

PENGOPTIMALAN PENGUKURAN BREGMAN DIVERGENCES MENGUNAKAN DAVIES BOULDIN INDEX

Deny Jollyta¹⁾, Muhammad Siddik²⁾, Johan³⁾, Gustientiedina⁴⁾

¹⁻⁴ Fakultas Ilmu Komputer, Institut Bisnis dan Teknologi Pelita Indonesia, Jl. Jend. Ahmad Yani No. 78-88
Pekanbaru

email: ¹⁾deny.jollyta@lecturer.pelitaindonesia.ac.id, ²⁾siddik@lecturer.pelitaindonesia.ac.id,
³⁾johan@lecturer.pelitaindonesia.ac.id, ⁴⁾gustientiedina@lecturer.pelitaindonesia.ac.id

Abstract

These Determination of the optimal clusters is often ambiguous because it results from several groups. The selection of information from which groups will be used by users becomes a separate problem because it involves policymaking. Davies Bouldin Index (DBI) is a cluster evaluation technique to determine the optimal number of clusters and is supported by appropriate distance measurements. This study aims to obtain that clusters through the DBI technique applied to the measurement of Bregman Divergences, Mahalano and Square Euclidean Distance, using K-Means and K-Medoids algorithms. The test results are shown through several indicators used as benchmarks to understand the performance of Bregman Divergences in determining the number of clusters such as correlation, cluster algorithm used, DBI pattern, DBI results, k-optimal and time needed for testing. Through both clustering algorithms, the Mahalano distance can produce consistent grouping patterns and the Square Euclidean Distance measuring technique successfully showed the best performance of the DBI which places k = 2 as the optimal cluster, the lowest DBI value of 0.882 and 1,030 in the test time for 0 seconds.

Keywords: Optimal Cluster, Bregman Divergences, DBI

Abstrak

Penentuan cluster optimal ini seringkali ambigu karena dihasilkan dari beberapa kelompok. Pemilihan informasi dari kelompok mana yang akan digunakan oleh pengguna menjadi masalah tersendiri karena menyangkut pembuatan kebijakan. Davies Bouldin Index (DBI) merupakan teknik evaluasi cluster untuk menentukan jumlah cluster yang optimal dan didukung dengan pengukuran jarak yang tepat. Penelitian ini bertujuan untuk mendapatkan cluster melalui teknik DBI yang diterapkan pada pengukuran Bregman Divergences, Mahalano dan Square Euclidean Distance, menggunakan algoritma K-Means dan K-Medoids. Hasil pengujian ditunjukkan melalui beberapa indikator yang digunakan sebagai tolak ukur untuk mengetahui kinerja Bregman Divergences dalam menentukan jumlah cluster seperti korelasi, algoritma cluster yang digunakan, pola DBI, hasil DBI, k-optimal dan waktu yang dibutuhkan untuk pengujian. Melalui kedua algoritma clustering tersebut, jarak Mahalano dapat menghasilkan pola pengelompokan yang konsisten dan teknik pengukuran Square Euclidean Distance berhasil menunjukkan performa DBI terbaik yang menempatkan k=2 sebagai cluster optimal, nilai DBI terendah sebesar 0,882 dan 1,030 pada waktu pengujian. selama 0 detik.

Keywords: Cluster Optimal, Bregman Divergences, DBI

1. PENDAHULUAN

Optimalisasi jumlah *cluster* selalu dimulai dengan pengelompokan data menggunakan algoritma *clustering*. Umumnya beberapa teknik evaluasi *cluster* di berbagai penelitian menggunakan algoritma *K-Means* karena dianggap mudah diterapkan pada berbagai

masalah pengelompokan (Sari, 2021). Sebagai salah satu teknik yang dapat menentukan jumlah *cluster* yang optimal, Davies Bouldin Index (DBI) dapat diterapkan pada berbagai algoritma *clustering* (Sureja et al., 2022), seperti *K-Means* (Tempola & Assagaf, 2018) dan *K-Medoid* (Siregar et al., 2023). *K-Means* merupakan algoritma yang membagi jumlah objek menjadi sejumlah *cluster* dimana tingkat kesamaan anggota dalam suatu *cluster*

tinggi sedangkan tingkat kesamaan antar *cluster* sangat rendah (Dubey et al., 2018). Pada penelitian (Sureja et al., 2022) dan (Pathak & Lal, 2017), *K-Means* dan *K-Medoids* terbukti dapat mengatasi masalah pengelompokan dengan jumlah data yang sangat besar dan bervariasi. *K-Medoids* merupakan pengembangan dari algoritma *K-Means* dengan menjadikan *centroid* sebagai objek yang sudah ada dan dikenal dengan *medoid*. *Medoid* menggantikan rata-rata dalam perhitungan *K-Means* sehingga berkinerja lebih baik (Adepeju et al., 2021). Beberapa penelitian menunjukkan bahwa *K-Medoids* dapat bekerja pada data yang besar dan bervariasi (Sun et al., 2018), (Wibowo et al., 2019).


