

Klasifikasi Waktu Tanggap Kebakaran oleh Pemadam Kebakaran di Kabupaten Sleman Menggunakan Metode *K-Nearest Neighbor*

DOI: <http://dx.doi.org/10.35889/jutisi.v14i2.2966>

Creative Commons License 4.0 (CC BY – NC) 

Derry Meilana Jeffri^{1*}, Arita Witanti²

Informatika, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia

*e-mail *Corresponding Author*: derry.jeffri@gmail.com

Abstract

*Fire incidents are disasters that have the potential to cause significant losses, both materially and in terms of human lives. Therefore, firefighters must respond quickly to public fire reports with a response time that adheres to the standards set by Peraturan Menteri Pekerjaan Umum Number 20 of 2009 concerning Pedoman Teknis Manajemen Proteksi Kebakaran di Perkotaan. However in reality, firefighters still struggle to meet these standards due to various issues such as traffic congestion and inadequate road infrastructure. To identify these problems more deeply, firefighters need to further evaluate which fire incidents in which areas fail to meet the standard response times. Thus, a classification fire response times becomes essential. This study aims to classify fire response times using the KNN (*K-Nearest Neighbor*) method and evaluate the classification results. The variables used in this study are travel distance and travel time. The results show excellent classification performance, with an average accuracy of 98%.*

Keyword: *Classification; K-Nearest Neighbor; Response Time; Firefighter.*

Abstrak

Insiden kebakaran merupakan bencana yang berpotensi menimbulkan dampak kerugian signifikan, baik secara material maupun nyawa manusia. Oleh karena itu, Pemadam Kebakaran harus merespons cepat aduan masyarakat terkait kebakaran dengan waktu tanggap sesuai standar yang ditetapkan berdasarkan Peraturan Menteri Pekerjaan Umum Nomor 20 Tahun 2009 tentang Pedoman Teknis Manajemen Proteksi Kebakaran di Perkotaan. Tetapi pada kenyataannya Pemadam Kebakaran masih kesulitan untuk memenuhi standar tersebut dikarenakan berbagai masalah seperti kepadatan lalu lintas maupun infrastruktur jalan yang kurang memadai. Untuk mengidentifikasi masalah lebih mendalam, Pemadam Kebakaran perlu mengevaluasi lebih lanjut dengan cara mengetahui kejadian kebakaran daerah mana saja yang tidak memenuhi standar. Maka dari itu, diperlukan klasifikasi waktu tanggap kebakaran. Penelitian ini bertujuan mengklasifikasikan waktu tanggap kebakaran menggunakan metode KNN (*K-Nearest Neighbor*) kemudian dilakukan evaluasi terhadap hasil klasifikasi. Variabel yang digunakan pada penelitian ini yaitu jarak tempuh dan waktu tempuh. Penelitian ini menunjukkan hasil klasifikasi yang sangat baik, dengan rata-rata akurasi sebesar 98%.

Kata kunci: *Klasifikasi; K-Nearest Neighbor; Waktu Tanggap; Pemadam Kebakaran.*

1. Pendahuluan

Kebakaran termasuk bencana yang membawa konsekuensi serius, mulai dari kerugian ekonomi hingga risiko kematian. Oleh karena itu, respons cepat dari Pemadam Kebakaran sangat diperlukan untuk meminimalkan dampak yang ditimbulkan. Pemadam Kebakaran memiliki aturan standar yang mengatur respons cepat untuk menanggulangi kebakaran yang sedang dialami oleh masyarakat, yaitu yang tertuang pada Peraturan Menteri Pekerjaan Umum Nomor 20 Tahun 2009 tentang Pedoman Teknis Manajemen Proteksi Kebakaran di Perkotaan. Pada

peraturan tersebut setiap Wilayah Manajemen Kebakaran (WMK) harus memenuhi standar layanan Pemadam Kebakaran dengan radius jangkauan maksimal 7,5 kilometer dan waktu respons kurang dari 15 menit [1]. WMK (Wilayah Manajemen Kebakaran) merupakan pembagian zonasi kawasan tinggal berdasarkan kesamaan karakteristik proteksi kebakaran yang dibatasi oleh batas alam dan batas buatan [1]. Sedangkan waktu tanggap atau *response time* adalah periode waktu yang diukur sejak diterimanya laporan kebakaran oleh Pemadam Kebakaran, termasuk pengiriman personel dan peralatan, hingga kondisi operasional pemadaman siap dilaksanakan [2].

Dalam kenyataannya, belum semua kejadian kebakaran di Kabupaten Sleman dapat ditangani sesuai dengan peraturan tersebut. Kepadatan kendaraan di lalu lintas dan kondisi infrastruktur jalan yang kurang layak dilewati oleh truk Pemadam Kebakaran merupakan beberapa faktor yang menentukan kecepatan Pemadam Kebakaran dalam merespons kejadian kebakaran. Dengan masalah yang ada tersebut dibutuhkan data klasifikasi yang mendukung terkait waktu tanggap Pemadam Kebakaran yang dapat dijadikan sebagai bahan evaluasi lebih lanjut untuk memperbaiki layanan terhadap masyarakat.

