

KLASIFIKASI PENERIMA DANA BANTUAN DESA MENGGUNAKAN METODE KNN (K-NEAREST NEIGHBOR)

Riyan Latifahul Hasanah¹; Muhamad Hasan²; Witriana Endah Pangesti³;
Fanny Fatma Wati⁴; Windu Gata⁵

Program Pascasarjana Magister Ilmu Komputer
STMIK Nusa Mandiri Jakarta
<http://nusamandiri.ac.id/>

¹riyanlat0804@bsi.ac.id; ²hasanmuhamad17@gmail.com; ³witriana21@gmail.com;
⁴fannyfatmawati8@gmail.com; ⁵windugata@gmail.com



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

Abstract—Determining the status of poor families as recipients of assistance is very important so that poverty reduction assistance from the government can be channeled on target. Data mining utilizes experience or even mistakes in the past to improve the quality of the model and the results of its analysis, one of which is the ability possessed by data mining techniques, namely classification. The purpose of this study was to test K-Fold Cross Validation in the K-Nearest Neighbors algorithm in predicting receipt of village aid funds. In the beneficiary dataset used in this study, there were 159 records or tuples with four attributes (house condition, income, employment and number of dependents). The new data category prediction is done by using the Euclidean Distance manual calculation stage of five different K values. While using the Rapidminer application aims to test the accuracy of the dataset in five different K values. The results show that with K=15 and K=30 the new data (D160) has a "Not Eligible" category with an accuracy of 100%. Then with K=45, K=60 and K=75, the new data (D160) has the category "Eligible" with an accuracy rate of 81.25%.

Keywords: Village Assistance Fund, K-Nearest Neighbors, K-Fold Cross Validation, Rapidminer.

Intisari—Penentuan status keluarga miskin sebagai penerima bantuan merupakan hal yang sangat penting agar bantuan penanggulangan kemiskinan dari pemerintah dapat disalurkan secara tepat sasaran. Data mining memanfaatkan pengalaman atau bahkan kesalahan di masa lalu untuk meningkatkan kualitas dari model maupun hasil analisisnya, salah satunya dengan kemampuan yang dimiliki teknik data mining yaitu klasifikasi. Tujuan penelitian ini adalah untuk

melakukan pengujian K-Fold Cross Validation pada algoritma K-Nearest Neighbors dalam memprediksi penerimaan dana bantuan desa. Dalam dataset penerima bantuan yang digunakan dalam penelitian ini, terdapat 159 record atau tuple dengan empat atribut (kondisi rumah, penghasilan, pekerjaan dan jumlah tanggungan). Prediksi kategori data baru dilakukan dengan menggunakan tahapan perhitungan manual Euclidean Distance dari lima nilai K yang berbeda. Sedangkan menggunakan aplikasi Rapidminer bertujuan untuk menguji akurasi dataset dalam lima nilai K yang berbeda. Hasilnya menunjukkan bahwa dengan K=15 dan K=30 data baru (D160) memiliki kategori "Tidak Layak" dengan tingkat akurasi sebesar 100%. Kemudian dengan K=45, K=60 dan K=75 data baru (D160) memiliki kategori "Layak" dengan tingkat akurasi sebesar 81,25%.

Kata Kunci: Dana Bantuan Desa, K-Tetangga Terdekat, K-Fold Cross Validation, Rapidminer.

PENDAHULUAN

Alokasi dana desa merupakan salah satu sumber pendapatan desa yang digunakan sebagai penunjang kegiatan otonomi desa, salah satunya dalam rangka pemberdayaan masyarakat di tingkat pedesaan. Tujuan pemberdayaan masyarakat ini adalah untuk memberdayakan kelompok masyarakat yang lemah, miskin, marjinal dan kaum kecil secara sosio ekonomis sehingga mereka dapat lebih mandiri dan dapat memenuhi kebutuhan dasar hidupnya (Karimah, et al., 2014).

