

Perbandingan Metode Pembobotan TF-RF Dan TF-ABS Pada Kategorisasi Berita Di BDI Denpasar

I Kadek Wahyu Dananjaya¹, I Gusti Ayu Agung Diatri Indradewi²

^{1,2}Program Studi Sistem Informasi, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
Jalan Udayana No. 11 Singaraja, Bali, Indonesia.

e-mail: wahyu.dananjaya@undiksha.ac.id¹, indradewi@undiksha.ac.id²

Received : January, 2023

Accepted : April, 2023

Published : April, 2023

Abstract

BDI Denpasar is a government agency tasked with carrying out training and education for human resources of animation, crafts, and art. BDI Denpasar in managing news classes in the Kabar Insan Oke service still uses conventional methods. Therefore, an automatic news classification module is needed. This study was made to compare the performance level of news classification at BDI Denpasar using K-NN classification with the TF-RF and TF-ABS term weighting methods. Methods that have a high level of performance will be implemented in the news classification module. This research was carried out by collecting news documents, text preprocessing, term weighting, classification, model validation and testing. The K-NN classification uses the $n_neighbor$ (k), namely $k=3$, $k=5$, $k=7$ and $k=9$ using a dataset of 324 documents containing 7 classes taken from BDI Denpasar website. Based on the results of the tests performed, TF-RF method obtained a higher performance at $k=5$ with an accuracy of 71% with a precision of 73% and a recall of 71%. TF-ABS method with the highest performance value is found at $k=9$ which obtains 70% accuracy, 63% precision and 70% recall. So the method that will be implemented in the news classification module is TF-RF at $k=5$ with an accuracy of 71% with a precision of 73% and a recall of 71%.

Keywords: Classification, Term weighting, TF-RF, TF-ABS, K-Nearest Neighbors

Abstrak

BDI Denpasar adalah sebuah instansi pemerintahan yang memiliki tugas memberikan pelatihan dan pendidikan bagi SDM di bidang keahlian animasi, kerajinan dan barang seni. BDI Denpasar dalam pengelolaan kelas berita di layanan Kabar Insan Oke ini masih menggunakan cara konvensional. Oleh sebab itu diperlukan sebuah modul klasifikasi berita otomatis. Penelitian ini dibuat untuk membandingkan tingkat performa klasifikasi berita pada BDI Denpasar menggunakan klasifikasi K-NN dengan metode pembobotan kata TF-RF dan TF-ABS. Metode yang memiliki tingkat performa yang tinggi akan diimplementasikan pada modul klasifikasi berita. Penelitian ini dilakukan dengan cara mengumpulkan dokumen berita, preprocessing teks, term weighting, klasifikasi, validasi model dan pengujian. Klasifikasi K-NN menggunakan $n_neighbor$ (k) yaitu $k=3$, $k=5$, $k=7$ dan $k=9$ menggunakan dataset sebanyak 324 dokumen berisikan 7 kelas yang diambil dari website BDI Denpasar. Berdasarkan hasil pengujian yang dilakukan, metode pembobotan kata TF-RF memperoleh tingkat performansi yang lebih tinggi pada nilai $k=5$ dengan accuracy adalah 71%, precision 73% dan recall sebesar 71%. Metode pembobotan kata TF-ABS yang nilai k memiliki performansi tertinggi terdapat pada $k=9$ yang memperoleh accuracy sebesar 70%, precision sebesar 63% dan recall sebesar 70%. Jadi metode yang

akan diimplementasikan pada modul klasifikasi berita yaitu TF-RF k=5 dengan accuracy sebesar 71%, precision 73% dan recall sebesar 71%.

Kata Kunci: Klasifikasi, Term weighting, TF-RF, TF-ABS, K-Nearest Neighbors

1. PENDAHULUAN

Pada saat ini data memiliki peran yang sangat penting dalam memenuhi sebuah tujuan dalam organisasi. Data yang dihasilkan oleh suatu instansi pasti akan terus-menerus semakin banyak sehingga pengelolaan data yang masih menggunakan cara manual akan menyebabkan aktivitas tidak efektif dan efisien. Salah satu data yang akan menjadi sangat besar dan tidak terorganisir seiring berjalannya waktu adalah data dokumen berita [1].

Pengklasifikasian dengan cara manual membuat aktifitas tidak efektif dan efisien di jaman digital seperti sekarang ini. Oleh karena itu, penggunaan sistem klasifikasi berbasis komputer sangat diperlukan agar aktivitas dalam pengklasifikasian dokumen berita lebih mudah dan tertata dengan baik serta dapat meminimalisir terjadinya kesalahan input kelas berita. Salah satu instansi yang memiliki permasalahan dalam aktivitas pengklasifikasian yaitu Balai Diklat Industri (BDI) Denpasar.

Balai Diklat Industri (BDI) Denpasar memiliki layanan bernama "Kabar Insan Oke" di dalam websitenya sendiri yang dibuat menggunakan CMS *WordPress*. Dalam pengelolaan kelas berita di sistem layanan Kabar Insan Oke ini masih menggunakan cara konvensional seperti memilih kelas berita dengan cara manual yang menyebabkan aktivitas kurang maksimal apalagi berita pasti akan selalu dilakukan pembaruan.