Beberapa penelitian terdahulu yang telah ditunjukkan di atas, menggunakan rumus *Euclidean Distance*. Pada penelitian ini, untuk pengelompokan yang baik dan tepat, algoritma *clustering* juga dapat didukung dengan teknik pengukuran jarak lainnya seperti *Bregman Divergences*. *Bregman Divergences* digunakan untuk berbagai algoritma dalam analisis numerik dan analisis konvergensi metode numerik dan algoritma (Sprung, 2019), seperti pada penelitian (Edelsbrunner & Wagner, 2017) yang menghasilkan analisis topologi data dengan jarak tertentu. Teknik *Bregman Divergences* memiliki beberapa alat ukur untuk menghasilkan jarak, seperti *Mahalano* dan *Square Euclidean Distance (SED)*. Penelitian (Martino et al., 2017) menunjukkan kinerja terbaik *Mahalano* dalam mengelompokkan data multivariat menggunakan *K-Means* dan hasilnya ditampilkan dalam bentuk kurva pertumbuhan. *Mahalano* memberikan informasi tentang pengukuran kesamaan dan perbedaan dalam data dimensi tinggi dan rendah (Ghorbani, 2019). Untuk implementasi SED, (Hossain & Abufardeh, 2019) menggunakan SED pada penyelesaian masalah struktur k-consensus dalam skema aproksimasi polinomial-waktu dan menghasilkan perhitungan data vertikal yang diterapkan pada algoritma *pTrees*.

Berdasarkan beberapa penelitian yang ada, *Bregman Divergences* umumnya digunakan untuk menghasilkan ukuran jarak suatu objek tetapi tidak sampai mengetahui pengelompokan yang terbaik. Studi ini berkontribusi dalam penentuan jumlah *cluster* optimal melalui teknik DBI yang diterapkan

pada pengukuran Jarak *Mahalano* dan SED menggunakan algoritma *K-Means* dan *K-Medoids*. Performansi pengukuran jarak ini dianalisis dari *cluster* optimal yang dihasilkan DBI melalui indikator korelasi, algoritma *cluster* yang digunakan, pola DBI, hasil DBI, k-optimal dan waktu yang dibutuhkan untuk pengujian. Hasil ini dapat menjadi kontribusi penelitian karena diharapkan menjadi acuan dalam memahami kinerja DBI yang diterapkan pada teknik pengukuran *Bregman Divergences*.

2. METODE PENELITIAN

Jumlah *cluster* yang optimal diperoleh melalui pengukuran *Bregman Divergences* dengan beberapa tahapan seperti pada Gambar 1.



Gambar 1. Tahapan penelitian

2.1 PERSIAPAN DATA

Penelitian diawali dengan persiapan data untuk memperlihatkan kinerja algoritma dan pengukuran *Bregman Divergences*. Persiapan data mengikuti tahapan *Knowledge Discovery in Database (KDD)*. Data yang digunakan sebagai dataset adalah data *stunting* dengan atribut berikut (The Ministry of Health, 2018):

Tabel 1. Deskripsi Atribut Data

No	Atribut	Deskripsi
1	Kondisi calon ibu	Terdiri dari kecukupan gizi calon ibu, postur calon ibu, jarak kehamilan, usia
2	Usia	Terdiri dari usia terlalu tua, terlalu muda dan cukup umur
3	Jarak kehamilam	Setiap tahun atau lebih dari 2 tahun
4	Postur calon ibu	Postur ideal atau pendek

5	Kondisi ekonomi	Tidak mampu, cukup, dan ideal
6	Kondisi sosial	Terdiri dari keadaan sanitasi dan keamanan pangan
7	Gizi bayi	Terdiri dari inisiasi menyusui dini (IMD), gagal ASI eksklusif, penyapihan dini dan makanan pendamping ASI (MP-ASI)
8	Kesakitan pada bayi	Terdiri dari gangguan kognitif, motorik dan gangguan verbal

2.2 PROSES DATA

Tahap kedua adalah memproses data menggunakan algoritma *K-Means* dan *K-Medoids* dengan pengukuran *Bregman Divergences* yang dipilih adalah *Mahalano* dan *SED*. Sejumlah k uji digunakan untuk mendapatkan perfoma pengukuran *Bregman Divergences*. Selanjutnya hasil *cluster* dari algoritma, dioptimasi menggunakan DBI.