Berbagai jenis program dari pemerintah dalam upaya penanggulangan kemiskinan telah banyak dilaksanakan, tetapi bantuan yang sampai di tangan rakyat ada yang tidak sesuai dengan yang

diharapkan. Hal tersebut disebabkan salah satunya karena penentuan status keluarga miskin sebagai penerima bantuan belum optimal, sehingga dalam memberikan bantuan kemiskinan masih ada yang belum tepat sasaran (Lestari & Targiono, 2017)

Pelaksanaan program penanggulangan kemiskinan yang dilakukan sejak tahun 1998 sampai saat ini, secara umum mampu menurunkan angka kemiskinan Indonesia yang berjumlah 47,97 juta atau sekitar 23,43 % pada tahun 1999 menjadi 30,02 juta atau sekitar 12,49 % pada tahun 2011. Berdasarkan Worldfactbook, BPS dan World Bank, di tingkat dunia penurunan jumlah penduduk miskin di Indonesia termasuk yang tercepat dibandingkan negara lainnya. Tercatat pada rentang tahun 2005 sampai 2009 Indonesia mampu menurunkan laju rata-rata penurunan jumlah penduduk miskin per tahun sebesar 0,8%, jauh lebih tinggi dibandingkan dengan pencapaian negara lain misalnya Kamboja, Thailand, Cina, dan Brasil yang hanya berada di kisaran 0,1% per tahun (TNP2K, 2015).

Dana desa adalah dana yang bersumber dari APBN yang diperuntukkan bagi desa yang ditransfer melalui APBD kabupaten atau kota dan diprioritaskan untuk pelaksanaan pembangunan dan pemberdayaan masyarakat desa (Kementerian Keuangan RI, 2017)

Dana desa adalah salah satu isu krusial dalam undang-undang desa, penghitungan anggaran berdasarkan jumlah desa dengan mempertimbangkan jumlah penduduk, angka kemiskinan, luas wilayah, dan tingkat kesulitan geografis dalam rangka meningkatkan kesejahteraan dan pemerataan pembangunan desa. Karena isu yang begitu krusial, para senator menilai, penyelenggaraan pemerintahan desa membutuhkan pembinaan dan pengawasan, khususnya penyelenggaraan kegiatan desa (Aminah & Sari, 2018)

Teknik dalam memanfaatkan data dalam jumlah yang besar untuk memperoleh informasi berharga yang belum diketahui agar dapat dimanfaatkan untuk pengambilan keputusan dikenal dengan istilah *data mining*. *Data mining* memanfaatkan pengalaman atau bahkan kesalahan di masa lalu untuk meningkatkan kualitas dari model maupun hasil analisisnya, salah satunya dengan kemampuan yang dimiliki teknik *data mining* yaitu klasifikasi (Susanto *et al.*, 2018).

Pemberian klasifikasi penerimaan dana bantuan desa pada penelitian ini menggunakan metode *K-Nearest Neighbor* (KNN). *K-Nearest Neighbor* adalah metode klasifikasi dengan mencari jarak terdekat antara data yang akan dievaluasi dengan K tetangga (*neighbor*) terdekatnya dalam data pelatihan (Kustiyahningsih & Syafa'ah, 2015). Penentuan nilai terbaik dapat

ditentukan dengan optimasi parameter, misalnya dengan menggunakan *K-Fold Cross Validation* yang merupakan salah satu metode yang digunakan untuk mengetahui rata-rata keberhasilan dari suatu sistem dengan cara melakukan perulangan dengan mengacak atribut masukan sehingga sistem tersebut teruji untuk beberapa atribut input yang acak (Susanto *et al.*, 2018).

Tujuan penelitian ini adalah untuk melakukan pengujian *K-Fold Cross Validation* pada algoritma *K-Nearest Neighbors* dalam memprediksi penerimaan dana bantuan desa dengan menggunakan kriteria-kriteria yang sudah ditentukan untuk mengetahui penerima dana layak atau tidak layak untuk menerima dana bantuan desa.