Menentukan kelas berita didalam sistem dapat dilakukan secara otomatis dengan menggunakan metode-metode klasifikasi. Salah satu metode yang bisa digunakan pada pengklasifikasian berita secara otomatis yaitu *K-Nearest Neighbors*. Metode ini termasuk kedalam 10 metode Data Mining terbaik yang sering digunakan [2]. Penelitian yang dilakukan oleh Aida Indriani tahun 2020 [3] menganalisis pada klasifikasi data forum diskusi mahasiswa dengan membandingkan dua metode pengklasifikasian antara *Naive Bayes Classifier* (NBC) dengan *K-Nearest Neighbors* (K-NN). Dari hasil analisis yang dilakukan, dapat ditarik

kesimpulan bahwa metode K-NN memiliki tingkat akurasi yang lebih baik daripada metode NBC dengan tingkat akurasi sebanyak 80% untuk metode K-NN dan 73% untuk NBC.

Melakukan pengklasifikasian dokumen berita dengan algoritma K-NN dapat menggunakan sebuah metode *term weighting* agar dalam proses pengklasifikasian tingkat akurasi yang dihasilkan lebih akurat dan lebih maksimal. Salah satu metode *term weighting* atau pembobotan kata yang digunakan dalam pengklasifikasian yaitu *Term Frequency-Relevance Frequency* (TF-RF) dan *Term Frequency-Absolute* (TF-ABS). Penelitian ini berupaya meneliti sebuah metode klasifikasi yang menggunakan metode pembobotan antara TF-RF dengan TF-ABS. Analisis diperlukan untuk menentukan perbandingan metode pembobotan mana yang lebih baik digunakan didalam modul klasifikasi berita dengan cara menghitung *Recall*, *Precision* dan *Accuracy* menggunakan metode *Confusion Matrix*.

Adapun penelitian terdahulu yang menggunakan topik sejenis, penelitian tersebutlah yang dijadikan sebagai pedoman dan inspirasi penelitian ini dibuat. Berikut merupakan penelitian – penelitian terdahulu yang menggunakan topik sejenis.

Penelitian yang dilakukan oleh Kurniawan, dkk tahun 2018 [4] menggunakan metode pengukuran bobot TF-ABS dan TF-CHI yang memperhitungkan jumlah *feature* yang terlihat pada suatu dokumen dan mempertimbangkan jumlah *feature* yang tidak terlihat pada dokumen. Klasifikasi berita tanpa mengimplementasikan *stemming* dengan menggunakan *unigram binary* menghasilkan tingkat akurasi sebesar 90.44%. Sedangkan jika menggunakan metode *term weighting* TF-ABS memperoleh tingkat akurasi sebanyak 95.74% dan pada metode *term weighting* TF-CHI sebanyak 95.87%. Berdasarkan analisis tersebut, dapat diambil kesimpulan bahwa hasil analisis metode *term weighting* TF-ABS dan TF-CHI lebih baik dan dapat meningkatkan kinerja

sistem jika dibandingkan dengan *unigram binary* yaitu sebanyak 5%.

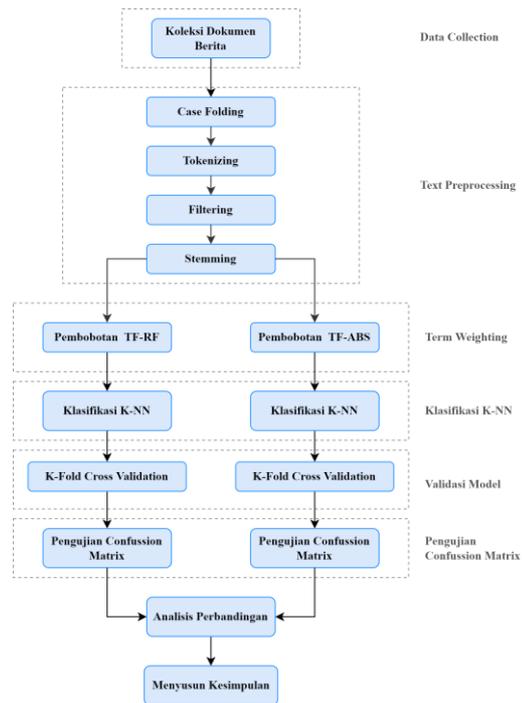
Penelitian yang dilakukan oleh Supono dan Muhammad Azis tahun 2021 [5] menganalisis perbandingan metode pembobotan teks TF-ABS dengan TF-IDF menggunakan metode klasifikasi K-NN. Hasil yang didapatkan dari analisis penelitian ini adalah metode pembobotan TF-ABS memperoleh hasil akurasi tertinggi sebesar 90,04% pada parameter $k=3$ dan penggunaan jumlah fitur sebesar 15%.

Penelitian lainnya yang dilakukan oleh Agatha Deolika, dkk tahun 2019 [6] menganalisis perbandingan 3 metode *term weighting* yaitu TF-IDF, TF-RF, WIDF menggunakan metode Naïve Bayes. Hasil *Accuracy* menggunakan *confusion matrix* diperoleh performa tertinggi pada TF-RF dengan tingkat *Accuracy* sebesar 98,67%, *Precision* 93,81%, dan *Recall* 96,67%. Dari analisis tersebut, dapat ditarik kesimpulan bahwa metode TF-RF dengan menggunakan klasifikasi *Naïve Bayes* lebih baik dibandingkan metode TF-IDF dan WIDF.

