



Penerapan K-Nearest Neighbors untuk Klasifikasi Kasus Hukum di Pengadilan Federal Australia

Karan¹, M. Alidin², Rafi Fadilah³, Taslim⁴

Email: ¹220401206@student.umri.ac.id, ²220401285@student.umri.ac.id, ³220401249@student.umri.ac.id, ⁴taslim.malano@gmail.com

¹²³⁴Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

Diterima: 13 Januari 2025 | Direvisi: 30 April 2025 | Disetujui: 22 Mei 2025

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Dengan semakin berkembangnya teknologi informasi, khususnya di bidang hukum, analisis kasus hukum kini dapat dilakukan secara lebih efisien melalui penerapan pembelajaran mesin. Penelitian ini bertujuan untuk mengklasifikasikan kasus hukum berdasarkan status Dikutip dan Tidak Dikutip menggunakan algoritma K-Nearest Neighbor (KNN). Proses klasifikasi melibatkan tahapan preprocessing teks, pembobotan kata menggunakan metode TF-IDF, dan pengujian algoritma KNN dengan berbagai nilai parameter k. Data penelitian diambil dari Pengadilan Federal Australia (FCA) yang mencakup kasus hukum tahun 2006–2009, dengan tiga skenario pembagian data: 90:10, 80:20, dan 70:30. Evaluasi model dilakukan menggunakan confusion matrix dengan metrik akurasi, precision, recall, dan F1-score. Hasil terbaik diperoleh pada skenario 80:20 dengan nilai k=3, menghasilkan akurasi sebesar 96,36%, precision 96,80%, recall 99,49%, dan F1-score 98,13%. Dengan hasil ini, algoritma KNN terbukti efektif dalam mendukung proses klasifikasi dokumen hukum secara otomatis.

Kata kunci: K-nearest neighbor, klasifikasi, tf-idf, prediksi,

Application of K-Nearest Neighbors to the Classification of Legal Cases in the Federal Courts of Australia

Abstract

With the development of information technology, especially in the legal field, legal case analysis can now be done more efficiently through the application of machine learning. This study aims to classify legal cases based on the status of Cited and Uncited using the K-Nearest Neighbor (KNN) algorithm. The classification process includes text preprocessing stages, word weighting using the TF-IDF method, and testing the KNN algorithm with various values of the parameter k. The research data was taken from the Federal Court of Australia (FCA) covering legal cases from 2006–2009, with three data sharing scenarios: 90:10, 80:20, and 70:30. The evaluation model was carried out using a confusion matrix with metrics of accuracy, precision, recall, and F1-score. The best results were obtained in the 80:20 scenario with a value of k = 3, resulting in an accuracy of 96.36%, a precision of 96.80%, a recall of 99.49%, and an F1-score of 98.13%. With these results, the KNN algorithm is proven to be effective in supporting the automatic legal document classification process.

Keywords: K-nearest neighbor, classification, tf-idf, prediction

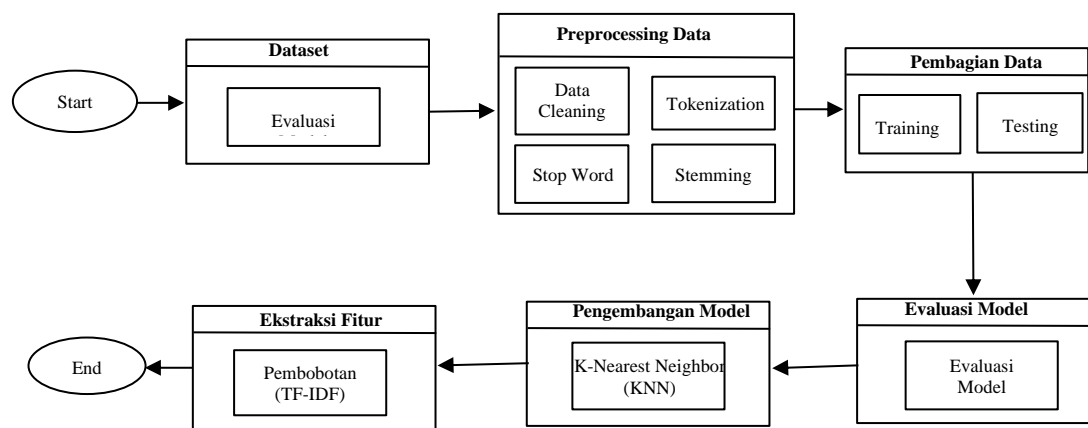
1. PENDAHULUAN

Hukum merupakan seperangkat aturan yang mengatur perilaku dalam masyarakat dengan tujuan untuk mewujudkan keteraturan dan kedamaian, keadilan, serta perlindungan hak individu maupun kelompok. Hukum berperan sebagai pedoman untuk menentukan benar atau salahnya suatu tindakan, dengan memberikan sanksi bagi pelanggaran yang terjadi. Dalam praktiknya, hukum sering kali membutuhkan preseden sebagai acuan untuk memutuskan kasus tertentu [1]. Namun, seiring dengan