BAHAN DAN METODE

Penelitian ini membahas mengenai implementasi *data mining* menggunakan algoritma *K-Nearest Neighbor* (KNN) dengan studi kasus pengujian *K-Fold Cross Validation* dalam klasifikasi penerimaan dana bantuan desa. *Dataset* yang digunakan dalam penelitian ini memiliki 159 *record* atau *tuple* dengan 4 atribut atau kriteria, yaitu kondisi rumah, penghasilan, pekerjaan dan jumlah tanggungan. Tabel 1 berikut ini merupakan bobot nilai dari setiap kriteria yang digunakan:

Tabel 1. Bobot Nilai Setiap Kriteria

KRITERA	NILAI	BOBOT
Kondisi Rumah	Bambu	4
	Triplek	3
	Batako	2
	Batu bata	1
	Beton	0
Penghasilan	<500.000	4
	500.000 -1.000.000	3
	1.000.001 - 3.000.000	2
	3.000.001-5.000.000	1
	>5.000.000	0
Pekerjaan	Buruh	4
	Petani	3
	PNS	2
	Wirusaha	1
	Pengusaha	0
Jumlah Tanggungan	>7Orang	4
	6-7 Orang	3
	4-5 Orang	2
	2-3 Orang	1
	1 Orang	0

Sumber: (Hasanah, Hasan, Pangesti, Wati, & Gata, 2019)

Bobot yang dimiliki masing-masing atribut atau kriteria akan dijumlahkan untuk menentukan kategori data tersebut "Layak" atau "Tidak layak".

Dalam pengujian peneliti menggunakan program *Microsoft Excel 2010* sebagai alat bantu perhitungan manual dan pengimplementasian data menggunakan aplikasi *Rapidminer* dengan

confusion matrix sebagai alat ukur performa algoritma klasifikasi.

HASIL DAN PEMBAHASAN

Perhitungan Manual

Dalam perhitungan manual ini *dataset* yang telah diperoleh akan dihitung menggunakan metode K-NN secara manual untuk mengetahui kualitas data yang dimiliki apakah cukup baik untuk digunakan sebagai data latih. Metode K-NN adalah salah satu metode klasifikasi yang sering digunakan, bertujuan untuk mengklasifikasikan objek baru berdasarkan data pembelajaran atau data latih yang jaraknya paling dekat dengan objek baru tersebut.

Dalam *dataset* penerima bantuan yang digunakan dalam penelitian ini, terdapat 159 *record* atau *tuple* dengan 4 atribut (kondisi rumah, penghasilan, pekerjaan dan jumlah tanggungan). Untuk melakukan perhitungan manual metode K-NN terlebih dahulu harus ditentukan jumlah data tetangga terdekat yang dinotasikan dengan K, dimana nilai K ditentukan secara bebas. Dalam penelitian ini ditentukan 5 nilai K, yaitu K=15, K=30, K=45, K=60 dan K=75. Langkah selanjutnya yaitu menghitung *euclidean distance* sebagai teknik pencarian tetangga terdekat dan berfungsi untuk menguji ukuran yang bisa digunakan sebagai intepretasi kedekatan jarak antara dua objek.

Rumus perhitungan *euclidean distance* sebagai berikut:

$$d_e = \sqrt{\sum_{k=1}^m (fd_{i,k} - k_j)^2} \dots\dots\dots (1)$$

Keterangan :

- d_e : jarak *euclidean*
- fd_i : data *training*
- k_j : data *testing*
- m : jumlah data penelitian

Berikut ini merupakan contoh perhitungan manual untuk mencari nilai *euclidean distance* antara data baru (D160) ke data pertama (D1).

$$D(X_i, X_j) = \sqrt{\sum_{n=1}^n (ar(X_i) - ar(X_j))^2}$$

$$D(1,160) = \sqrt{(3-1)^2 + (2-2)^2 + (4-1)^2 + (4-2)^2}$$

$$D(1,160) = \sqrt{(2)^2 + (0)^2 + (3)^2 + (2)^2}$$

$$D(1,160) = \sqrt{17}$$

$$D(1,160) = 4,123105626$$

Jarak antara data baru (D160) dengan data kedua dan seterusnya dihitung menggunakan cara

yang sama. Hasil perhitungan *euclidean distance* seperti pada Tabel 2 berikut ini:

Tabel 2. Hasil Perhitungan *Euclidean Distance*

NO	KONDISI RUMAH	PENG-HASILAN	PEKER-JAAN	JML ART	EUCLIDEAN DISTANCE
1	3	2	4	4	4,123105626
2	3	3	4	5	4,795831523
3	3	2	4	4	4,123105626
4	1	2	4	7	5,830951895
5	3	3	4	4	4,242640687
6	2	3	4	4	3,872983346
7	3	4	4	6	5,744562647
....
....
159	2	2	4	4	3,741657387
160	1	2	1	2	- (data baru)

Sumber: (Hasanah et al., 2019)

Setelah diketahui jarak antara data baru dengan setiap data latih, maka data diurutkan berdasarkan *euclidean distance* terkecil ke terbesar. Semakin kecil *euclidean distance* berarti jarak antar data semakin dekat. Hasil pengurutan akan diberi peringkat sesuai dengan nilai K. Lalu tentukan kategori atau label dari data yang telah diperingkatkan tersebut.

Tabel 3 merupakan data yang telah diurutkan dengan nilai K=15, sehingga data diberi peringkat 1 sampai 15.

Tabel 3. Peringkat Data dengan K=15

NO	KR	PH	PJ	JA	KET	EUCLIDEAN DISTANCE	PERINGKAT
19	2	1	3	3	TL	2,645751311	1
25	2	1	3	3	TL	2,645751311	2
147	2	2	3	4	TL	3	3
31	2	2	4	3	TL	3,31662479	4
32	2	2	4	3	TL	3,31662479	5
118	2	2	4	3	TL	3,31662479	6
13	2	3	4	3	L	3,464101615	7
....
....
146	1	2	3	5	TL	3,605551275	15

Sumber: (Hasanah et al., 2019)

Dengan melihat kategori dari 15 tetangga terdekat tersebut maka akan dapat diprediksi kategori dari data baru berdasarkan kategori tetangga terdekat yang paling banyak. Dari Tabel 3 diatas diketahui bahwa 1 data memiliki kategori "Layak", sedangkan 14 data memiliki kategori

“Tidak layak”. Maka dapat disimpulkan bahwa data baru (D160) dengan $K=15$ memiliki kategori “Tidak layak”. Tabel 4 merupakan data yang telah diurutkan dengan nilai $K=30$, sehingga data diberi peringkat 1 sampai 30.

Tabel 4. Peringkat Data dengan $K=30$

NO	KR	PH	PJ	JA	KET	EUCLIDEAN DISTANCE	PERINGKAT
19	2	1	3	3	TL	2,645751311	1
25	2	1	3	3	TL	2,645751311	2
....
....
94	1	1	4	4	TL	3,741657387	25
95	2	2	4	4	L	3,741657387	26
99	1	1	4	4	TL	3,741657387	27
102	2	2	4	4	L	3,741657387	28
103	2	2	4	4	L	3,741657387	29
107	3	2	4	3	L	3,741657387	30

Sumber: (Hasanah et al., 2019)

Dengan melihat kategori dari 30 tetangga terdekat tersebut maka akan dapat diprediksi kategori dari data baru berdasarkan kategori tetangga terdekat yang paling banyak. Dari Tabel 4 di atas diketahui bahwa 12 data memiliki kategori “Layak”, sedangkan 18 data memiliki kategori “Tidak layak”. Maka dapat disimpulkan bahwa data baru (D160) dengan $K=30$ memiliki kategori “Tidak layak”.

Tabel 5 merupakan data yang telah diurutkan dengan nilai $K=45$, sehingga data diberi peringkat 1 sampai 45.