Berdasarkan pembahasan yang dilakukan sebelumnya, berikut *novelty* atau perbedaan penelitian ini dengan penelitian yang sejenis sebelumnya, yaitu menganalisis perbandingan pembobotan kata antara *Term Frequency – Relevance Frequency (TF-RF)* dengan *Term Frequency – Absolute (TF-ABS)* yang menggunakan algoritma *K-Nearest Neighbors*.

2. METODE PENELITIAN

Jenis penelitian yang digunakan dalam pengerjaannya yaitu jenis penelitian eksperimen. Melaksanakan penelitian ini diperlukannya sebuah langkah-langkah aktifitas pengerjaan penelitian agar kegiatan penelitian lebih terstruktur dan lebih jelas. Berikut prosedur kerja dari penelitian dapat dilihat pada Gambar 1.



Gambar 1. Prosedur Kerja Penelitian

2.1 Data Collection

Dataset yang dipakai dalam penelitian ini yaitu data berita di layanan media informasi Kabar Insan Oke. Terdapat 7 kelas dokumen berita yang digunakan pada layanan tersebut, antara lain: Pengumuman, Agenda, Kabar Insan Oke, Bikin Maker Space, Diklat 3 in 1, Teaching Factory dan Inbis Tohpati. Jumlah keseluruhan berita dalam 7 kelas tersebut yaitu sebanyak 324 data berita dari bulan Maret 2021 sampai bulan Februari 2022.

Tabel 1: Jumlah Dataset

[Sumber: BDI Denpasar]

Kategori	Jumlah
Pengumuman	61
Agenda	44
Kabar Insan Oke	103
Bikin Maker Space	13
Diklat 3 In 1	53
Teaching Factory	10
Inbis Tohpati	40
Total	324

Data tersebut akan dibagi menjadi 90:10 yang sebelumnya dilakukan teknik *oversampling* dengan menggunakan metode *Synthetic Minority Over-sampling Technique (SMOTE)* yang diambil dari *library imblearn*, SMOTE

berfungsi agar kelas yang minoritas dibuatkan replikasi sampel baru atau data sintesis[7].

2.2 Text Preprocessing

Tahapan ini merupakan langkah awal dalam memproses teks yang bertujuan membersihkan teks menjadi data yang lebih terstruktur dan akan diolah pada tahapan berikutnya [8]. Proses *Text Preprocessing* akan dilakukan menggunakan tools bahasa pemrograman *Python* dengan menginstal beberapa *library* seperti *NLTK*, *Pandas* dan *Sastrawi*.

1) Case Folding

Case Folding merupakan proses merubah semua huruf ke dalam bentuk huruf kecil, dimana selain huruf *a-z* akan dianggap sebagai delimiter dan dihilangkan. Proses ini menggunakan *method str.lower()* yang diambil dari *library Pandas* agar dalam melakukan pengklasifikasian tidak ada kata yang diulang dalam pembobotan nantinya.

2) Tokenizing

Tokenizing merupakan sebuah proses membagi kalimat kedalam satu kata yang individu untuk mempermudah dalam menghitung frekuensi kemunculan kata pada aktifitas pengklasifikasian. Proses ini menggunakan *method word_tokenize()* yang diimport dari *library NLTK*.

3) Filtering

Filtering merupakan proses menghilangkan atau membuang kata-kata yang tidak memiliki makna seperti kata hubung (yang, untuk, agar, jika, ketika, dsb). *Filtering* juga dapat disebut sebagai *Stopwords Removal*. Proses *Stopwords Removal* menggunakan *module stopwords indonesian* yang diambil dari *library nltk.corpus*.

4) Stemming

Stemming merupakan sebuah proses terakhir yang mengembalikan sebuah kata kedalam kata dasarnya. Ini bertujuan agar dalam melakukan pengklasifikasian, tidak ada kesalahan perhitungan kemunculan kata dan agar mengurangi kata yang ambigu. Proses ini menggunakan module yang disediakan pada *library Sastrawi.StemmerFactory*.

2.3 Term weighting

1) Term Frequency-Relevance Frequency (TF-RF)

TF-RF adalah sebuah metode gabungan antara TF dengan RF yang mempertimbangkan relevansi dari dokumen yang dilihat dari frekuensi kemunculan kata di kategori tersebut dan bertujuan mendapatkan tingkat performa yang lebih baik dibandingkan metode pembobotan kata lainnya [9]. Rumus persamaan perhitungan bobot suatu term pada *Term Frequency-Relevance Frequency (TF-RF)* [10] dapat dilihat pada Persamaan 1.

$$tf_{td}rf = tf_{td} * \log(2 + \frac{b}{max1,c}) \quad (1)$$

Dimana $tf*rf$ adalah Pembobotan TF-RF, tf_{td} adalah Frekuensi kemunculan kata t dalam dokumen, b adalah Jumlah dokumen yang mengandung kata t dan c adalah Jumlah dokumen yang tidak memiliki kata t .