Hingga saat ini Pemadam Kebakaran Kabupaten Sleman belum menggunakan *machine learning* untuk mempermudah dan mengotomatisasi pengklasifikasian data waktu tanggap tersebut. Penggunaan klasifikasi dengan metode *KNN (K-Nearest Neighbor)* dapat menjadi solusi karena metode ini fleksibel dan dapat diimplementasikan dalam berbagai konteks selama jarak antar data dapat diukur [3]. Selain itu metode ini menjadi pilihan yang tepat karena kemampuannya dapat dipakai pada data dengan dimensi sederhana [4] dimana pada penelitian ini hanya memerlukan 2 variabel yaitu jarak tempuh dan waktu tempuh. Maka dari itu, penulis meneliti seberapa besar tingkat akurasi jika klasifikasi waktu tanggap Pemadam Kebakaran di Kabupaten Sleman ini menggunakan metode *KNN (K-Nearest Neighbor)*.

Di penelitian ini dilakukan klasifikasi pada data waktu tanggap kebakaran sesuai dengan standar yang terdapat pada peraturan yang berlaku. Kemudian setelah data diklasifikasikan akan diklasifikasikan kembali dengan metode *KNN (K-Nearest Neighbor)*. Setelah hasil dari klasifikasi dengan metode *KNN (K-Nearest Neighbor)* didapatkan, hasil ini dievaluasi seberapa besar tingkat akurasi yang ditunjukkan oleh performa *KNN (K-Nearest Neighbor)* terhadap data waktu tanggap kebakaran oleh Pemadam Kebakaran Kabupaten Sleman. Dengan pemahaman yang lebih baik tentang akurasi metode *KNN (K-Nearest Neighbor)*, penelitian ini memiliki potensi ikut andil dalam berkontribusi pada pengembangan model klasifikasi yang lebih responsif dalam upaya memperbaiki layanan terhadap masyarakat dalam hal penanggulangan kebakaran di Kabupaten Sleman.

2. Tinjauan Pustaka

Untuk menghasilkan penelitian yang baik, penulis merujuk penelitian terdahulu sebagai acuan penelitian. Penelitian pertama yang dilakukan oleh Dinda Nur Oktaviyana dan Wawan Joko Pranoto pada tahun 2024 dalam penelitiannya yang berjudul *Klasifikasi Waktu Pada Dokumen Persetujuan Accounting Voucher*. pada penelitian ini meneliti penerapan teknik klasifikasi waktu menggunakan metode *Naïve bayes* untuk pengoptimalan proses manajemen dokumen persetujuan. Variabel yang digunakan dalam penelitian ini adalah jenis dokumen, nomor dokumen, status dokumen dan perbedaan hari. Hasil dari penelitian ini menunjukkan tingkat akurasi sebesar 89% [5].

Penelitian kedua dilakukan oleh Arie Yandi dan Yogi Primadasa pada tahun 2018 dalam penelitiannya yang berjudul *Penerapan Teknik Klasifikasi Untuk Prediksi Kelulusan Mahasiswa Menggunakan Algoritma K-Nearest Neighbour*. Pada penelitian ini meneliti prediksi terkait ketepatan waktu kelulusan mahasiswa menggunakan metode *KNN* untuk membantu program studi dalam memberi perhatian lebih pada mahasiswa yang diprediksi lulus tidak tepat waktu. Di penelitian ini menggunakan variabel nilai IPK semester 1 hingga semester 5. Hasil dari penelitian ini adalah klasifikasi dengan metode *KNN* dapat digunakan untuk memprediksi kelulusan [6].

Penelitian ketiga dilakukan oleh Irfham Widhi Saputro dan Bety Wulan Sari pada tahun 2019 dalam penelitiannya yang berjudul *Uji Performa Algoritma Naïve bayes Untuk Prediksi Masa Studi Mahasiswa*. Di penelitian ini algoritma *Naïve bayes* dipakai untuk meneliti performa model klasifikasi waktu kelulusan mahasiswa. Pada penelitian menggunakan variabel tipe sekolah, jenis kelamin, kota sekolah dan IP semester 1 hingga 4. Hasil dari penelitian ini menunjukkan tingkat akurasi 68% [7].

Penelitian keempat dilakukan oleh Inna Alvi Nikmatun dan Indra Waspada pada tahun 2019 dalam penelitiannya yang berjudul Implementasi Data Mining Untuk Klasifikasi Masa Studi Mahasiswa Menggunakan Algoritma *K-Nearest Neighbor*. Metode *KNN* digunakan dalam penelitian ini untuk meneliti klasifikasi masa studi mahasiswa dengan berbagai variabel antara lain seluruh atribut yang ada pada dataset, mata kuliah semester 1 hingga semester 4, mata kuliah hanya wajib, semua mata kuliah pilihan, mata kuliah relasi dan mata kuliah komdas. Hasil dari penelitian ini, dari keenam uji coba yang telah dilakukan menunjukkan nilai akurasi tertinggi diperoleh dari uji coba klasifikasi menggunakan variabel mata kuliah pilihan yaitu 75,95% [8].