bertambahnya jumlah kasus yang muncul setiap tahun, menentukan relevansi sebuah kasus secara manual menjadi tantangan yang kompleks. Oleh karena itu, penggunaan teknologi, seperti pembelajaran mesin, menjadi langkah yang sangat diperlukan untuk mendukung efisiensi dalam proses analisis hukum. Salah satu pendekatan modern untuk menangani tantangan ini adalah dengan menerapkan metode pembelajaran mesin, khususnya dalam klasifikasi data. Pembelajaran mesin jenis supervised learning menyediakan berbagai algoritma yang dapat digunakan untuk mengelompokkan atau memprediksi data. Beberapa algoritma yang sering digunakan meliputi K-Nearest Neighbor (KNN), Naive Bayes Classifier (NBC), Support Vector Machine (SVM), Neural Network (NN), Random Forest Classifier (RFC), AdaBoost Classifier (ABC), hingga Quadratic Discriminant Analysis (QDA). Setiap algoritma memiliki pendekatan yang berbeda dalam memproses data, dengan kelebihan dan kekurangannya masing-masing [2]. Salah satu algoritma yang banyak digunakan karena kesederhanaannya adalah KNN. Algoritma ini bekerja dengan cara memanfaatkan data yang telah dilabeli sebelumnya dan mengklasifikasikan data baru berdasarkan jarak terdekat dengan sejumlah K tetangga pada data pelatihan [3]. Pendekatan ini cocok untuk dataset yang memiliki pola sederhana, namun tetap efektif dalam memberikan hasil yang kompetitif. Berbagai penelitian sebelumnya telah menunjukkan keberhasilan algoritma KNN dalam menangani klasifikasi teks dan data berbasis kategori. Dalam bidang kesehatan, algoritma KNN telah diterapkan untuk memprediksi kategori pasien berdasarkan gejala atau parameter tertentu [4]. Penelitian tersebut menunjukkan bahwa KNN dan variannya, seperti Hassanat KNN dan Ensemble KNN, mampu meningkatkan akurasi prediksi pada berbagai dataset medis dengan hasil yang kompetitif [2]. Selain itu, penelitian mengenai klasifikasi teks multi-label berskala besar pada legislasi Uni Eropa menunjukkan bahwa metode berbasis ekstraksi fitur seperti TF-IDF, jika diterapkan dengan algoritma yang tepat, dapat meningkatkan akurasi klasifikasi dokumen hukum [5]. Namun, penerapan KNN secara spesifik untuk klasifikasi kasus hukum berdasarkan status dikutip (*Cited*) dan tidak dikutip (*Uncited*) masih sangat terbatas. Penelitian ini mencoba menjembatani kesenjangan tersebut dengan memanfaatkan algoritma KNN untuk membantu klasifikasi dalam konteks hukum. Penelitian ini berfokus pada penggunaan algoritma KNN untuk klasifikasi kasus hukum berdasarkan status dikutip (*Cited*) dan tidak dikutip (*uncited*). Dengan memanfaatkan dataset dari Pengadilan Federal Australia (FCA), penelitian ini mencakup tahapan preprocessing data, pembobotan menggunakan metode TF-IDF, serta pengujian dengan berbagai nilai parameter kkk. Evaluasi model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score untuk memastikan keandalan hasil klasifikasi. Studi ini diharapkan dapat memberikan kontribusi dalam mendukung efisiensi analisis hukum, khususnya dalam menentukan preseden hukum yang relevan secara otomatis, serta menjawab kesenjangan penelitian sebelumnya yang masih terbatas pada penerapan KNN di bidang klasifikasi dokumen hukum.

2. METODE PENELITIAN

Dengan menerapkan algoritma KNN untuk mengklasifikasikan kasus hukum berdasarkan *Cited* dan *Uncited*, penelitian ini dirancang secara sistematis agar setiap tahapan penelitian dapat dilakukan sesuai dengan hasil yang diharapkan. Proses penelitian dijelaskan secara menyeluruh dalam diagram alur yang disajikan pada Gambar 1.



Gambar 1. Tahap Penelitian

Penelitian ini diawali dengan pengumpulan dataset teks hukum yang diambil dari kasus-kasus Pengadilan Federal Australia (FCA) melalui platform AustLII. Dataset ini mencakup kasus dari tahun 2006 hingga 2009 dengan informasi yang meliputi slogan, kalimat kutipan, slogan kutipan, serta kelas kutipan. Setelah data dikumpulkan, dilakukan proses preprocessing untuk menjamin keandalan data. Langkah-langkah preprocessing mencakup normalisasi teks, eliminasi kata-kata yang tidak relevan (stop words), tokenisasi, dan stemming, sehingga data bebas dari redundansi dan lebih siap untuk dianalisis. Data yang telah melalui proses tersebut selanjutnya dipisahkan ke dalam dua kelompok: data untuk pelatihan model (training) dan data untuk pengujian model (testing). Proses pemisahan ini bertujuan memastikan model memiliki kemampuan belajar yang optimal serta dapat diuji secara objektif. Selanjutnya, algoritma KNN digunakan untuk menganalisis data dan memprediksi kategori kutipan berdasarkan jarak antar data. Evaluasi kinerja model dilakukan menggunakan berbagai metrik seperti tingkat ketetapan (akurasi), precision, recall, dan F1-score dalam memastikan kualitas prediksi model. Hasil evaluasi divalidasi, dan model yang dihasilkan dioptimalkan untuk memenuhi tujuan penelitian ini.