2) Term Frequency-Absolute (TF-ABS)

TF-ABS adalah sebuah metode pengukuran bobot kemungkinan sebuah term t_j yang berada dalam dokumen dengan kategori c_i kemudian dibagi dengan kemungkinan term t_j yang tidak ada didalam dokumen dengan kelas tersebut dan menerapkan (basis log e) atau yang dikenal sebagai logit [11]. Rumus persamaan perhitungan bobot menggunakan ABS atau abs-logit [5] dapat dilihat pada Persamaan 2.

$$tf_{td}ABS(t_j, c_k) = tf_{td} * \ln \left(\frac{(n_{kj} + 0.5)(n_{kj} + 0.5)}{(n_{kj} + 0.5)(n_{kj} + 0.5)} \right) \quad (2)$$

Dimana ABS adalah Bobot kata, t_j adalah term t_j , C_k adalah kategori C_k , n_{kj} adalah Jumlah dokumen pada kategori C_k yang memiliki term t_j , $n_{\sim k_j}$ adalah Jumlah dokumen tidak dalam kategori C_k yang memiliki term t_j , $n_{k\sim j}$ adalah Jumlah dokumen dalam kategori C_k yang tidak memiliki term t_j , $n_{\sim k\sim j}$ adalah Jumlah dokumen tidak dalam kategori C_k yang tidak memiliki term t_j .

2.4 Klasifikasi K-Nearest Neighbors

Tahapan ini merupakan proses menentukan data uji akan masuk ke kelas mana menggunakan metode K-NN. Algoritma K-NN bekerja berdasarkan jarak terdekat dari query instance ke data uji atau data train untuk menentukan klasifikasi terdekatnya[12]. Sebelum melakukan pengklasifikasian, data harus dilakukan perhitungan tingkat kesamaan antar objek dengan menggunakan rumus *Cosine Similarity*. penelitian ini menggunakan nilai $k = 3, 5, 7$ dan 9 . Nilai k yang dipilih berupa bilangan ganjil agar dalam penentuan kelas tidak ada nilai yang sama. Nilai k tersebut akan dilakukan proses eksperimental untuk memilih nilai k mana yang performanya lebih tinggi. Nilai k yang digunakan penelitian ini mengacu pada penelitian sebelumnya yang dilakukan oleh Agung N Assidyk, dkk [13].

2.5 Validasi Model

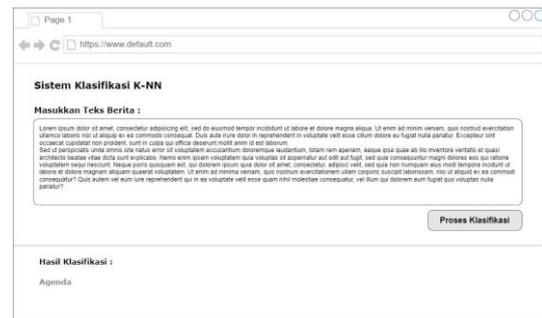
Validasi model ini dilakukan untuk melihat tingkat akurasi model, dimana dalam memvalidasi model dataset terlebih dahulu dibagi menjadi 2 bagian yaitu data latih dan data uji. Pembagian dataset tersebut menggunakan metode *K-Fold Cross Validation*, dimana metode ini merupakan sebuah teknik untuk mengukur nilai hasil statistik analisis akan menggeneralisasi data independen dan memperkirakan seberapa akurat model yang telah dibuat [14]. Penelitian ini menggunakan nilai k yaitu $k = 5$, karena menurut Max Kuhn dan K Johnson [15] dalam bukunya yang berjudul “Applied Predictive Modeling” menjelaskan jika memilih nilai k disarankan tidak terlalu besar dan tidak terlalu kecil. Jika nilai k terlalu besar akan memperoleh model yang tidak bias, tetapi dapat juga menghasilkan keadaan overfitting jika data yang digunakan sesuai, sedangkan jika nilai k terlalu kecil dapat memicu terjadinya bias. Oleh sebab itu disarankan menggunakan nilai $k = 5$ atau $k = 10$. Setiap subset dalam 5-fold pada penelitian ini akan berisikan nilai yang sama rata.

2.6 Pengujian Confusion Matrix

Confusion Matrix merupakan sebuah metode yang digunakan untuk mengukur kinerja sebuah metode klasifikasi *machine learning* dimana memiliki 2 kelas atau lebih [16]. Untuk melihat seberapa akurat model yang digunakan dengan menghitung *accuracy*, *precision* dan *recall*.

2.7 Gambaran Umum Modul Klasifikasi Berita

Metode yang mendapatkan hasil performa yang terbaik nantinya akan digunakan pada sistem program klasifikasinya, dimana sistem tersebut bersifat terpisah atau belum terintegrasi kedalam website BDI Denpasar. Gambaran umum modul program klasifikasi terdapat pada Gambar 2.



Gambar 2. Contoh Tampilan Modul

3. HASIL DAN PEMBAHASAN

Hasil pengujian klasifikasi menggunakan skenario uji coba atau eksperimen. Skenario pengujian dilakukan untuk mengetahui model dengan nilai k mana yang terbaik untuk digunakan pada modul klasifikasi berita.

3.1 Metode Pembobotan Kata TF-RF

1) Nilai $K=3$

Term	Frequency	Relevance	Frequency
Agenda	0.43	0.67	0.52
Bikin Maker Space	0.71	1.00	0.83
Diklat 3 in 1	0.71	0.94	0.81
Inbis Tohpati	0.89	0.53	0.67
Kabar Insan Oke	0.50	0.14	0.22
Teaching Factory	0.92	1.00	0.96
pengumuman	0.50	0.40	0.44
accuracy			0.68
macro avg	0.67	0.67	0.64
weighted avg	0.70	0.68	0.66

Gambar 3. Hasil Klasifikasi TF-RF $K=3$

Gambar 3 memperlihatkan untuk *precision* menghasilkan nilai rata-rata sebesar 70% yang artinya tingkat kedekatan prediksi antar kelas rata-rata diperoleh sebesar 70%, *recall* memperoleh rata-rata 68% atau tingkat model dalam mengambil kembali sebuah informasi rata-rata sebesar 68% dan terakhir tingkat *accuracy* menghasilkan rata-rata sebesar 68% atau tingkat kedekatan prediksi yang diperoleh model dengan data aktual.