Penelitian kelima dilakukan oleh Supardi Salmu dan Achmad Solichin pada tahun 2017 dalam penelitiannya yang berjudul Prediksi Tingkat Kelulusan Mahasiswa Tepat Waktu Menggunakan *Naïve Bayes*: Studi Kasus UIN Syarif Hidayatullah Jakarta. Model *Cross Industry Standard Process for Data Mining (CRISP-DM)* menggunakan metode *Naïve bayes* untuk meneliti faktor apa saja yang mempengaruhi dalam proses prediksi kelulusan mahasiswa menurut data performa akademik mahasiswa. Di penelitian menggunakan variabel antara lain jenis kelamin, jenis seleksi, pendapatan ayah, pendidikan ibu, IP semester 1 hingga 4 dan SKS semester 1 hingga 4. Dari penelitian ini diperoleh akurasi sebesar 80,72% [9].

Berdasarkan penelitian terdahulu yang telah disebutkan, penelitian terdahulu berfokus pada klasifikasi dengan objek waktu dalam konteks manajemen dokumen dan konteks akademik dengan implementasi algoritma *Naïve bayes* dan *K-Nearest Neighbor*. Perbedaan pada penelitian ini terletak pada klasifikasi dengan objek waktu dalam konteks kebencanaan yaitu klasifikasi waktu tanggap kebakaran oleh Pemadam Kebakaran yang hingga saat ini belum ada penelitian yang serupa. Selain itu perbedaan penelitian ini menggunakan 2 variabel yaitu jarak tempuh dan waktu tempuh dalam menilai kesesuaian waktu tanggap berdasarkan Peraturan Menteri Pekerjaan Umum Nomor 20 Tahun 2009.

3. Metodologi

3.1. Algoritma KNN (K-Nearest Neighbor)

Menurut Kusriani dalam bukunya yang berjudul *Data Mining Algorithm*, Metode *KNN (K-Nearest Neighbor)* mengklasifikasikan data baru berdasarkan kedekatannya dengan data-data dalam data pelatihan. Kedekatan ini diukur dengan membandingkan bobot dari beberapa fitur yang ada [10]. Untuk mengklasifikasikan data baru, perlu diberikan nilai *K* objek dari data uji dan memprediksi kategorinya berdasarkan mayoritas kategori terdekat dari nilai *K* objek tersebut. Kedekatan antar data diukur menggunakan jarak *Euclidean* [11]. Metode *KNN* memiliki rumus perhitungan seperti yang ditunjukkan pada persamaan 1 [12].

$$E = \sqrt{(\sum_{i=1}^n (pi - qi)^2)} \tag{1}$$

Dimana *E* adalah Jarak *Euclidean*, *pi* adalah *Data Training*, *qi* adalah *Data Testing*, *i* adalah *Variable Data*, *n* adalah Dimensi Data [12]. Metode *KNN* memiliki langkah-langkah sebagai berikut:

1. Menetapkan nilai *K*
2. Menghitung jarak *Euclidean* antara *data training* dan *data testing*
3. Mengurutkan jarak dari yang terkecil hingga terbesar
4. Mengumpulkan kelas dengan jumlah sesuai dengan nilai *K*
5. Menentukan kelas dengan cara voting dan yang dipilih adalah kelas mayoritas

3.2. Data dan Variabel

Penelitian klasifikasi waktu tanggap kebakaran ini menggunakan data kejadian kebakaran dari tahun 2021 hingga 2024 yang penulis dapatkan dari kantor Satuan Polisi Pamong Praja bidang Pemadam Kebakaran Kabupaten Sleman. Pada data tersebut akan diambil 2 variabel yaitu data jarak tempuh dan waktu tempuh untuk menentukan kategori klasifikasinya. Kategori klasifikasi dan syarat klasifikasi ditunjukkan pada tabel 1.

Tabel 1. Kategori Klasifikasi

Kategori Klasifikasi	Syarat	
	Jarak Tempuh (KM)	Waktu Tempuh (Menit)
Waktu Sesuai Dalam WMK	<= 7,5	< 15
Waktu Sesuai Luar WMK	> 7,5	< 15
Waktu Tidak Sesuai Luar WMK	> 7,5	>= 15
Waktu Tidak Sesuai Dalam WMK	<= 7,5	>= 15

Klasifikasi Waktu Tanggap Kebakaran oleh Pemadam Kebakaran (Derry Meilana Jeffri)

Keseluruhan data yang didapatkan yaitu sebanyak masing-masing variabel 873 data. data ini dibagi menjadi *data training* dan *data testing* menggunakan 3 rasio, yaitu rasio 80:20, rasio 70:30 dan rasio 60:40 seperti yang ditunjukkan pada tabel 2.