2.1. Dataset

Data yang dianalisis dalam penelitian ini berasal dari kasus-kasus hukum Pengadilan Federal Australia (FCA) yang diperoleh melalui platform AustLII [6]. Dataset mencakup kasus hukum dari tahun 2006 hingga 2009, dengan informasi seperti slogan, kalimat kutipan, slogan kutipan, serta kelas kutipan. Dataset ini dibagi menjadi dua kategori utama, yaitu *Cited* (termasuk *cited* dan *applied*) dan *Uncited* (termasuk *related* dan *distinguished*), untuk mendukung proses klasifikasi berbasis teks.

2.2. Preprocessing Data

Preprocessing data adalah proses pengolahan data yang melibatkan langkah-langkah awal seperti pemilihan dan pembersihan data (*data cleaning*) untuk meningkatkan kualitas serta relevansi data sebelum digunakan dalam analisis lebih lanjut [7]. Yang meliputi (a) pemilihan dan pembersihan data (*data cleaning*) dengan menjadikan seluruh teks dalam bentuk huruf kecil serta menghilangkan karakter yang tidak diperlukan, seperti angka dan tanda baca, tanpa mengubah makna teks [8]. Langkah ini bertujuan untuk menyederhanakan representasi data dan mengurangi noise pada dataset; (b) data diproses lebih lanjut melalui tokenisasi, yaitu dengan memisahkan teks menjadi kata-kata individual serta menghapus spasi berlebih dan karakter tidak relevan, seperti tanda baca, emoji, dan URL [9]. Tokenisasi mempermudah analisis data berbasis teks dengan memisahkan kata-kata yang nantinya digunakan dalam model klasifikasi; (c) penghapusan stop words menggunakan pustaka NLTK untuk mengeliminasi kata-kata yang umum seperti "dan," "atau," dan "di," yang tidak memiliki pengaruh besar terhadap hasil analisis; dan (d) *stemming*, yaitu proses perubahan kata menjadi bentuk dasar dengan menggunakan algoritma Porter Stemmer [10]. *Stemming* dilakukan untuk mengurangi dimensi fitur dan memastikan bahwa kata-kata dengan arti yang sama memiliki representasi yang seragam dalam analisis model.

2.3. Pembagian Data

Proses pemisahan dataset terdiri dari dua kelompok utama: data latih (*training*) dan data uji (*testing*). Dataset yang digunakan dalam penelitian ini terdiri dari teks hukum dengan berbagai atribut yang telah diproses melalui tahap preprocessing sebelumnya. Data pelatihan digunakan untuk melatih algoritma model klasifikasi berbasis KNN, Sementara itu, data uji digunakan untuk mengukur kinerja model yang telah dikembangkan. Pemisahan ini bertujuan agar model dapat dilatih secara efektif menggunakan sebagian data, sekaligus memungkinkan evaluasi yang objektif pada data yang tidak pernah dilihat sebelumnya oleh model.

2.4. Ekstraksi Fitur

Setelah data melalui tahap preprocessing, langkah berikutnya adalah ekstraksi fitur untuk mengubah teks menjadi format angka (numerik) yang dapat dipahami oleh model klasifikasi. Penelitian ini menggunakan pendekatan *TF-IDF* (*Term Frequency-Inverse Document Frequency*), yang memberikan bobot pada setiap kata (*term*) dalam dokumen berdasarkan frekuensi kemunculannya dalam dokumen tertentu dibandingkan dengan keseluruhan koleksi dokumen [11]. Pendekatan ini dirancang untuk memberikan bobot lebih pada kata-kata yang memiliki relevansi tinggi dalam dokumen tertentu, sekaligus mengurangi pengaruh kata-kata yang muncul secara umum di banyak dokumen.

Secara umum, metode TF-IDF melibatkan dua elemen utama, yaitu TF (*Term Frequency*) dan IDF (*Inverse Document Frequency*). Kedua komponen ini memiliki rumus serta prinsip kerja yang berbeda, tetapi pada akhirnya digabungkan untuk menghasilkan bobot akhir berdasarkan kombinasi TF dan IDF, seperti dijelaskan berikut ini:

TF (*Term Frequency*)

Prosesnya dimulai dengan mengukur seberapa sering suatu kata muncul dalam sebuah dokumen. karena panjang dokumen dapat bervariasi, nilai TF kemudian dinormalisasi dengan membagi frekuensi kata tersebut dengan panjang dokumen.

$$tf_{t,d} = \frac{n_{t,d}}{(\text{total number of term in document})} \quad (1)$$

Keterangan:

Tf = frekuensi kemunculan suatu kata dalam sebuah dokumen

IDF (*Inverse Document Frequency*)

Setelah perhitungan nilai TF, langkah berikutnya yaitu menghitung IDF, yang digunakan untuk menilai pentingnya suatu kata dalam konteks dokumen. Semakin rendah nilai IDF, semakin sedikit kontribusi yang diberikan oleh kata tersebut dalam keseluruhan kumpulan dokumen, sedangkan nilai IDF yang lebih besar menunjukkan kata tersebut lebih signifikan.

$$idf_d = \log \frac{\text{number of document}}{(\text{total number of term in document})} \quad (2)$$

Keterangan:

Idf = mengukur penting/tidak sebuah kata dalam dokumen

TF-IDF (Term Frequency - Inverse Document Frequency)

Setelah memperoleh nilai TF dan IDF, tahap selanjutnya adalah menentukan nilai TF-IDF dengan cara mengalikan kedua nilai tersebut.

$$tfidf_{t,d} = tf_{t,d} \times idf_d \quad (3)$$

Keterangan:

TF-IDF = hasil penggabungan antara TF dan IDF

2.5. Pengembangan Model

Pada tahap ini, algoritma KNN digunakan untuk mengembangkan model klasifikasi yang mampu membedakan kasus hukum berdasarkan status dikutip dan tidak dikutip. Algoritma ini bekerja berdasarkan prinsip mencari sejumlah K tetangga terdekat dari suatu data menggunakan perhitungan jarak tertentu [12].

Algoritma KNN menggunakan Jarak Euclidean, yaitu sebuah metode untuk menghitung jarak yang mengukur kedekatan antara dua titik dalam ruang berdimensi lebih dari satu. Jarak ini dihitung berdasarkan akar kuadrat dari jumlah kuadrat selisih nilai setiap koordinat. Rumus jarak Euclidean dapat dituliskan sebagai berikut:

$$d_i = \sqrt{\sum_{i=1}^n (x_{2i} - x_{1i})^2} \quad (4)$$

Dengan d adalah jarak Euclidean, p adalah dimensi data, i adalah variabel data, x1 adalah data sampel, dan x2 adalah data training atau data testing [13].

2.6. Evaluasi Model

Tahap evaluasi model dilakukan untuk mengukur performa algoritma KNN dalam mengklasifikasikan kasus hukum berdasarkan status dikutip dan tidak dikutip. Evaluasi ini menggunakan beberapa metrik utama, yaitu akurasi, precision, recall, dan F1-score [14]. Akurasi mengukur persentase keseluruhan prediksi yang benar dari data uji. Precision menggambarkan kemampuan model dalam memprediksi data positif dengan benar dibandingkan seluruh prediksi positif. Recall menilai sejauh mana model dapat mendeteksi semua data positif yang relevan, sedangkan F1-score merupakan keseimbangan antara precision dan recall, yang berguna untuk mengevaluasi performa model, terutama ketika dataset memiliki distribusi kelas yang tidak seimbang.

Confusion Matrix digunakan untuk memberikan analisis mendalam mengenai hasil klasifikasi [15]. Evaluasi menggunakan Confusion Matrix merupakan suatu metode yang memungkinkan untuk mencatat sejauh mana akurasi atau kesalahan prediksi suatu algoritma dalam proses klasifikasi [16]. Confusion Matrix membantu memvisualisasikan distribusi prediksi model dalam empat kategori, yaitu TP menggambarkan data positif yang tepat dikenali sebagai positif, TN menggambarkan data negatif yang akurat diprediksi sebagai negatif, FP mencerminkan data negatif yang secara keliru dikategorikan sebagai positif, dan FN adalah data positif yang teridentifikasi secara salah sebagai negatif [17].

Tab 1. *Confusion matrix*

Predict	Actual	
	True	False
True	True Positif	False Negatif
False	False Positif	True Negatif

Hasil evaluasi ini memberikan wawasan komprehensif tentang mengenai performa model dan membantu dalam mengidentifikasi pola kesalahan yang mungkin terjadi. Dengan demikian, langkah-langkah perbaikan dapat dilakukan untuk mengoptimalkan kemampuan model dalam proses klasifikasi.

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Data

Kumpulan data diperoleh dari Pengadilan Federal Australia (FCA) melalui platform AustLII, yang mencakup kasus-kasus hukum dari tahun 2006 hingga 2009. Dataset ini terdiri dari total 15.263 dokumen hukum yang diklasifikasikan ke dalam dua kategori utama, yaitu *cited* (termasuk *cited* dan *applied*) sebanyak 14.548 dokumen dan *uncited* (termasuk *related* dan *distinguished*) sebanyak 715 dokumen.

Table 2. Dataset

No	Case id	Case Outcome	Case Title	Case Text
1	Case1	Cited	Alpine Hardwood (Aust) Pty Ltd v Hardys Pty Ltd (No 2)	Ordinarily that discretion will be
2	Case2	Cited	Black v Lipovac [1998] FCA 699 ; (1998) 217 ALR 386	The general principles governing the exercise.
...
25205	Case25205	Cited	Spiel v Commodity Brokers Australia Pty Ltd (In liq) (198..	Once the threshold prescribed by s 1335 is
25206	Case25206	Distinguished	Tullock Ltd v Walker (Unreported, Supreme Court of	Given the extent to which Deumer stands to gain from the
25207	Case25207	Distinguished	Yandil Holdings Pty Ltd v Insurance Co of North America	In my view, it is clear that the Court may do ..

Setelah data dikumpulkan, tahap preprocessing dilakukan untuk meningkatkan kualitas dan relevansi data. Proses ini melibatkan normalisasi teks, seperti pengubahan menjadi huruf kecil, penghapusan angka, karakter khusus, dan teks redundan. Hasil preprocessing menunjukkan distribusi data yang telah dikelompokkan ke dalam kategori *Cited* dan *Uncited*. Hasil normalisasi data ditampilkan pada Tabel 3.