2) Nilai K=5

```

=====Classification Report=====
=====Term Frequency-Relevance Frequency=====
precision  recall  f1-score  support
Agenda      0.54    0.78    0.64     9
Bikin Maker Space  0.62    1.00    0.77     5
Diklat 3 in 1  0.68    0.81    0.74    16
Inbis Tohpati  0.91    0.67    0.77    15
Kabar Insan Oke  0.67    0.29    0.40     7
Teaching Factory  0.92    1.00    0.96    11
pengumuman  0.57    0.40    0.47    10

accuracy    0.71    0.71    0.71    73
macro avg  0.70    0.71    0.68    73
weighted avg  0.73    0.71    0.70    73
    
```

Gambar 4. Hasil Klasifikasi TF-RF K=5

Berdasarkan Gambar 4 hasil klasifikasi dengan k=5 memperlihatkan untuk nilai *precision* menghasilkan nilai rata-rata sebesar 73% yang memiliki arti rata-rata 73% tingkat kedekatan prediksi kelas antar satu dengan lainnya, nilai *recall* memperoleh rata-rata 71% atau tingkat model yang dibuat dalam memanggil kembali sebuah informasi rata-rata sebesar 71% dan terakhir tingkat *accuracy* menghasilkan rata-rata sebesar 71% yang artinya tingkat kedekatan prediksi yang dibuat model dengan data sebenarnya memiliki tingkat akurasi sebesar 71%.

3) Nilai K=7

```

=====Classification Report=====
=====Term Frequency-Relevance Frequency=====
precision  recall  f1-score  support
Agenda      0.42    0.56    0.48     9
Bikin Maker Space  0.71    1.00    0.83     5
Diklat 3 in 1  0.68    0.94    0.79    16
Inbis Tohpati  0.89    0.53    0.67    15
Kabar Insan Oke  1.00    0.14    0.25     7
Teaching Factory  0.79    1.00    0.88    11
pengumuman  0.62    0.50    0.56    10

accuracy    0.68    0.68    0.68    73
macro avg  0.73    0.67    0.64    73
weighted avg  0.73    0.68    0.66    73
    
```

Gambar 5. Hasil Klasifikasi TF-RF K=7

Hasil klasifikasi dengan k=7 mendapatkan nilai *precision* dengan rata-rata sebesar 73% atau yang dimaksud model memperoleh tingkat kedekatan prediksi kelas antar satu sama lain, nilai *recall* memperoleh rata-rata 68% yang berarti model dengan k=7 memiliki tingkat kecepatan dalam mengambil sebuah informasi kembali rata-rata sebesar 68% dan *accuracy* menghasilkan rata-rata sebesar 68% atau pengertian lainnya model yang dibuat dengan k=7 menghasilkan tingkat keakuratan prediksi dengan data aktual sebesar 68%.

4) Nilai K=9

```

=====Classification Report=====
=====Term Frequency-Relevance Frequency=====
precision  recall  f1-score  support
Agenda      0.50    0.78    0.61     9
Bikin Maker Space  0.67    0.80    0.73     5
Diklat 3 in 1  0.78    0.88    0.82    16
Inbis Tohpati  0.69    0.60    0.64    15
Kabar Insan Oke  1.00    0.43    0.60     7
Teaching Factory  0.77    0.91    0.83    11
pengumuman  0.67    0.40    0.50    10

accuracy    0.70    0.70    0.70    73
macro avg  0.72    0.68    0.68    73
weighted avg  0.72    0.70    0.69    73
    
```

Gambar 6. Hasil Klasifikasi TF-RF K=9

Gambar 6 memperlihatkan hasil klasifikasi dengan k=9 yaitu pada *precision* menghasilkan nilai rata-rata sebesar 72% yang memiliki arti bahwa model memiliki tingkat kedekatan prediksi kelas antar satu dengan lainnya rata-rata sebesar 72%, *recall* memperoleh rata-rata 70% atau model yang dibuat dengan menggunakan nilai k=9 memiliki tingkat kecepatan dalam mencari kembali sebuah informasi rata-rata sebesar 70% dan terakhir tingkat *accuracy* menghasilkan rata-rata sebesar 70% atau yang memiliki arti model yang dibuat menghasilkan tingkat ketepatan prediksi dengan data sesungguhnya rata-rata sebesar 70%.

3.2 Metode Pembobotan Kata TF-ABS

1) Nilai K=3

```

=====Classification Report=====
=====Term Frequency-Absolute=====
precision  recall  f1-score  support
Agenda      0.44    0.78    0.56     9
Bikin Maker Space  0.71    1.00    0.83     5
Diklat 3 in 1  0.78    0.88    0.82    16
Inbis Tohpati  0.78    0.47    0.58    15
Kabar Insan Oke  0.00    0.00    0.00     7
Teaching Factory  1.00    1.00    1.00    11
pengumuman  0.55    0.60    0.57    10

accuracy    0.68    0.68    0.68    73
macro avg  0.61    0.67    0.62    73
weighted avg  0.66    0.68    0.66    73
    
```

Gambar 7. Hasil Klasifikasi TF-ABS K=3

Hasil uji coba pertama pada TF-ABS dapat dilihat pada Gambar 7, dimana hasil yang diperoleh pada *precision* menghasilkan nilai rata-rata sebesar 66% atau tingkat kedekatan prediksi antar satu kelas dengan lainnya rata-rata dengan kedekatan 66%, *recall* memperoleh rata-rata 68% atau istilah lainnya model yang dibuat menghasilkan rata-rata tingkat keberhasilan dalam mengambil kembali sebuah informasi sebesar 68% dan terakhir tingkat *accuracy* menghasilkan rata-rata sebesar 68% atau tingkat keakuratan model memprediksi kelas

yang dihasilkan TF-ABS dengan k=3 rata-rata sebesar 68%.