Tabel 2. Pembagian Data

Total Seluruh Data	80:20		70:30		60:40	
	<i>Taining</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
873	698	175	611	262	523	350

3.3. Metode Pengujian Performa Algoritma

Untuk mengukur performa algoritma ini akan menggunakan metode pengujian tingkat Akurasi, Presisi, *Recall* dan *F-1 Score*. Selanjutnya dijelaskan metode persamaannya:

1) Akurasi

Akurasi adalah ukuran kedekatan antara hasil yang diprediksi dengan hasil yang sebenarnya [13]. Persamaan untuk menghitung nilai Akurasi ditunjukkan pada persamaan 2 [10].

$$A = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

2) Presisi

Presisi menunjukkan sejauh mana jawaban yang diberikan sesuai dengan permintaan informasi yang diminta [14]. Persamaan untuk menghitung nilai Presisi ditunjukkan pada persamaan 3 [10].

$$P = \frac{TP}{TP+FP} \quad (3)$$

3) *Recall*

Recall merupakan rasio perbandingan antara data relevan yang dipilih terhadap jumlah keseluruhan data relevan yang telah tersedia [15]. Persamaan untuk menghitung nilai *Recall* ditunjukkan pada persamaan 4 [10].

$$R = \frac{TP}{TP+FN} \quad (4)$$

4) *F-1 Score*

F1-Score merupakan indikator performa yang mengintegrasikan hasil pengukuran Presisi dan *Recall* [16]. Persamaan untuk menghitung *F1-Score* ditunjukkan pada persamaan 5 [17].

$$F = 2 * \frac{P * R}{P + R} \quad (5)$$

Dimana *A* adalah Akurasi, *P* adalah Presisi, *R* adalah *Recall*, *F* adalah *F1-Score*, *TP* (*True Positive*) adalah jumlah data yang terprediksi positif yang benar-benar positif, *TN* (*True Negative*) adalah jumlah data yang terprediksi negatif yang benar-benar negatif, *FP* (*False Positive*) adalah jumlah data yang terprediksi positif tetapi sebenarnya negatif, *FN* (*False Negative*) adalah jumlah data yang terprediksi negatif tetapi sebenarnya positif.

4. Hasil dan Pembahasan

4.1. Sampel Data Penelitian

Di penelitian ini data telah diklasifikasikan sesuai dengan aturan yang telah ditetapkan, kemudian melewati proses *pre-processing* data yang meliputi *data cleaning*, *label encoding* dan *data splitting*. Pada tabel 3 adalah *label encode* yang sesuai dengan klasifikasi kemudian akan tersaji dalam tabel *data training* maupun *data testing*.

Tabel 3. *Label Encode*

Kategori Klasifikasi	Hasil <i>Encode</i>
Waktu Sesuai Dalam WMK	0
Waktu Sesuai Luar WMK	1
Waktu Tidak Sesuai Luar WMK	2
Waktu Tidak Sesuai Dalam WMK	3

Data training ditunjukkan di tabel 4 dan di tabel 5 adalah data yang akan dijadikan *data testing* dengan rasio 80:20.

Tabel 4. *Data Training* Rasio 80:20

No	Jarak Tempuh	Waktu Tempuh	Label Encode
1	9.7	30	2
2	12.6	19	2
3	1.6	17	3
...
698	12.3	10	1

Tabel 5. *Data Testing* Rasio 80:20

No	Jarak Tempuh	Waktu Tempuh	Label Encode
699	6.5	10	0
700	5.2	16	3
701	11	25	2
...
873	7.7	31	2

Data training ditunjukkan di tabel 6 dan di tabel 7 adalah data yang akan dijadikan *data testing* dengan rasio 70:30.

Tabel 6. *Data Training* Rasio 70:30

No	Jarak Tempuh	Waktu Tempuh	Label Encode
1	9.7	30	2
2	12.6	19	2
3	1.6	17	3
...
611	10.6	18	2

Tabel 7. *Data Testing* Rasio 70:30

No	Jarak Tempuh	Waktu Tempuh	Label Encode
612	5.5	13	0
613	6.8	5	0
614	11.4	14	1
...
873	7.7	31	2

Data training ditunjukkan di tabel 8 dan di tabel 9 adalah data yang akan dijadikan *data testing* dengan rasio 60:40.

Tabel 8. *Data Training* Rasio 60:40

No	Jarak Tempuh	Waktu Tempuh	Label Encode
1	9.7	30	2
2	12.6	19	2
3	1.6	17	3
...
523	8	17	2

Tabel 9. *Data Testing* Rasio 60:40

No	Jarak Tempuh	Waktu Tempuh	Label Encode
524	3.5	13	0
525	12.7	18	2
526	9.2	27	2
...
873	7.7	31	2

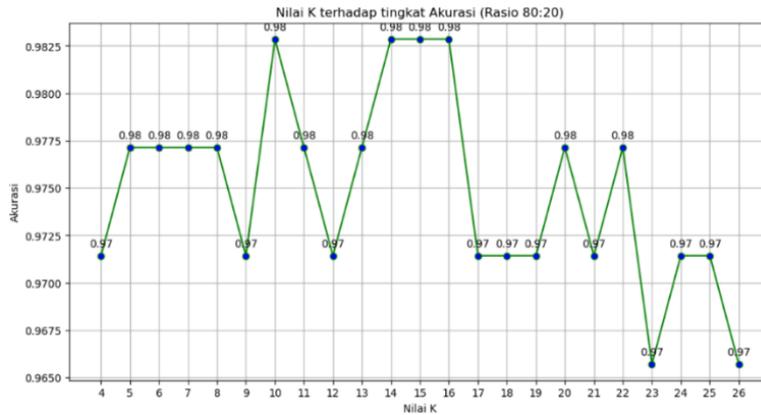
4.2. Implementasi Algoritma

Implementasi algoritma KNN (*K-Nearest Neighbor*) dan uji performa algoritma pada penelitian ini dilakukan menggunakan aplikasi berbahasa pemrograman *Python* berbasis web

Jupyter Notebook. Berikut ditunjukkan beberapa uji coba algoritma *KNN (K-Nearest Neighbor)* dengan rasio 80:20, 70:30 dan 60:40.