Tabel 5. Peringkat Data dengan $K=45$

NO	KR	PH	PJ	JA	KET	EUCLIDEAN DISTANCE	PERINGKAT
19	2	1	3	3	TL	2,645751311	1
25	2	1	3	3	TL	2,645751311	2
....
....
159	2	2	4	4	L	3,741657387	40
6	2	3	4	4	L	3,872983346	41
9	2	3	4	4	L	3,872983346	42
16	2	1	4	4	TL	3,872983346	43
24	2	1	4	4	TL	3,872983346	44
33	2	1	4	4	TL	3,872983346	45

Sumber: Hasanah et al. (2019)

Dengan melihat kategori dari 45 tetangga terdekat tersebut maka akan dapat diprediksi kategori dari data baru berdasarkan kategori

tetangga terdekat yang paling banyak. Dari Tabel 5 di atas diketahui bahwa 23 data memiliki kategori “Layak”, sedangkan 22 data memiliki kategori “Tidak layak”. Maka dapat disimpulkan bahwa data baru (D160) dengan $K=45$ memiliki kategori “Layak”.

Tabel 6 merupakan data yang telah diurutkan dengan nilai $K=60$, sehingga data diberi peringkat 1 sampai 60.

Tabel 6. Peringkat Data dengan $K=60$

NO	KR	PH	PJ	JA	KET	EUCLIDEAN DISTANCE	PERINGKAT
19	2	1	3	3	TL	2,645751311	1
25	2	1	3	3	TL	2,645751311	2
....
....
3	3	2	4	4	L	4,123105626	55
44	3	2	4	4	L	4,123105626	56
47	3	2	3	5	L	4,123105626	57
49	3	2	4	4	L	4,123105626	58
54	3	2	4	4	L	4,123105626	59
110	3	2	4	4	L	4,123105626	60

Sumber: (Hasanah et al., 2019)

Dengan melihat kategori dari 60 tetangga terdekat tersebut maka akan dapat diprediksi kategori dari data baru berdasarkan kategori tetangga terdekat yang paling banyak. Dari Tabel 6 di atas diketahui bahwa 33 data memiliki kategori “Layak”, sedangkan 27 data memiliki kategori “Tidak layak”. Maka dapat disimpulkan bahwa data baru (D160) dengan $K=60$ memiliki kategori “Layak”.

Tabel 7 merupakan data yang telah diurutkan dengan nilai $K=75$, sehingga data diberi peringkat 1 sampai 75.

Tabel 7. Peringkat Data dengan $K=75$

NO	KR	PH	PJ	JA	KET	EUCLIDEAN DISTANCE	PERINGKAT
19	2	1	3	3	TL	2,645751311	1
25	2	1	3	3	TL	2,645751311	2
....
....
153	1	2	4	5	L	4,242640687	70
10	1	3	4	5	L	4,358898944	71
18	2	2	4	5	L	4,358898944	72
23	2	2	4	5	L	4,358898944	73
26	2	2	4	5	L	4,358898944	74
30	1	1	4	5	TL	4,358898944	75

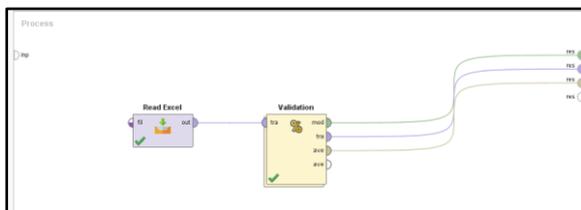
Sumber: Hasanah et al. (2019)

Dengan melihat kategori dari 75 tetangga terdekat tersebut maka akan dapat diprediksi kategori dari data baru berdasarkan kategori tetangga terdekat yang paling banyak. Dari Tabel 7 diatas diketahui bahwa 47 data memiliki kategori "Layak", sedangkan 28 data memiliki kategori "Tidak layak". Maka dapat disimpulkan bahwa data baru (D160) dengan K=75 memiliki kategori "Layak".