Table 3. Hasil Normalisasi

Cited		
No	Clean Text	Label
1	ordinarili discret exercis cost follow event award parti parti basi departur normal practic award indemn cost requir speci...	Cited
2	ener principl govern exercis discret award indemn cost reject unsuccess parti call calderbank letter set judgment full court	Cited
3	ordinarili discret exercis cost follow event award parti parti basi departur normal practic award indemn cost requir special	Cited
4	gener principl govern exercis discret award indemn cost reject unsuccess parti call calderbank letter set judgment full	Cited
...
Uncited		
No	Clean Text	Label
1	june made order extend conven period meet creditor requir held corpor act cth act midnight juli relat number compani member ...	Uncited
2	june made order extend conven period meet creditor requir held corpor act cth act midnight juli relat number compani member ...	Uncited
3	june made order extend conven period meet creditor requir held corpor act cth act midnight juli relat number compani member ...	Uncited
4	applic submit question whether treasur satisfi acquisit contrari nation interest jurisdict fact made matter treasur took account ...	Uncited
...

Setelah melalui tahap preprocessing, data selanjutnya dipisahkan menjadi dua bagian utama: data untuk pelatihan (training) dan data untuk pengujian (testing). Dataset terdiri dari beberapa parameter yang telah ditentukan sebelumnya, di mana teks hasil preprocessing digunakan sebagai variabel x, sementara label kutipan (*Cited* dan *Uncited*) berfungsi sebagai variabel y.

3.2. Pembobotan TF-IDF

TF-IDF adalah metode untuk menghitung bobot kata berdasarkan frekuensi kemunculannya dalam dokumen tertentu (TF) dan kelangkaannya di seluruh dokumen (IDF). Metode ini membantu mengidentifikasi kata-kata yang paling relevan dan mengurangi pengaruh kata umum yang kurang signifikan dalam analisis teks.

a. Perhitungan nilai tf dan df

Nilai tf dihitung berdasarkan frekuensi kemunculan sebuah kata dalam dokumen tertentu, di mana jika kata tersebut muncul, nilainya adalah 1, dan jika tidak muncul, nilainya adalah 0. Langkah ini mengukur frekuensi kemunculan suatu kata dalam dokumen tertentu. Sementara itu, df dihitung dengan melihat jumlah dokumen yang memuat kata tersebut setidaknya satu kali. Kombinasi tf dan df memungkinkan analisis teks yang lebih efektif untuk menentukan kata-kata yang paling relevan dalam kumpulan dokumen.

Table 4. Nilai tf dan df

Term	TF								DF
	Data Training					Data Testing			
	D1	D2	D3	D4	D5	U1	U2	U3	
Accept	0	0	0	1	0	1	1	0	3
Accessorially	1	0	0	0	0	0	0	0	1
After	1	0	0	1	0	1	0	0	3
Action	3	0	0	0	0	0	0	0	3
Addition	2	0	0	0	0	0	0	0	2

Tabel 7 menyajikan hasil perhitungan tf dan df berdasarkan analisis teks menggunakan 8 data sampel, yang terdiri dari 5 data training dan 3 data testing. Perhitungan dilakukan hingga term ke-6, di mana setiap term dievaluasi berdasarkan frekuensi kemunculannya dalam dokumen tertentu. Nilai tf menggambarkan seberapa frekuensi kemunculan kata tersebut di dalam setiap dokumen, sementara df mencerminkan jumlah dokumen-dokumen yang memuat kata tersebut. Hasil perhitungan ini digunakan dalam pembobotan tf-idf untuk mengidentifikasi kata-kata yang memiliki tingkat relevansi tinggi pada analisis teks. Melalui proses ini, kata-kata yang lebih spesifik pada konteks dokumen dapat diutamakan, sedangkan kata-kata umum yang kurang penting secara signifikan akan memiliki bobot yang lebih rendah. Hal ini membantu meningkatkan efektivitas model dalam menganalisis pola data berbasis teks.

b. Perhitungan TF normalisasi

Normalisasi Term Frequency (TF) dilakukan untuk menyesuaikan nilai TF dengan mengatasi anomali yang muncul akibat perbedaan panjang dokumen. Proses normalisasi ini dilakukan dengan cara membagi frekuensi kemunculan sebuah term dengan total kata yang terdapat dalam dokumen tersebut. Panjang dokumen didefinisikan sebagai jumlah seluruh kata yang terdapat dalam dokumen (d). Nilai IDF dihitung dengan menggunakan persamaan yang ditunjukkan pada Tabel 5.