4.2.1. Uji Coba 1 Rasio 80:20

Dalam metode *KNN* dibutuhkan nilai *K* untuk menetapkan berapa banyak kedekatan tetangga yang akan digunakan pada model ini. Untuk menentukan nilai *K* dilakukan uji coba nilai *K* terhadap tingkat akurasi yang dihasilkan. Nilai *K* dapat dicari dengan rentang nilai $K = \sqrt{n}$, dimana *n* adalah jumlah *data training* [18]. Pada percobaan kali ini pada rasio 80:20 didapati *data training* berjumlah 698 data, maka untuk rentang nilai uji coba untuk mencari nilai *K* adalah jumlah kategori klasifikasi = 4 hingga $\sqrt{698} \approx 26$. Pada gambar 1 menunjukkan grafik nilai *K* terhadap tingkat akurasi.



Gambar 1. Nilai *K* terhadap tingkat Akurasi pada rasio 80:20

Pada gambar 1 memperlihatkan uji coba $K = 4$ hingga $K = 26$ pada rasio data 80:20, dengan tingkat akurasi tertinggi pada $K = 10$, $K = 14$, $K = 15$ dan $K = 16$ yaitu sebesar 0.98. Selanjutnya yang digunakan adalah nilai $K = 15$, dipilih nilai tersebut karena nilainya ganjil tujuannya agar menghindari hasil voting seimbang [19].

	Jarak_Tempuh	Respons_Time	Label_Sebenarnya	Label_Prediksi	Status
0	20.6	25.0	2.0	2.0	True
1	3.9	7.0	0.0	0.0	True
2	2.6	10.0	0.0	0.0	True
3	7.8	20.0	2.0	2.0	True
4	2.2	5.0	0.0	0.0	True
..
170	21.3	24.0	2.0	2.0	True
171	9.2	15.0	2.0	2.0	True
172	2.2	2.0	0.0	0.0	True
173	24.3	34.0	2.0	2.0	True
174	8.4	13.0	1.0	1.0	True

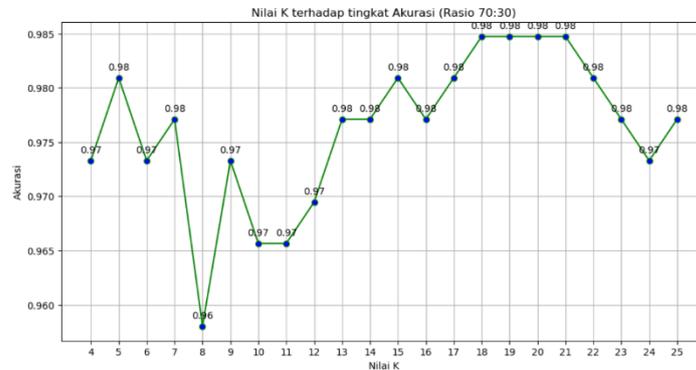
[175 rows x 5 columns]
 Total data testing: 175
 Total prediksi benar: 172
 Total prediksi salah: 3

Gambar 2. Uji Coba 1 Rasio 80:20

Dari uji coba pertama pada rasio 80:20 dengan menggunakan nilai $K = 15$ dari total *data testing* berjumlah 175 data menghasilkan 172 data diprediksi benar dan 3 data diprediksi salah. Ini ditunjukkan sesuai dengan yang tampil pada sistem yang diperlihatkan pada gambar 2.

4.2.2. Uji Coba 2 Rasio 70:30

Pada percobaan kali ini pada rasio 70:30 didapati *data training* berjumlah 611 data, maka untuk rentang nilai uji coba untuk mencari nilai *K* adalah jumlah kategori klasifikasi = 4 hingga $\sqrt{611} \approx 25$. Pada gambar 3 menunjukkan grafik nilai *K* terhadap tingkat akurasi.



Gambar 3. Nilai K terhadap tingkat Akurasi pada rasio 70:30

Pada gambar 3 memperlihatkan uji coba $K = 4$ hingga $K = 25$ pada rasio data 70:30, dengan tingkat akurasi tertinggi pada $K = 18$, $K = 19$, $K = 20$ dan $K = 21$ yaitu sebesar 0.98. Selanjutnya yang digunakan adalah nilai $K = 19$.

Dari uji coba kedua pada rasio 70:30 dengan menggunakan nilai $K = 19$ dari total *data testing* berjumlah 262 data menghasilkan 258 data diprediksi benar dan 4 data diprediksi salah. Ini ditunjukkan sesuai dengan yang tampil pada sistem yang diperlihatkan pada gambar 4.