Implementasi dengan Rapidminer

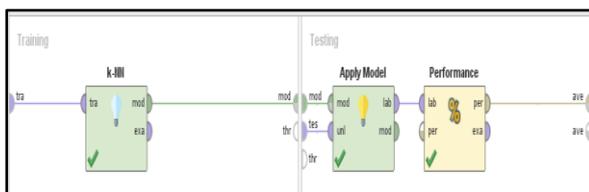
Pada perhitungan ini, dilakukan pengukuran akurasi untuk membuktikan tingkat performa suatu algoritma terhadap *dataset* yang digunakan menggunakan alat bantu aplikasi *Rapidminer*. Dalam penelitian ini digunakan *confussion matrix* sebagai alat ukur performa algoritma klasifikasi. *Confussion matrix* atau matrik kebingungan merupakan sebuah perhitungan yang membandingkan *dataset* dengan hasil klasifikasi sesuai dengan data sebenarnya dengan jumlah keseluruhan data. Hasil akhir dari matrik ini adalah tingkat akurasi dengan satuan persen (%). Tingkat akurasi ini yang nantinya dijadikan acuan para peneliti terkait performa algoritma klasifikasi tersebut.

Dalam aplikasi *Rapidminer* proses perhitungan performa algoritma dapat digambarkan seperti Gambar 1 berikut.



Sumber: Hasanah et al. (2019)
Gambar 1. Main Process pada Aplikasi Rapidminer

Sedangkan untuk data *training* digunakan algoritma KNN dan data *testing* digunakan *Apply Model* serta *Performance* untuk menghasilkan matrik kebingungan atau *confussion matrix*. Hasil matrik dari aplikasi dapat dilihat pada Gambar 2. Data *training* yang digunakan dalam penelitian ini berjumlah 159 *record* atau *tuple* dengan Nilai K=15, K=30, K=45, K=60, dan K=75.



Sumber: Hasanah et al. (2019)
Gambar 2. Confussion Matrix Model pada Aplikasi Rapidminer

Dari Tabel 8, sebagai contoh digunakan K=45 diperoleh data bahwa tingkat akurasi atau *confussion matrix* adalah sebesar 81,25%. Dapat disimpulkan bahwa tingkat akurasi yang diperoleh dari 4 atribut (kondisi rumah, penghasilan, pekerjaan dan jumlah tanggungan) dalam menentukan bobot "Layak" dan "Tidak Layak" menggunakan 159 data *training* dan nilai K=45 tergolong tinggi dengan akurasi=81,25%, *precision*=81,25% dan *recall*=100%.

Tabel 8. Hasil *Confussion Matrix* dengan K=45

	True LAYAK	True TIDAK LAYAK	Class Precision
Pred. LAYAK	39	9	81.25%
Pred. TIDAK LAYAK	0	0	0.00%
Class Recall	100.00%	0.00%	

Sumber: Hasanah et al. (2019)

Perhitungan selanjutnya, yaitu membandingkan beberapa hasil tingkat akurasi dari algoritma KNN dengan nilai K=15, K=30, K=45, K=60, dan K=75. Hasil ini akan dicatat lalu dibandingkan satu sama lain untuk menetapkan nilai K yang paling optimal yaitu penggunaan KNN dengan tingkat akurasi tertinggi.

Dari percobaan perhitungan penentuan penerimaan dana bantuan desa menggunakan perhitungan manual dan *Rapidminer*, kategori data baru dan akurasi KNN dengan nilai K yang digunakan dapat dilihat pada Tabel 9 berikut :

Tabel 9. Kategori Data Baru dan Akurasi KNN dari Berbagai Nilai K

K	15	30	45	60	75
Kategori Data Baru	Lay ak	Lay ak	Tidak Layak	Tidak Layak	Tidak Layak
<i>Accuracy</i>	100 %	100 %	81,25%	81,25%	81,25%

Sumber: Hasanah et al. (2019)

