarcsms.com](http://www.ijarcsms.com)
- [9] N. Putu, E. Merliana, and A. J. Santoso, “Analisa Penentuan Jumlah Cluster Terbaik pada Metode K-Means,” in *Seminar Nasional Multi Disiplin Ilmu & Call for Papers UNISBANK*, 2015, pp. 978–979. [Online]. Available: [https://unisbank.ac.id/ojs/index.php/sendi\\_u/article/view/3333](https://unisbank.ac.id/ojs/index.php/sendi_u/article/view/3333)
- [10] N. T. Hartanti, “Metode Elbow dan K-Means Guna Mengukur Kesiapan Siswa SMK Dalam Ujian Nasional,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 6, no. 2, pp. 82–89, 2020, doi: 10.25077/teknosi.v6i2.2020.82-89.
- [11] D. A. I. C. Dewi and D. A. K. Pramita, “Analisis Perbandingan Metode Elbow dan Silhouette pada Algoritma Clustering K-Medoids dalam Pengelompokan Produksi Kerajinan Bali,” *Matrix J. Manaj. Teknol. dan Inform.*, vol. 9, no. 3, pp. 102–109, 2019, doi: 10.31940/matrix.v9i3.1662.
- [12] E. Prasetyo, *Data Mining : Konsep dan Aplikasi menggunakan MATLAB*, 1st ed. Yogyakarta: ANDI, 2012.