Table 5. Nilai tf dan df

	TF								DF
	Data Training					Data Testing			
	D1	D2	D3	D4	D5	U1	U2	U3	
0	0	0	0.0645	0	0.0645	0.0605	0	2.09861	
0.0226	0	0	0	0	0	0	0	2.09861	
0.0182	0	0	0.0521	0	0.0521	0	0	1.693147	
0.0678	0	0	0	0	0	0	0	2.09861	
0.0452	0	0	0	0	0	0	0	2.09861	

Tabel 5 menyajikan nilai TF Normalisasi dan IDF pada data pelatihan dan pengujian untuk analisis teks. Kolom "Data Training" menunjukkan frekuensi term yang telah dinormalisasi untuk setiap dokumen pelatihan (D1 hingga D5), sedangkan kolom "Data Testing" menampilkan frekuensi term di dokumen pengujian (U1 hingga U3). Nilai IDF digunakan untuk menghitung seberapa jarang sebuah term muncul di seluruh kumpulan dokumen, di mana nilai yang lebih tinggi menunjukkan term tersebut lebih spesifik dan jarang ditemukan. Informasi dalam tabel ini membantu mengidentifikasi tingkat kepentingan setiap term dalam konteks keseluruhan data, sehingga mendukung peningkatan akurasi dalam analisis teks.

c. Perhitungan TF-IDF

Nilai TF-IDF dihitung dengan mengalikan nilai TF Normalisasi dengan nilai IDF, seperti yang dijelaskan dalam Persamaan 3. Proses ini menghasilkan bobot yang mencerminkan relevansi setiap term dalam sebuah dokumen relatif terhadap seluruh kumpulan dokumen. Hasil dari perhitungan ini memberikan gambaran tentang kontribusi setiap term dalam analisis teks dan disajikan pada Tabel 9.

Table 6. Nilai TF-idf f pada Data Training dan Testing

TF							
Data Training				Data Testing			
D1	D2	D3	D4	D5	U1	U2	U3
0	0	0	0.135545	0	0.13554	0.12713	0
0.04749	0	0	0	0	0	0	0
0.03091	0	0	0.08822	0	0.0521	0	0
0.14248	0	0	0	0	0	0	0
0.09498	0	0	0	0	0	0	0

Berdasarkan Tabel 9, hasil perhitungan nilai TF menunjukkan distribusi bobot antar dokumen pada data pelatihan dan pengujian. Pada kolom "Data Training," dokumen D4 memiliki nilai TF sebesar 0,135545, sementara dokumen lainnya seperti D1, D2, D3, dan D5 sebagian besar menunjukkan nilai 0. Namun, dokumen D1 memiliki beberapa nilai TF, seperti 0,04749, 0,03091, 0,14248, dan 0,09498 untuk term tertentu. Di sisi lain, pada kolom "Data Testing," dokumen U1 memiliki nilai TF sebesar 0,13554, dan dokumen U2 memiliki nilai 0,12713 untuk beberapa term, sedangkan dokumen U3 tidak memiliki nilai TF yang signifikan. Hasil ini memberikan gambaran bahwa beberapa term memiliki kontribusi yang lebih tinggi pada dokumen tertentu, baik dalam data pelatihan maupun pengujian.

3.3. Hasil Pelatihan Model menggunakan KNN

Dalam melakukan klasifikasi menggunakan algoritma KNN, dilakukan pelatihan model dengan berbagai nilai k untuk mengevaluasi performa model terhadap data. Dalam penelitian ini, nilai k yang diuji meliputi 1, 3, 5, 7, 9, dan 11. Pemilihan nilai k yang berbeda bertujuan untuk mengidentifikasi nilai terbaik yang memberikan hasil akurasi terbaik pada data uji. Tabel 7 memperlihatkan hasil dari jumlah data pelatihan dan data pengujian pada tiga skenario pembagian data.

Table 7. Skenario pembagian data

Skenario	Data Training	Data Testing
Skenario 1 (90:10)	13849	1539
Skenario 2 (80:20)	12310	3078
Skenario 3 (80:20)	10771	4617

Hasil klasifikasi berdasarkan tiga skenario pembagian data, yaitu 90:10, 80:20, dan 70:30, ditemukan pada Tabel 8.

Table 8. Hasil Klasifikasi KNN

Skenario	Nilai k	Akurasi
Skenario 1 (90:10)	1	94,73%
	3	96,03%
	5	95,71%
	7	95,71%
	9	95,71%
	11	95,64%
Skenario 1 (80:20)	1	95,61%
	3	96,36%
	5	96,03%
	7	95,87%
	9	95,93%
	11	95,87%
Skenario 1 (70:30)	1	95,49%
	3	95,88%
	5	95,71%
	7	95,64%
	9	95,58%

11	95,51%
----	--------

3.3. Evaluasi Model

Evaluasi kinerja model dilakukan dengan memanfaatkan Confusion Matrix. Metrik evaluasi seperti akurasi, precision, recall, dan f1-score untuk skenario 1 (pembagian data 90:10) dapat ditemukan pada Tabel 9.

Table 9. Hasil Evaluasi Skenario 90:10

Nilai k	Akurasi	Precision	Recall	F1-score
1	94,73%	96,89%	97,62%	97,25%
3	96,03%	96,38%	99,59%	97,96%
5	95,71%	95,94%	99,72%	97,80%
7	95,71%	95,82%	99,86%	97,80%
9	95,71%	95,70%	100%	97,80%
11	95,64%	95,64%	100%	97,77%

Hasil dari akurasi, precision, recall, dan f1-score untuk skenario 1 (80:20) dapat dilihat pada tabel 10.