Hasil penelitian menunjukkan bahwa nilai K=15 dan K=30 merupakan nilai K yang paling optimal dengan tingkat akurasi sebesar 100% dan kategori data baru "Layak". Sedangkan untuk K=45, K=60 dan K=75 memiliki tingkat akurasi sebesar 81,25% dengan kategori data baru "Tidak Layak". Hasil prosentase ini didapatkan dari proses percobaan sebanyak 10 kali dengan data yang diacak (10 *fold cross validation*) kemudian hasil klasifikasi yang muncul dibandingkan dengan data sebenarnya. Perhitungan ini menggunakan *confussion matrix* untuk menentukan prosentase data yang sesuai dengan kenyataan dibandingkan jumlah keseluruhan data yang ada. Nilai K yang digunakan dalam penelitian ini seluruhnya adalah

nilai kelipatan 15 mulai dari K=15 sampai dengan K=75. Penentuan hasil klasifikasi untuk nilai K lebih dari 1 digunakan metode hasil terbanyak atau mayoritas hasil klasifikasi.

KESIMPULAN

Algoritma K-NN digunakan dalam penelitian ini untuk melakukan klasifikasi terhadap *dataset* penerimaan bantuan dana desa. Penelitian dilakukan melalui tahapan perhitungan manual untuk mengetahui hasil kelayakan atau ketidaklayakan dari sebuah data baru, serta menggunakan aplikasi *Rapidminer* untuk menguji akurasi *dataset* dalam berbagai nilai K. Hasilnya menunjukkan bahwa dengan K=15 dan K=30 data baru (D160) memiliki kategori "Tidak Layak" dengan tingkat akurasi sebesar 100%. Kemudian dengan K=45, K=60 dan K=75 data baru (D160) memiliki kategori "Layak" dengan tingkat akurasi sebesar 81,25%.

Diharapkan untuk penelitian selanjutnya menggunakan data yang lebih banyak agar hasil lebih optimal, serta membandingkan dengan algoritma lainnya. Hasil penelitian ini direkomendasikan untuk dipergunakan sebagai pertimbangan dalam menentukan penerima dana bantuan desa.

REFERENSI

- Aminah, A., & Sari, N. (2018). Pengelolaan dan Pemanfaatan Dana Desa untuk Pemberdayaan Masyarakat (Studi Kasus Di Gampong Gunong Meulinteung Kecamatan Panga Kabupaten Aceh Jaya). *Jurnal Public Policy*, 4(1), 442-456. https://doi.org/10.1007/978-1-4471-1543-4_12
- Hasanah, R. L., Hasan, M., Pangesti, W. E., Wati, F. F., & Gata, W. (2019). *Laporan Akhir Penelitian - Klasifikasi Penerima Dana Bantuan Desa Menggunakan Metode Knn (K-Nearest Neighbor)*. Jakarta.
- Karimah, F., Saleh, C., & Wanasmawatie, I. (2014). Pengelolaan Alokasi Dana Desa Dalam Pemberdayaan Masyarakat (Studi pada Desa Deket Kulon Kecamatan Deket Kabupaten Lamongan). *Jurnal Administrasi Publik*, 2(4), 597-602.
- Kementerian Keuangan RI. (2017). *Buku Pintar Dana Desa*. Jakarta: Direktorat Jenderal Perimbangan Keuangan. Retrieved from <https://www.kemenkeu.go.id/media/6749/buku-pintar-dana-desa.pdf>
- Kustiyahningsih, Y., & Syafa'ah, N. (2015). Sistem Pendukung Keputusan Untuk Menentukan Jurusan Pada Siswa SMA Menggunakan Metode KNN dan Smart. *Jurnal Sistem Informasi Indonesia*, 1(1), 19-28.
- Lestari, U., & Targiono, M. (2017). Sistem Pendukung Keputusan Klasifikasi Keluarga Miskin Menggunakan Metode Simple Additive Weighting (SAW) sebagai Acuan Penerima Bantuan Dana Pemerintah (Studi Kasus: Pemerintah Desa Tamanmartani, Sleman). *Jurnal TAM*, 8(1), 70-78.
- Susanto, E. S., Kusriani, & Fatta, H. Al. (2018). Prediksi Kelulusan Mahasiswa Magister Teknik Informatika Universitas AMIKOM Yogyakarta Menggunakan Metode K-Nearest Neighbor. *Jurnal Teknologi Informasi*, 8(2), 67-72.