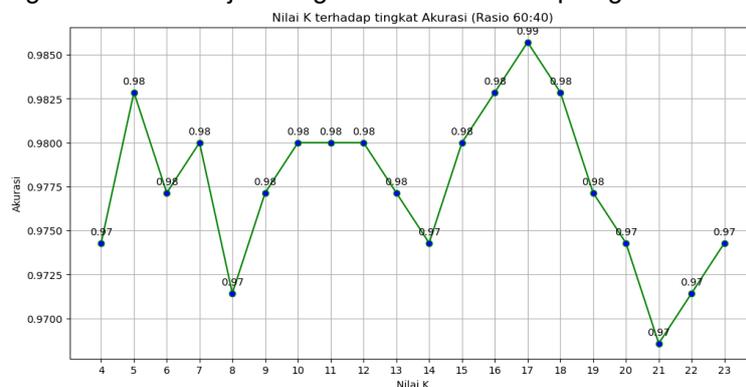
	Jarak_Tempuh	Respons_Time	Label_Sebenarnya	Label_Prediksi	Status
0	20.6	25.0	2.0	2.0	True
1	3.9	7.0	0.0	0.0	True
2	2.6	10.0	0.0	0.0	True
3	7.8	20.0	2.0	2.0	True
4	2.2	5.0	0.0	0.0	True
--	--	--	--	--	--
257	10.2	26.0	2.0	2.0	True
258	3.2	8.0	0.0	0.0	True
259	2.5	10.0	0.0	0.0	True
260	4.0	12.0	0.0	0.0	True
261	5.8	15.0	3.0	3.0	True

[262 rows x 5 columns]
 Total data testing: 262
 Total prediksi benar: 258
 Total prediksi salah: 4

Gambar 4. Uji Coba 2 Rasio 70:30

4.2.3. Uji Coba 3 Rasio 60:40

Pada percobaan kali ini pada rasio 60:40 didapati *data training* berjumlah 523 data, maka untuk rentang nilai uji coba untuk mencari nilai *K* adalah jumlah kategori klasifikasi = 4 hingga $\sqrt{523} \approx 23$. Pada gambar 5 menunjukkan grafik nilai *K* terhadap tingkat akurasi.



Gambar 5. Nilai K terhadap tingkat Akurasi pada rasio 60:40

Pada gambar 5 memperlihatkan uji coba $K = 4$ hingga $K = 23$ pada rasio data 60:40, dengan tingkat akurasi tertinggi pada $K = 17$ yaitu sebesar 0,99. Selanjutnya yang digunakan adalah nilai $K = 17$.

Dari uji coba kedua pada rasio 60:40 dengan menggunakan nilai $K = 17$ dari total *data testing* berjumlah 350 data menghasilkan 345 data diprediksi benar dan 5 data diprediksi salah. Ini ditunjukkan sesuai dengan yang tampil pada sistem yang diperlihatkan pada gambar 6.

	Jarak_Tempuh	Respons_Time	Label_Sebenarnya	Label_Prediksi	Status
0	20.6	25.0	2.0	2.0	True
1	3.9	7.0	0.0	0.0	True
2	2.6	10.0	0.0	0.0	True
3	7.8	20.0	2.0	2.0	True
4	2.2	5.0	0.0	0.0	True
..
345	11.3	15.0	2.0	2.0	True
346	18.4	35.0	2.0	2.0	True
347	9.9	25.0	2.0	2.0	True
348	10.0	18.0	2.0	2.0	True
349	10.6	15.0	2.0	2.0	True

[350 rows x 5 columns]
 Total data testing: 350
 Total prediksi benar: 345
 Total prediksi salah: 5

Gambar 6. Uji Coba 3 Rasio 60:40

4.3. Uji Performa Algoritma

Pada kali ini akan diuji akurasi, presisi, *recall* dan *F1-score* terhadap algoritma *KNN* (*K-Nearest Neighbor*) yang dipakai untuk memproses klasifikasi data waktu tanggap kebakaran. Berikut ditunjukkan uji performa algoritmanya.

4.3.1. Uji Performa Algoritma Rasio 80:20

Pada uji performa algoritma pertama dengan rasio 80:20 dengan nilai $K = 15$. Pada sistem menunjukkan tingkat akurasi sebesar 98%, presisi sebesar 99%, *recall* sebesar 96% dan *F1-score* sebesar 97%. Hasil ini ditampilkan pada gambar 7.

```
Akurasi: 0.9828571428571429
Presisi: 0.9883202955236854
Recall: 0.9643719806763285
F1 Score: 0.9755702584401138
```

Gambar 7. Hasil Uji Performa Algoritma Rasio 80:20

4.3.2. Uji Performa Algoritma Rasio 70:30

Pada uji performa algoritma kedua dengan rasio 70:30 dengan nilai $K = 19$. Pada sistem menunjukkan tingkat akurasi sebesar 98%, presisi sebesar 99%, *recall* sebesar 97% dan *F1-score* sebesar 98%. Hasil ini ditampilkan pada gambar 8.

```
Akurasi: 0.9847328244274809
Presisi: 0.9894542772861357
Recall: 0.968939393939394
F1 Score: 0.9785095507129404
```