Table 10. Hasil Evaluasi Skenario 80:20

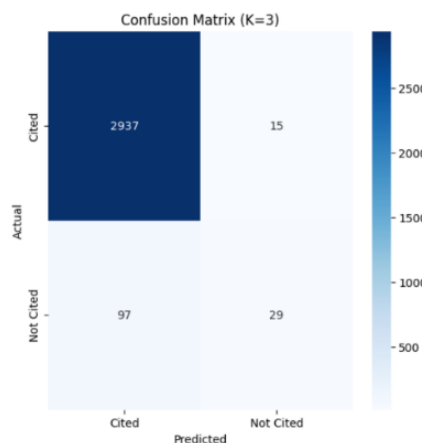
Nilai k	Akurasi	Precision	Recall	F1-score
1	95,61%	97,50%	97,93%	97,71%
3	96,36%	96,80%	99,49%	98,12%
5	96,03%	96,30%	99,69%	97,96%
7	95,87%	96,08%	99,76%	97,88%
9	95,93%	96,02%	99,89%	97,92%
11	95,87%	95,90%	99,96%	97,89%

Hasil dari akurasi, precision, recall, dan f1-score untuk skenario 1 (70:30) dapat dilihat pada tabel 11

Table 11. Hasil Evaluasi Skenario 70:30

Nilai k	Akurasi	Precision	Recall	F1-score
1	95,49%	97,17%	98,14%	97,65%
3	95,88%	96,35%	99,45%	97,87%
5	95,71%	95,94%	99,72%	97,79%
7	95,64%	95,74%	99,88%	97,76%
9	95,58%	95,59%	99,97%	97,73%
11	95,51%	95,51%	100%	97,70%

Berdasarkan hasil evaluasi model KNN pada berbagai skenario (90:10, 80:20, dan 70:30), performa terbaik tercatat pada skenario 80:20 dengan nilai k=3, dengan akurasi 96.36%, precision 96.80%, 99.49%, dan f1-score 98.13%. Model ini menunjukkan:



Gambar 2. Confusion Matrik (k3)

keseimbangan yang baik antara akurasi dan sensitivitas dalam mendeteksi kelas positif. Sebaliknya, hasil terendah diperoleh pada skenario 70:30 dengan nilai k=11, dengan akurasi 95.52%, precision 95.52%, recall 100%, dan f1-score 97.71%. Meskipun

akurasi dan precision sedikit menurun dibandingkan dengan skenario lainnya, model ini tetap menunjukkan performa yang sangat baik dengan recall 100%, yang berarti berhasil mendeteksi semua kasus positif meskipun dengan trade-off pada precision. Agar pemahaman tentang kinerja model lebih mendalam dan komprehensif, *Confusion Matrix* pada skenario 80:20 dengan nilai $k=3$ disajikan pada Gambar 2, yang menunjukkan nilai k terbaik berdasarkan hasil evaluasi tersebut.

Evaluasi model KNN dilakukan untuk mengklasifikasikan kasus hukum berdasarkan status dikutip atau tidak dikutip dengan menggunakan *confusion matrix*. *Confusion matrix* ini menyediakan informasi mengenai jumlah prediksi yang benar maupun salah yang dihasilkan oleh model. True Positive (TP) sebanyak 2.937 menunjukkan bahwa model mampu memprediksi kasus sebagai dikutip dengan benar sesuai status sebenarnya. Ini mengindikasikan bahwa model tersebut sangat efektif dalam mengidentifikasi kasus-kasus yang benar-benar termasuk dalam kategori yang disebutkan. Namun, terdapat False Positive (FP) sebanyak 15, yang berarti model salah mengklasifikasikan kasus sebagai dikutip padahal status sebenarnya adalah tidak dikutip. Kesalahan ini menunjukkan adanya kekeliruan dalam sebagian prediksi model terhadap data kasus.

True Negative (TN) sebanyak 29 menunjukkan bahwa model berhasil memprediksi kasus sebagai tidak dikutip sesuai dengan status sebenarnya. Hal ini menunjukkan bahwa model mampu mengidentifikasi kasus yang benar-benar tidak dikutip, meskipun jumlahnya relatif kecil dibandingkan dengan prediksi benar untuk kategori dikutip. Sementara itu, False Negative (FN) sebanyak 97 mengindikasikan bahwa model salah memprediksi kasus sebagai tidak dikutip, padahal status sebenarnya adalah dikutip. Kesalahan ini menunjukkan bahwa model hanya membuat sedikit kekeliruan dalam mengabaikan kasus yang seharusnya diklasifikasikan sebagai dikutip, dengan jumlah kesalahan yang sangat rendah.

4. KESIMPULAN

Penelitian ini berhasil menunjukkan efektivitas algoritma KNN dalam klasifikasi kasus hukum berdasarkan status Dikutip dan Tidak Dikutip. Dengan menggunakan metode ekstraksi fitur TF-IDF dan evaluasi model melalui metrik performa, model KNN pada skenario pembagian data 80:20 dengan $k=3$ memberikan hasil yang optimal. Akurasi tinggi sebesar 96,36% serta F1-score 98,13% menunjukkan bahwa metode ini mampu memberikan prediksi yang andal dalam mengklasifikasikan dokumen hukum. Hasil ini memberikan kontribusi signifikan terhadap efisiensi analisis hukum, khususnya dalam konteks penentuan presiden. Penelitian ini merekomendasikan pengujian lebih lanjut dengan algoritma dan dataset yang lebih kompleks untuk memperluas penerapannya di berbagai konteks hukum lainnya.