Algoritma *K-Means* merupakan algoritma yang didasarkan pada model *centroid* yang sudah dikenal dalam berbagai literatur (Sun et al., 2018). Prinsip kerja dari algoritma ini adalah menggunakan parameter k sebagai masukan dan membagi jumlah objek menjadi k melalui kesamaan objek (Pratiwi & Wibowo, 2022).

K-Medoids adalah algoritma untuk menemukan *medoid* dalam sebuah *cluster* (Kurniawan et al., 2020) dan bekerja berdasarkan teknik representasi objek (Wang Yan et al., 2020) dengan meminimalkan ketidaksetaraan objek. K objek dipilih secara acak sebagai *medoid* untuk dijadikan titik pusat dan semua data yang dipilih ditempatkan pada *cluster* yang *medoid* berdekatan dengan objek. Proses pemindahan data yang memiliki lampiran ke *medoid* dilakukan berkali-kali. Dengan setiap iterasi, *medoid* mengubah lokasinya secara bertahap.

Mahalano Distance adalah salah satu alat ukur dalam *Bregman Divergences*. *Mahalano* memiliki kinerja yang baik pada data dengan sedikit variasi. Ketika data memiliki tingkat variasi yang sangat tinggi, *Mahalano* tidak dapat bekerja menghitung jarak dengan baik (Martino et al., 2017). Hal inilah yang menjadi alasan penggunaan *Mahalano* dalam penelitian ini. Kinerja DBI dievaluasi melalui pengelompokan data yang memiliki tingkat

variasi data yang rendah. Rumus jarak *Mahalano* adalah sebagai berikut:

$$\lambda^2 = (X - \mu)^T \Lambda^{-1} (X - \mu) \quad (1)$$

λ^2 = Mahalano Distance

Λ^{-1} = Covariance Matrix

$(X - \mu)^T$ = Vector Transpose

Untuk mendapatkan anggota dari suatu *cluster*, diperlukan pengukuran jarak antar objek. *Euclidean Distance* melakukan dengan melibatkan akar kuadrat. Dalam beberapa aplikasi data mining, pengukuran seperti itu tidak diperlukan selama jarak digunakan untuk membandingkan kedekatan antar objek. Pengukuran lain yang dapat digunakan tanpa akar kuadrat adalah *SED*. *SED* telah banyak digunakan karena dapat menghemat biaya dan waktu komputasi (Hossain & Abufardeh, 2019). Rumus *SED* diberikan sebagai berikut:

$$SED(X, Y) = \sum_{i=1}^n (x_i - y_i)^2 \quad (2)$$

SED menggunakan rumus yang sama dengan *Euclidean Distance*, hanya saja tidak menggunakan akar kuadrat sehingga perhitungan jarak menjadi lebih sederhana. berkali-kali. Dengan setiap iterasi, *centroid* mengubah lokasinya secara bertahap

2.3 HASIL CLUSTER

Pengolahan data menggunakan algoritma *K-Means* dan *K-Medoids* menghasilkan sejumlah *cluster* dengan anggota *cluster* masing-masing

2.4 CLUSTER OPTIMAL

Tahap ini adalah proses mencari *cluster* optimal dari sejumlah k uji yang telah diujikan melalui *K-Means* dan *K-Medoids* untuk setiap pengukuran dengan menggunakan teknik DBI.