2) Nilai K=5

```

=====Classification Report=====
=====Term Frequency-Absolute=====
precision recall f1-score support
Agenda 0.47 0.89 0.62 9
Bikin Maker Space 0.71 1.00 0.83 5
Diklat 3 in 1 0.62 0.62 0.62 16
Inbis Tohpati 0.77 0.67 0.71 15
Kabar Insan Oke 0.50 0.14 0.22 7
Teaching Factory 1.00 0.82 0.90 11
pengumuman 0.56 0.50 0.53 10
accuracy 0.66 0.66 0.66 73
macro avg 0.66 0.66 0.63 73
weighted avg 0.68 0.66 0.65 73
    
```

Gambar 8. Hasil Klasifikasi TF-ABS K=5

Hasil klasifikasi k=5 dapat dilihat pada Gambar 8, dimana hasil klasifikasi menghasilkan nilai *precision* dengan rata-rata sebesar 68% yang artinya model yang dibuat menghasilkan tingkat kedekatan prediksi antar serangkaian kelas satu dengan yang lainnya, nilai *recall* memperoleh rata-rata 66% atau model menghasilkan tingkat keberhasilan dalam mencari sebuah informasi kembali rata-rata sebesar 66% dan *accuracy* menghasilkan rata-rata sebesar 66% atau model memperoleh tingkat ketepatan prediksi kelas dengan data aktual sebesar 66%.

3) Nilai K=7

```

=====Classification Report=====
=====Term Frequency-Absolute=====
precision recall f1-score support
Agenda 0.53 0.91 0.67 11
Bikin Maker Space 0.83 0.71 0.77 7
Diklat 3 in 1 0.50 0.62 0.56 8
Inbis Tohpati 0.62 0.62 0.62 8
Kabar Insan Oke 1.00 0.13 0.24 15
Teaching Factory 0.61 1.00 0.76 11
pengumuman 0.50 0.38 0.43 13
accuracy 0.66 0.59 0.59 73
macro avg 0.66 0.63 0.58 73
weighted avg 0.67 0.59 0.54 73
    
```

Gambar 9. Hasil Klasifikasi TF-ABS K=7

Pada Gambar 9 memperlihatkan untuk *precision* memperoleh nilai rata-rata sebesar 67% atau tingkat kedekatan hasil prediksi kelas antara satu sama lain rata-rata sebesar 67%, *recall* memperoleh rata-rata 59% atau tingkat keberhasilan model dalam mengambil kembali sebuah informasi rata-rata memperoleh keberhasilan sebesar 59% dan terakhir tingkat *accuracy* menghasilkan rata-rata sebesar 59% atau tingkat kedekatan antara hasil prediksi kelas dengan data

aktual rata-rata menghasilkan kedekatan sebesar 59%.

4) Nilai K=9

```

=====Classification Report=====
=====Term Frequency-Absolute=====
precision recall f1-score support
Agenda 0.60 0.67 0.63 9
Bikin Maker Space 0.62 1.00 0.77 5
Diklat 3 in 1 0.68 0.81 0.74 16
Inbis Tohpati 0.69 0.60 0.64 15
Kabar Insan Oke 0.00 0.00 0.00 7
Teaching Factory 0.79 1.00 0.88 11
pengumuman 0.78 0.70 0.74 10
accuracy 0.60 0.68 0.70 73
macro avg 0.60 0.68 0.63 73
weighted avg 0.63 0.70 0.66 73
    
```

Gambar 10. Hasil Klasifikasi TF-ABS K=9

Hasil klasifikasi memperoleh nilai *precision* dengan rata-rata sebesar 63% atau tingkat kedekatan hasil prediksi antar kelas satu dengan kelas lainnya memiliki rata-rata kedekatan sebesar 63%, nilai *recall* memperoleh rata-rata 70% atau tingkat keberhasilan model dalam menemukan kembali informasi rata-rata memperoleh keberhasilan sebesar 70% dan terakhir *accuracy* menghasilkan rata-rata sebesar 70% atau tingkat kedekatan hasil prediksi kelas dengan data sebenarnya memperoleh tingkat kedekatan dengan rata-rata sebesar 70%.

3.3 Perbandingan TF-RF dan TF-ABS

Hasil eksperimen menggunakan parameter k=3, k=5, k=7, dan k=9 pada model klasifikasi dengan menggunakan metode pembobotan kata TF-RF dan TF-ABS digunakan untuk menilai kinerja model terbaik yang akan diimplementasikan ke dalam sistem klasifikasi otomatis. Perbandingan hasil kinerja model klasifikasi *K-Nearest Neighbor* dengan menggunakan pembobotan kata TF-RF dan TF-ABS pada setiap nilai k yang dipakai ditunjukkan pada Tabel 2.