DAFTAR PUSTAKA

- [1] F. Ihsan Margolang, "Kontrak Perdagangan Internasional dalam Perspektif Hukum Perdata dalam Menyikapi Perbedaan Yuridiksi," *Gerechtheit J.*, vol. 01, no. 01, pp. 26–31, 2024, [Online]. Available: <https://journal.inacexter.com/index.php/gerechtheit>
- [2] S. E. Ramadhania and S. Rani, "Implementasi Kombinasi Algoritma Genetika dan Tabu Search untuk Penyelesaian Travelling Salesman Problem," *Automata*, vol. 2, no. 1, pp. 99–106, 2021, [Online]. Available: <http://elib.zib.de/pub/mp-testdata/tsp/tsplib/tsp/>
- [3] L. Isyriyah, Adi Bayu Permadi, and R. Maulidi, "Penggunaan Algoritma K-Nearest Neighbors(KNN) dalam Klasifikasi Artikel Clickbait Berbahasa Indonesia," *Tematik*, vol. 11, no. 1, pp. 7–15, 2024, doi: 10.38204/tematik.v11i1.1872.
- [4] I. Chalkidis, M. Fergadiotis, P. Malakasiotis, and I. Androutsopoulos, "Large-scale multi-label text classification on EU legislation," *ACL 2019 - 57th Annu. Meet. Assoc. Comput. Linguist. Proc. Conf.*, pp. 6314–6322, 2020, doi: 10.18653/v1/p19-1636.
- [5] S. Uddin, I. Haque, H. Lu, M. A. Moni, and E. Gide, "Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction," *Sci. Rep.*, vol. 12, no. 1, pp. 1–11, 2022, doi: 10.1038/s41598-022-10358-x.
- [6] S. Bansal, "Klasifikasi Teks Kutipan Hukum," p. 2021, 2021, [Online]. Available: <https://www.kaggle.com/datasets/shivamb/legal-citation-text-classification/data>
- [7] M. Muharrom, "Komparasi Algoritma Klasifikasi Naive Bayes Dan K-Nearest Neighbors Dalam Analisis Sentimen Terhadap Opini Film Pada Twitter," *J. Inform. Dan Teknologi Komput.*, vol. 3, no. 1, pp. 43–50, 2023, doi: 10.55606/jitek.v3i1.1147.
- [8] N. Purnama, F. Insani, E. Haerani, and I. Afrianty, "Model Prediksi Jumlah Penjualan Pelumas Mesin Di PT. X Dengan Algoritma Naïve Bayes," *J. Comput. Sci. Inf. Technol.*, vol. 5, no. 3, pp. 609–618, 2024.
- [9] A. Firdaus, "Aplikasi Algoritma K-Nearest Neighbor pada Analisis Sentimen Omicron Covid-19," *J. Ris. Stat.*, pp. 85–92, 2022, doi: 10.29313/jrs.v2i2.1148.
- [10] G. Putra, A. Brahmantha, E. Utami, and A. Yaqin, "Klasifikasi Genre Anime Berdasarkan Sinopsis Menggunakan Algoritma K-Nearest Neighbors," *J. Manaj. Inform. Sist. Inf.*, vol. 7, no. 1, pp. 15–24, 2024.
- [11] S. N. Yanti, Yuhandri, and Sumijan, "Jurnal KomtekInfo Implementasi K-Nearest Neighbor Berbasis Particle Swarm," *J. KomtekInfo*, vol. 11, no. 4, pp. 371–379, 2024, doi: 10.35134/komtekinfo.v11i4.586.
- [12] I. R. Lina and S. Retnowati, "Metode K-Nearest Neighbor Berbasis Forward Selection untuk Identifikasi Status Stunting pada Balita," *J. Comput. Sci. Inf. Technol.*, vol. 5, no. 3, pp. 695–704, 2024.
- [13] P. M. Hasan, N. Ayu, and R. A. Saputra, "Klasifikasi Keringanan Ukt Mahasiswa Uho Menggunakan K-Nearest Neighbor (KNN)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 6, pp. 11939–11945, 2024.
- [14] M. A. Satriawan and W. Widhiarso, "Klasifikasi Pengenalan Wajah Untuk Mengetahui Jenis Kelamin Menggunakan Metode Convolutional Neural Network," *J. Algoritm.*, vol. 4, no. 1, pp. 43–52, 2023, doi: 10.35957/algoritme.xxxx.
- [15] R. Riskawati, F. Fatihanursari, I. Iin, and A. Rizki Rinaldi, "Penerapan Metode Naïve Bayes Classifier Pada Analisis Sentimen Aplikasi Gopay," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 346–353, 2024, doi: 10.36040/jati.v8i1.8699.
- [16] S. Agustian *et al.*, "Pengaruh Agregasi Data pada Klasifikasi Sentimen untuk Dataset Terbatas Menggunakan SGD Classifier," *J. Comput. Sci. Inf. Technol.*, vol. 5, no. 3, pp. 626–634, 2024.
- [17] N. Knn, "Analisa Sentimen Pada Media Sosial ' X ' Pencarian Keyword ChatGPT Menggunakan Algoritma K-Nearest Abstrak," vol. 5, no. 3, pp. 3291–3305, 2024.