DBI adalah teknik evaluasi *cluster* yang diperkenalkan oleh Davies dan Bouldin pada tahun 1979 (Wijaya et al., 2021). Evaluasi dengan menggunakan DBI ini memiliki skema evaluasi *cluster* internal, dimana hasil *cluster* baik tidaknya dapat dilihat dari kuantitas dan kedekatan antar data *cluster*. DBI adalah fungsi rasio dari jumlah *cluster* yang tersebar ke pemisahan *cluster*. Pendekatan pengukuran DBI mengupayakan jarak maksimum pada jarak *inter-cluster* dan minimal pada jarak *intra-cluster*. *Cluster* optimal dipilih jika DBI

menghasilkan nilai terkecil. Rumus DBI adalah (Fränti, 2017):

$$DBI = \frac{1}{K} \sum_{j=1}^K \max_{j \neq k} R_{j,k} \quad (3)$$

Dimana:

K=cluster dan R=rasio perbandingan cluster ke-i dan ke-j.

2.5 EVALUASI KINERJA MAHALANO DAN SED

Tahapan penelitian diakhiri dengan mengevaluasi hasil kinerja teknik pengukuran pendukung DBI sehingga menghasilkan jumlah cluster yang optimal. Evaluasi tersebut menggunakan beberapa indikator, yakni korelasi, algoritma cluster yang digunakan, pola DBI, hasil DBI, k-optimal dan waktu yang dibutuhkan untuk pengujian korelasi.

3. HASIL DAN PEMBAHASAN


Pengujian data dilakukan dengan *K-Means* dan *K-Medoids* untuk mendapatkan bentuk pengelompokan yang diukur dengan *Mahalano* dan SED. Beberapa k diuji untuk mendapatkan hasil pengelompokan dengan mengacu pada persamaan (1) dan (2). Kemudian setiap uji k dievaluasi oleh DBI untuk mendapatkan k yang paling optimal dengan menggunakan persamaan (3). DBI untuk setiap algoritma, ditunjukkan pada Tabel 2.

Tabel 2. Hasil DBI


K	<i>K-Means</i>		<i>K-Medoids</i>	
	<i>Mahalano</i>	SED	<i>Mahalano</i>	SED
2	2.852	1.030	0.979	0.882
3	2.982	1.196	1.927	1.000
4	2.154	1.185	1.633	1.375
5	2.059	1.178	1.634	1.100
6	2.719	1.261	1.532	1.244

Tabel 2 menunjukkan bahwa nilai DBI yang dihasilkan dari teknik *Mahalano* dan SED merupakan hasil terbaik. DBI terendah dihitung dari nilai antar dan intra-cluster dari setiap k yang diuji pada setiap algoritma. Nilai DBI membentuk pola yang berbeda untuk setiap hasil pengukuran. Pola cluster yang dihasilkan oleh *Mahalano* melalui algoritma *K-Means* dan *K-Medoids* lebih stabil dibandingkan dengan pola yang dihasilkan oleh SED. *Mahalano* mempertimbangkan hubungan antar atribut dan kandungan atribut

(instances) yang mendukung data seperti yang dijelaskan pada Tabel 1. Setiap atribut dan instances dibandingkan untuk mendapatkan korelasi yang tidak sama dengan 0. Pola DBI yang dihasilkan oleh *Mahalano* dan SED diperlihatkan pada Gambar 2 dan 3.



Gambar 2. Pola DBI Mahalano Distance



Gambar 3. Pola DBI SED

Berdasarkan analisis dari DBI terendah, SED memiliki DBI terkecil sebesar 0,882 yang terdapat pada k = 2. Pada Tabel 2, masing-masing algoritma dengan kedua teknik pengukuran *Bregman Divergence* di atas menunjukkan cluster optimal pada uji k yang berbeda. Dalam penerapan dua algoritma pengelompokan, DBI yang diperoleh dari *Mahalano* menempatkan k = 5 untuk *K-Means* dan k = 2 untuk *K-Medoids*. Algoritma yang menghasilkan DBI terendah pada kedua pengukur jarak *Bregman Divergence* ini adalah *K-Medoids*, dimana jumlah cluster optimal keduanya berada pada k = 2.

Analisis lain yang dapat dideskripsikan dari hasil pengujian ini adalah keanggotaan pada cluster optimal terpilih. Pola *Mahalano* yang stabil terlihat pada keanggotaan yang memiliki

kemiripan atau kesamaan atribut yang tinggi, sedangkan SED menghasilkan keanggotaan dengan kesamaan keanggotaan yang hampir merata diantara setiap anggota *cluster*. Tabel 3 berikut kesamaan atribut keanggotaan dominan yang dihasilkan oleh algoritma *K-Medoids* untuk dua pengukuran *Bregman Divergence*.