Tabel 2: Hasil TF-RF dan TF-ABS

K	TF-RF			TF-ABS		
	Precision	Recall	Accuracy	Precision	Recall	Accuracy
K=3	70%	68%	68%	66%	68%	68%
K=5	73%	71%	71%	68%	66%	66%
K=7	73%	68%	68%	67%	59%	59%
K=9	72%	70%	70%	63%	70%	70%

Berdasarkan hasil pada Tabel 2, metode pembobotan TF-RF dengan k=3 memperoleh performa yang terendah yaitu *precision* sebesar

70%, *recall* 68% dan *accuracy* 68%. Nilai tertinggi terdapat pada k=5 yang menghasilkan *precision* sebesar 73%, *recall* 71% dan *accuracy* 71%. Pada metode pembobotan TF-ABS nilai terendah terdapat pada k=7 dengan *precision* 67%, *recall* 59% dan *accuracy* 59%. Nilai tertinggi terdapat pada k=9 dengan menghasilkan *precision* sebesar 63%, *recall* 70% dan *accuracy* 70%. Nilai tersebut didapat dari perhitungan confusion matrix yang dilakukan sebelumnya.

Berdasarkan hasil pengujian yang dilakukan pada model menggunakan metode pembobotan kata *Term Frequency-Relevance Frequency (TF-RF)* dan *Term Frequency-Absolute (ABS)*, dapat diambil kesimpulan bahwa model yang memiliki performansi terbaik yaitu pada model yang menggunakan metode pembobotan kata *Term Frequency-Relevance Frequency (TF-RF)* dengan menggunakan nilai k=5 pada metode klasifikasi *K-Nearest Neighbor (K-NN)*. Jadi modul klasifikasi berita akan menggunakan metode pembobotan kata TF-RF.

Tabel 3: Hasil *K-Fold Cross Validation*

Parameter	Split 1	Split 2	Split 3	Split 4	Split 5	Rata-rata
K = 5	0.6538	0.5538	0.6307	0.6201	0.5813	0.6080

Hasil validasi model menggunakan metode *K-Fold Cross Validation* pada nilai k=5 dapat dilihat pada Gambar 11, dimana pada iterasi pertama akurasi yang dihasilkan sebesar 65%, iterasi kedua menghasilkan tingkat akurasi sebesar 55%, iterasi ketiga memperoleh akurasi sebesar 63%, sedangkan iterasi keempat mendapatkan hasil sebesar 62% dan terakhir pada iterasi kelima memperoleh hasil 58%. Rata-rata yang dihasilkan dari 5 fold atau 5 iterasi tersebut sebesar 60%, jadi tingkat akurasi model tidak terlalu tinggi, yang kemungkinan disebabkan oleh data latih yang kurang banyak dan data yang kurang dibersihkan lagi.

3.4 Modul Klasifikasi Berita

Berdasarkan analisis yang sudah dilakukan sebelumnya, metode pembobotan kata atau *term weighting* yang akan digunakan pada modul klasifikasi berita yaitu *Term Frequency-Relevance Frequency (TF-RF)*. Berikut hasil tampilan modul klasifikasi berita yang menggunakan metode TF-RF dengan Bahasa

Pemrograman PHP, dapat dilihat pada Gambar 12.



Gambar 11. Hasil Modul Klasifikasi Berita

4. KESIMPULAN

Berdasarkan hasil pengujian yang dilakukan, metode pembobotan kata TF-RF memperoleh tingkat performansi yang lebih tinggi atau lebih baik dalam pengujian *confusion matrix* pada nilai k=5 dengan *accuracy* adalah 71% yang artinya tingkat kedekatan prediksi yang dibuat model dengan data sebenarnya memiliki tingkat akurasi sebesar 71%, *precision* sebesar 73% yang memiliki arti rata-rata 73% tingkat kedekatan prediksi kelas antar satu dengan lainnya dan *recall* sebesar 71% atau tingkat model yang dibuat dalam memanggil kembali sebuah informasi rata-rata sebesar 71%. Sedangkan pada TF-ABS nilai k yang performansinya tertinggi terdapat pada k=9 yang memperoleh *accuracy* sebesar 70% atau tingkat kedekatan hasil prediksi kelas dengan data sebenarnya memperoleh tingkat kedekatan dengan rata-rata sebesar 70%, *precision* sebesar 63% atau tingkat kedekatan hasil prediksi antar kelas satu dengan kelas lainnya memiliki rata-rata kedekatan sebesar 63% dan *recall* sebesar 70% atau tingkat keberhasilan model dalam menemukan kembali informasi rata-rata memperoleh keberhasilan sebesar 70%. Jadi metode pembobotan kata yang diimplementasikan pada modul klasifikasi berita yaitu menggunakan metode TF-RF dengan k=5.

Hasil klasifikasi sangat bergantung pada tahapan *preprocessing* dataset, sehingga disarankan menambahkan *library emot* untuk menghilangkan *emoticons* atau emoji didalam teks dan menambahkan dataset yang lebih banyak lagi agar hasil klasifikasi lebih tepat dan akurat.

Metode *K-Nearest Neighbors* dengan menggunakan metode pembobotan *Term Frequency-Relevance Frequency (TF-RF)* dan *Term Frequency-Absolute (TF-ABS)* masih

belum maksimal dalam melakukan klasifikasi, sehingga disarankan mencoba metode klasifikasi lain seperti *Support Vector Machines*, *Neural Networks*, *GA*, *Decision Trees*, dan *Naïve Bayes* untuk memaksimalkan hasil penelitian dan meningkatkan tingkat performansi model.