Gambar 8. Hasil Uji Performa Algoritma Rasio 70:30

4.3.3. Uji Performa Algoritma Rasio 60:40

Pada uji performa algoritma ketiga dengan rasio 60:40 dengan nilai $K = 17$. Pada sistem menunjukkan tingkat akurasi sebesar 98%, presisi sebesar 99%, *recall* sebesar 97% dan *F1-score* sebesar 98%. Hasil ini ditampilkan pada gambar 9.

```
Akurasi: 0.9857142857142858
Presisi: 0.9902251818570817
Recall: 0.9688868042526579
F1 Score: 0.9789700678322937
```

Gambar 9. Hasil Uji Performa Algoritma Rasio 60:40

4.4. Pembahasan

Pada penelitian ini telah mengimplementasikan model klasifikasi pada objek waktu dalam konteks kebencanaan yaitu data waktu tanggap kebakaran menggunakan metode *KNN (K-Nearest Neighbor)*. Diketahui dari ketiga uji coba pada semua rasio *data training* dan *data testing* yang telah ditetapkan, rata-rata didapatkan hasil tingkat akurasi yang baik yaitu sebesar 98%. Penelitian ini sejalan dengan penelitian terdahulu yang meneliti klasifikasi pada objek waktu dalam konteks manajemen dokumen seperti pada penelitian yang dilakukan oleh Dinda Nur Oktaviany dan Wawan Joko Pranoto pada tahun 2024 [5] yang menghasilkan performa yang baik. Bukan hanya pada penelitian klasifikasi pada objek waktu dalam konteks manajemen dokumen, penelitian klasifikasi pada objek waktu dalam konteks akademik juga menghasilkan performa yang baik seperti yang dilakukan oleh Arie Yandi dan Yogi Primadasa pada tahun 2018 [6], Irkham Widhi Saputro dan Bety Wulan Sari pada tahun 2019 [7], Inna Alvi Nikmatun dan Indra Waspada pada tahun 2019 [8], dan Supardi Salmu dan Achmad Solichin pada tahun 2017 [9].

Dengan penelitian ini, maka telah dibuktikan bahwa metode *KNN (K-Nearest Neighbor)*, cocok digunakan untuk mengklasifikasikan objek waktu dalam berbagai konteks, seperti manajemen dokumen, akademik maupun kebencanaan seperti yang sedang diteliti dengan hasil performa yang baik. Maka dari itu, data yang diperoleh dari metode ini layak dijadikan bahan evaluasi lebih lanjut dan dapat mempermudah proses klasifikasi data waktu tanggap kebakaran untuk memperbaiki layanan Pemadam Kebakaran Kabupaten Sleman kepada masyarakat.

5. Kesimpulan

Rata-rata hasil uji coba dari ketiga skenario menunjukkan tingkat Akurasi 98%, nilai Presisi 98%, *Recall* mencapai 96% dan *F1-Score* sebesar 97%. Berdasarkan hasil pengujian klasifikasi waktu tanggap kebakaran oleh Pemadam Kebakaran di Kabupaten Sleman menggunakan metode *KNN (K-Nearest Neighbor)*, bisa ditarik kesimpulan bahwa metode *KNN* mampu memberikan performa klasifikasi yang sangat baik terhadap data waktu tanggap kebakaran.

Hasil penelitian ini merekomendasikan perlunya komparasi antara metode *KNN* dengan metode klasifikasi lainnya guna menentukan pendekatan paling optimal dalam mengklasifikasikan data waktu tanggap kebakaran. Penulis juga menyarankan peneliti selanjutnya menggunakan data terbaru untuk mendapatkan hasil yang sesuai dengan kondisi sebenarnya.

Daftar Referensi

- [1] Menteri Pekerjaan Umum Republik Indonesia, *Peraturan Menteri Pekerjaan Umum Nomor: 20/Prt/M/2009 Tentang Pedoman Teknis Manajemen Proteksi Kebakaran Di Perkotaan*. Indonesia, 2009.
- [2] A. Fitri, Musri, and I. Syahrial, "Implementasi Standar Pelayanan Minimal (SPM) Penanggulangan Bencana Kebakaran Pada Pemadam Kebakaran Kabupaten Pesisir Selatan," *J. Ilm. Ekotrans Erud.*, vol. 2, no. 1, pp. 55–65, 2022.
- [3] I. Setiaji and V. Lusiana, "Uji akurasi Metode KNN dan Citra HSI dalam Mengklasifikasi Batik Solo Berdasarkan Motif," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 12, no. 3, pp. 1013-122, 2023, doi: 10.35889/jutisi.v12i3.1377.
- [4] A. J. Arifin and A. Nugroho, "Uji Akurasi Penggunaan Metode KNN dalam Analisis Sentimen Kenaikan Harga BBM pada Media Twitter," *Progresif J. Ilm. Komput.*, vol. 19, no. 2, pp. 700-712, 2023, doi: 10.35889/progresif.v19i2.1288.
- [5] Dinda Nur Octaviany and Wawan Joko Pranoto, "Klasifikasi Waktu Pada Dokumen Persetujuan Accounting Voucher," *J. Tek. Mesin, Ind. Elektro dan Inform.*, vol. 3, no. 1, pp. 47–60, 2023, doi: 10.55606/jtmei.v3i1.3215.
- [6] A. Y. Saputra and Y. Primadasa, "Penerapan Teknik Klasifikasi Untuk Prediksi Kelulusan Mahasiswa Menggunakan Algoritma K-Nearest Neighbor," *Techno.Com*, vol. 17, no. 4, pp. 395–403, 2018, doi: 10.33633/tc.v17i4.1864.
- [7] I. W. Saputro and B. W. Sari, "Uji Performa Algoritma Naïve Bayes untuk Prediksi Masa Studi Mahasiswa," *Creat. Inf. Technol. J.*, vol. 6, no. 1, pp. 1-13, 2020, doi: 10.24076/citec.2019v6i1.178.
- [8] Nikmatun, I. Alvi, Waspada, and Indra, "Implementasi Data Mining Untuk Klasifikasi Masa