Tabel 3. Kesamaan Atribut Pada k Optimal
K-Medoids

k=2	<i>Mahalano</i>	k=2	SED
0	Kecukupan gizi calon ibu, postur tubuh calon ibu, kondisi ekonomi, kondisi sosial, kesakitan pada bayi	0	Kondisi sosial, Gizi bayi
1	Kecukupan gizi calon ibu, postur tubuh calon ibu, kondisi sosial, gizi bayi	1	Kecukupan gizi calon ibu, usia, kondisi sosial, sakit bayi

Hasil pengujian menunjukkan bahwa pengukuran *Bregman Divergence* dapat membantu kinerja DBI dalam menentukan jumlah *cluster* yang optimal. Pola dan keanggotaan yang dibentuk dengan pengelompokan cukup baik untuk data dengan variasi terbatas. Nilai *inter-cluster* dan *intra-cluster* yang dihasilkan oleh DBI menentukan uji k optimal dan informasi yang diperoleh dari hasil pengelompokan sangat bergantung pada kedekatan masing-masing data dalam atribut. Secara keseluruhan kinerja *Mahalano* dan SED dalam pembentukan *cluster* optimal melalui DBI dapat dilihat pada Tabel 4.

Tabel 4. Hasil Evaluasi *Mahalano* dan SED

Indikator	<i>Mahalano</i>	SED
Korelasi	Lebih kuat - <i>K-Means</i> , jarak yang dihasilkan lebih besar	Standar Jarak yang dihasilkan <i>K-Means</i> and <i>K-Medoids</i> hampir sama
Algoritma <i>cluster</i> yang digunakan	- <i>K-Medoids</i> , jarak yang dihasilkan lebih kecil	
Pola DBI	Konsisten	Tidak konsisten
Hasil DBI	Lebih tinggi	Lebih rendah
k-optimal	Terdapat pada k uji yang berbeda	Terdapat pada k uji yang sama
Waktu yang	- <i>K-Means</i> , lebih cepat	Waktu pengujian kedua algoritma sama

dibutuhkan - *K-Medoids*, lebih
untuk lambat
pengujian

4. SIMPULAN

Cluster yang optimal dapat diperoleh dari pengukuran *Bregman Divergence*. Data dengan variasi yang rendah juga dapat dikelompokkan dengan baik melalui DBI. Data pengujian membuktikan bahwa *Mahalano* dapat membentuk pola pengelompokan yang konsisten menggunakan algoritma *K-Means* dan *K-Medoids* dan mendapatkan *cluster* optimal pada uji k yang berbeda. SED menghasilkan nilai DBI terendah sebesar 0,882 dan 1,030 dengan waktu pengujian lebih cepat yaitu 0 detik. Walaupun pola pengelompokannya tidak sebaik *Mahalano*, SED membantu DBI untuk mendapatkan *cluster* yang optimal pada uji k yang sama terhadap kedua algoritma tersebut. Dengan demikian, penentuan jumlah *cluster* yang optimal dari suatu pengelompokan juga dapat dikembangkan pada formula jarak lain dari pengukuran *Bregman Divergence* dengan algoritma dan variasi data yang sesuai.

5. DAFTAR PUSTAKA

- Adepeju, M., Langton, S., & Bannister, J. (2021). Anchored k-medoids: a novel adaptation of k-medoids further refined to measure long-term instability in the exposure to crime. *Journal of Computational Social Science*, 4(2), 655–680.
<https://doi.org/10.1007/s42001-021-00103-1>
- Dubey, A. K., Gupta, U., & Jain, S. (2018). Comparative study of K-means and fuzzy C-means algorithms on the breast cancer data. *International Journal on Advanced Science, Engineering and Information Technology*, 8(1), 18–29.
<https://doi.org/10.18517/ijaseit.8.1.3490>
- Edelsbrunner, H., & Wagner, H. (2017). Topological data analysis with bregman divergences. *Leibniz International Proceedings in Informatics 33rd International Symposium on Computational Geometry (SoCG 2017)*, 39(39), 1–16.
<https://doi.org/10.4230/LIPIcs.SocG.2017.39>
- Fränti, P. (2017). Introduction. In *Cluster*