Modul yang dibuat masih memiliki kekurangan, sehingga disarankan menambahkan fitur-fitur lainnya yang dapat membantu aktifitas pengklasifikasian seperti fitur *voice typing*.

PERNYATAAN PENGHARGAAN

Penulis mengucapkan terimakasih kepada Dosen Pembimbing, Dosen Penguji, Orang Tua serta pihak-pihak yang sudah membantu dalam menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- [1] H. Februariyanti, "Klasifikasi Dokumen Berita Teks Bahasa Indonesia menggunakan Ontologi," *Tekno. Inf. Din.*, vol. 17, no. 1, pp. 14–23, 2012, [Online]. Available: <http://www.unisbank.ac.id/ojs/index.php/fti1/article/view/1612/594>.
- [2] X. Wu and V. Kumar, *The Top Ten Algorithms in Data Mining*, Chapman & Hall/CRC Data Mining and Knowledge Discovery, vol. 53, no. 9. 2013.
- [3] A. Indriani, "Analisa Perbandingan Metode Naïve Bayes Classifier Dan K-Nearest Neighbor Terhadap Klasifikasi Data," *Sebatik*, vol. 24, no. 1, pp. 1–7, 2020, doi: 10.46984/sebatik.v24i1.909.
- [4] M. A. Kurniawan, Y. Sibaroni, and K. M. Lhaksana, "Kategorisasi Berita Menggunakan Metode Pembobotan TF.ABS dan TF.CHI," *Indones. J. Comput.*, vol. 3, no. 2, p. 83, 2018, doi: 10.21108/indojc.2018.3.2.236.
- [5] R. A. Supono and S. Muhammad Azis, "Perbandingan Metode TF-ABS dan TF-IDF Pada Klasifikasi Teks Helpdesk Menggunakan K-Nearest Neighbor," *J. RESTI*, vol. 5, no. 10, pp. 911–918, 2021.
- [6] A. Deolika, Kusri, and E. T. Luthfi, "Analisis Pembobotan Kata Pada Klasifikasi Text Mining," *J. Tekno. Inf.*, vol. 3, no. 2, p. 179, 2019, doi: 10.36294/jurti.v3i2.1077.
- [7] A. A. Arifiyanti and E. D. Wahyuni, "Smote: Metode Penyeimbang Kelas Pada Klasifikasi Data Mining," *SCAN - J.*

Tekno. Inf. dan Komun., vol. 15, no. 1, pp. 34–39, 2020, doi: 10.33005/scan.v15i1.1850.

- [8] M. A. I. Anshori, *Perbandingan Metode Naïve Bayes Dengan K-Nearest Neighbor (KNN) Untuk Klasifikasi Kategori Abstrak Skripsi*. Fakultas Teknik Informatika, Universitas Islam Negeri Maulana Malik Ibrahim: tidak diterbitkan, 2020.
- [9] H. Wu and X. Gu, "Reducing over-weighting in supervised term weighting for sentiment analysis," *COLING 2014 - 25th Int. Conf. Comput. Linguist. Proc. COLING 2014 Tech. Pap.*, pp. 1322–1330, 2014.
- [10] M. Lan, C. L. Tan, and H. B. Low, "Proposing a new term weighting scheme for text categorization," *Proc. Natl. Conf. Artif. Intell.*, vol. 1, pp. 763–768, 2006.
- [11] M. A. Suprayogi and R. A. Supono, "Klasifikasi Helpdesk Menggunakan Metode K-Nearest Neighbor dan TF-ABS," *Techno.Com*, vol. 20, no. 4, pp. 508–517, 2021, doi: 10.33633/tc.v20i4.5094.
- [12] J. S. Komputer, N. Ajijah, A. Kurniawan, S. T. Informatika, F. I. Komputer, and U. Singaperbangsa, "Klasifikasi Teks Mining Terhadap Analisa Isu Kegiatan Tenaga Lapangan Menggunakan Algoritma K-Nearest Neighbor (KNN)," *J. Sains Komput. Inform.*, vol. 7, pp. 254–262, 2023.
- [13] A. N. Assidyk, E. B. Setiawan, and I. Kurniawan, "Analisis Perbandingan Pembobotan TF-IDF dan TF-RF pada Trending Topic di Twitter dengan Menggunakan Klasifikasi K-Nearest Neighbor," *e-Proceeding Eng.*, vol. 7, no. 2, pp. 7773–7781, 2020.
- [14] F. Tempola, M. Muhammad, and A. Khairan, "Perbandingan Klasifikasi Antara KNN dan Naive Bayes pada Penentuan Status Gunung Berapi dengan K-Fold Cross Validation," *J. Tekno. Inf. dan Ilmu Komput.*, vol. 5, no. 5, p. 577, 2018, doi: 10.25126/jtiik.201855983.
- [15] M. Kuhn and K. Johnson, *Applied predictive modeling*. 2013.
- [16] A. T. Ni'mah and A. Z. Arifin, "Perbandingan Metode Term Weighting terhadap Hasil Klasifikasi

Teks pada Dataset Terjemahan Kitab
Hadis," *Rekayasa*, vol. 13, no. 2, pp.
172–180, 2020, doi:
10.21107/rekayasa.v13i2.6412.