- Studi Mahasiswa Menggunakan Algoritma K-Nearest Neighbor,” *J. SIMETRIS*, vol. 10, no. 2, pp. 421–432, 2019.
- [9] D. Salmu, S. and A. Solichin, “Prediksi Tingkat Kelulusan Mahasiswa Tepat Waktu Menggunakan Naïve Bayes : Studi Kasus UIN Syarif Hidayatullah Jakarta Prediction of Timeliness Graduation of Students Using Naïve Bayes : A Case Study at Islamic State University Syarif Hidayatullah Jakarta,” *Pros. Semin. Nas. Multidisiplin Ilmu*, no. April, pp. 701–709, 2017.
- [10] A. Prasetyo and A. Witanti, “Implementasi Metode K-Nearest Neighbor Dalam Menentukan Waktu Optimal Penarikan Pesanan Driver Ojol,” *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 2, pp. 255–269, 2024.
- [11] Yahya and W. P. Hidayanti, “Penerapan Algoritma K-Nearest Neighbor Untuk Klasifikasi Efektivitas Penjualan Vape (Rokok Elektrik) pada ‘ Lombok Vape On ,”” *J. Inform. dan Teknol.*, vol. 3, no. 2, pp. 104–114, 2020, [Online]. Available: https://e-journal.hamzanwadi.ac.id/index.php/infotek/article/view/2279/pdf_23
- [12] S. H. Rukmawan, F. R. Aszhari, Z. Rustam, and J. Pandelaki, “Cerebral Infarction Classification Using the K-Nearest Neighbor and Naive Bayes Classifier,” *J. Phys. Conf. Ser.*, vol. 1752, no. 1, p. 012045, 2021, doi: 10.1088/1742-6596/1752/1/012045.
- [13] F. T. Admojo and Ahsanawati, “Klasifikasi Aroma Alkohol Menggunakan Metode KNN,” *Indones. J. Data Sci.*, vol. 1, no. 2, pp. 34–38, 2020, doi: 10.33096/ijodas.v1i2.12.
- [14] D. Cahyanti, A. Rahmayani, and S. A. Husniar, “Analisis performa metode Knn pada Dataset pasien pengidap Kanker Payudara,” *Indones. J. Data Sci.*, vol. 1, no. 2, pp. 39–43, 2020, doi: 10.33096/ijodas.v1i2.13.
- [15] A. A. D. Halim and S. Anraeni, “Analisis Klasifikasi Dataset Citra Penyakit Pneumonia menggunakan Metode K-Nearest Neighbor (KNN),” *Indones. J. Data Sci.*, vol. 2, no. 1, pp. 01–12, 2021, doi: 10.33096/ijodas.v2i1.23.
- [16] H. A. Dwi Fasnuari, H. Yuana, and M. T. Chulkamdi, “Penerapan Algoritma K-Nearest Neighbor Untuk Klasifikasi Penyakit Diabetes Melitus,” *Antivirus J. Ilm. Tek. Inform.*, vol. 16, no. 2, pp. 133–142, 2022, doi: 10.35457/antivirus.v16i2.2445.
- [17] Ichsanudin and Supatman, “Klasifikasi Penumpang Kereta Api DAOP 6 Yogyakarta Berdasarkan Kelas Stasiun Menggunakan KNN,” *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 4, pp. 318–328, 2024.
- [18] M. Fansyuri and D. Yunita, “Implementasi K-Nearest Neighbor Untuk Klasifikasi Jenis Kelamin Berdasarkan Analisis Citra Wajah,” *Klik*, vol. 3, no. 6, pp. 1208–1216, 2023, doi: 10.30865/klik.v3i6.827.
- [19] N. Safitri, D. Kusnandar, and S. Martha, “Implementasi Algoritma K-nearest Neighbor Dengan Normalisasi Z-score Dalam Klasifikasi Penerima Bantuan Sosial Desa Serunai,” *Bul. Ilm. Math. Stat. dan Ter.*, vol. 13, no. 1, pp. 99–106, 2024, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jbmstr/article/view/74063>