- Validation (p. 110).
- Ghorbani, H. (2019). Mahalanobis Distance and Its Application for Detecting Multivariate Outliers. *Facta Universitatis, Series: Mathematics and Informatics*, 34(3), 583–595. <https://doi.org/10.22190/fumi1903583g>
- Hossain, M., & Abufardeh, S. (2019). A New Method of Calculating Squared Euclidean Distance (SED) Using pTree Technology and Its Performance Analysis. *Proceedings of 34th International Conference on Computers and Their Applications*, 58(1), 45–34. <https://doi.org/10.29007/trrg>
- Kurniawan, W., Rifai, A., Gata, ; Windu, & Gunawan, D. (2020). Analisis Algoritma K-Medoids Clustering Dalam Menentukan Pemesanan Hotel. *Jurnal Swabumi*, 8(2), 182–187. <https://www.kaggle.com>
- Martino, A., Ghiglietti, A., Ieva, F., & Paganoni, A. M. (2017). A k-means procedure based on a Mahalanobis type distance for clustering multivariate functional data. *Statistical Methods and Applications*, August, 1–23. <https://doi.org/10.1007/s10260-018-00446-6>
- Pathak, B., & Lal, N. (2017). A survey on clustering in data mining. *International Journal of Computer Applications*, 159(2), 6–11. <https://doi.org/10.1145/1980022.1980143>
- Pratiwi, H., & Wibowo, A. P. W. (2022). Implementasi Algoritma K-Means Untuk Mengklaster Kelompok Sektor Perkebunan Di Indonesia. *JOISIE Journal Of Information System And Informatics Engineering*, 6(1), 39–48.
- Sari, D. P. (2021). Pengelompokan Penyakit Berdasarkan Lingkungan Dengan Algoritma K-Means Pada Puskesmas Sungai Tarab 2. *JOISIE (Journal Of Information Systems And Informatics Engineering)*, 5(2), 75–81. <https://doi.org/10.35145/joisie.v5i2.1700>
- Siregar, H. L., Lestari Siregar, H., Zarlis, M., & Efendi, S. (2023). Cluster Analysis using K-Means and K-Medoids Methods for Data Clustering of Amil Zakat Institutions Donor. *Jurnal Media Informatika Budidarma*, 7(2), 668–677. <https://doi.org/10.30865/mib.v7i2.5315>
- Sprung, B. (2019). Upper and lower bounds for the Bregman divergence. *Journal of Inequalities and Applications*, 2019(4), 6–12. <https://doi.org/10.1186/s13660-018-1953-y>
- Sun, D., Fei, H., & Li, Q. (2018). A Bisecting K-Medoids clustering Algorithm Based on Cloud Model. *IFAC-Papers OnLine*, 51(11), 308–315. <https://doi.org/10.1016/j.ifacol.2018.08.301>
- Sureja, N., Chawda, B., & Vasant, A. (2022). An improved K-medoids clustering approach based on the crow search algorithm. *Journal of Computational Mathematics and Data Science*, 3(July 2021), 12. <https://doi.org/10.1016/j.jcmds.2022.100034>
- Tempola, F., & Assagaf, A. F. (2018). Clustering of Potency of Shrimp In Indonesia With K-Means Algorithm And Validation of Davies-Bouldin Index. *Atlantis Highlights in Engineering (AHE), Volume 1 International Conference on Science and Technology*, 1(1), 730–733. <https://doi.org/10.2991/icst-18.2018.148>
- The Ministry of Health. (2018). Situasi Balita Pendek (stunting) di Indonesia. *The Ministry of Health of Republic Indonesia*, 1, 1–56. <https://doi.org/ISSN 2088 - 270X>
- Wang Yan, E., Jian, A., Yan, L., & Honggang, W. (2020). Optimization of K-medoids Algorithm for Initial Clustering Center. *Journal of Physics: Conference Series*, 1487(1), 8. <https://doi.org/10.1088/1742-6596/1487/1/012011>
- Wibowo, D. W., Yunshasnawa, Y., Setiawan, A., Rohadi, E., & Khabibi, M. K. (2019). Application of K-medoids clustering method for grouping corn plants based on productivity, production, and area of land in East Java. *Journal of Physics: Conference Series*, 1402(7), 6. <https://doi.org/10.1088/1742-6596/1402/7/077061>
- Wijaya, Y. A., Kurniady, D. A., Setyanto, E., Tarihoran, W. S., Rusmana, D., & Rahim, R. (2021). Davies Bouldin Index Algorithm for Optimizing Clustering Case Studies Mapping School Facilities.

TEM Journal, 10(3), 1099–1103.
<https://doi.org/10.18421/TEM103-13>