

Pendeteksian Berita Hoax Menggunakan Naive Bayes Multinomial Pada Twitter dengan Fitur Pembobotan TF-IDF

Candra Surya Sriyano¹, Erwin Budi Setiawan²

^{1,2}Fakultas Informatika, Universitas Telkom, Bandung

¹candrasurya@students.telkomuniversity.ac.id, ²erwinbudisetiawan@telkomuniversity.ac.id

Abstrak

Media sosial adalah sarana tempat untuk berkomunikasi dan bertukar informasi sesama manusia, dan salah satu media sosial yang digunakan adalah Twitter. Namun informasi yang disebarkan tidak seluruhnya berupa fakta, melainkan ada berita yang tidak sesuai kebenarannya atau sering disebut hoax. Penelitian ini, penulis membangun sistem berita deteksi hoax pada media sosial Twitter dengan menggunakan metode Naive Bayes Multinomial. Proses klasifikasi dilakukan dengan tahapan PreProcessing dan pembobotan kata menggunakan TF-IDF sampai terbentuk korpus terkait berita hoax. Hasil akhir pada pendeteksian berita hoax menggunakan Naive Bayes Multinomial dengan pembobotan TF-IDF ini diperoleh akurasi tertinggi sebesar 72.06%.

Kata Kunci: Hoax, Non-Hoax, Twitter, Sosial Media, Naive Bayes Multinomial, TF-IDF

Abstract

Social media is a means for communicating and exchanging information among humans, and one of the social media used is Twitter. However, the information disseminated is not entirely in the form of facts, but there is news that does not match the truth or is often called a hoax. This final project research, the writer builds a hoax detection news system on Twitter social media using the Naive Bayes Multinomial method. The classification process is carried out with the Pre-processing stage and word weighting using TF-IDF until a corpus is formed related to hoax news. The final result in detecting hoax news using Naive Bayes Multinomial with TF-IDF weighting obtained the highest accuracy of 72.06%.

Keywords: Hoax, Non-Hoax, Twitter, Social Media, Naive Bayes Multinomial, TF-IDF

1. Pendahuluan

Perkembangan teknologi informasi dan komunikasi saat ini mengalami kemajuan yang sangat pesat, sehingga arus informasi dapat dengan mudah tersebar tidak hanya di dunia nyata tetapi juga di dunia maya khususnya di media social. Media Sosial adalah media online (daring) yang dimanfaatkan sebagai sarana pergaulan sosial secara online di internet. Di media sosial, para penggunanya dapat saling berkomunikasi, berinteraksi, berbagi, networking, dan berbagai kegiatan lainnya [17]. Media sosial menggunakan teknologi berbasis website atau aplikasi yang dapat mengubah suatu komunikasi ke dalam bentuk dialog interaktif. Beberapa contoh media sosial yang banyak digunakan adalah YouTube, Facebook, Blog, Twitter, dan lain-lain [17]. Setiap orang memiliki kebebasan untuk mengunggah sebuah konten positif ataupun negatif. Bahkan mereka juga dapat secara bebas menyalahgunakan informasi atau menyebarkan informasi yang tidak sesuai dengan kebenarannya atau berita hoax.

Hoax adalah berita bohong yang disengaja, yang menghasut, yang tidak akurat [16]. Di Indonesia, media sosial menjadi saluran penyebaran berita hoax tertinggi yaitu sebesar 87.5% jika dibandingkan dengan aplikasi chatting (67%), website (28.2%), televisi/radio (8.7%), media cetak (6.4%), dan email (2.6%) [16]. Penyebaran berita hoax sangat merugikan masyarakat karna banyak pihak yang merasa dirugikan dengan tersebarnya berita hoax tersebut.

Dengan maraknya berita hoax yang tersebar di media sosial terutama twitter [17], tujuan penulis melakukan penelitian ini adalah untuk mengklasifikasikan berita yang ada di media sosial twitter termasuk kedalam kategori hoax atau non-hoax. Dengan menggunakan metode Naive Bayes Multinomial dan pembobotan *Term Frequency Inverse Document Frequency* (TF-IDF), Metode *Multinomial Naive Bayes* ini memanfaatkan teorema probabilitas yaitu teorema bayes dan fungsionalitas *data mining* yaitu klasifikasi *naive bayesian*, Naive Bayes Multinomial adalah salah satu metode bayes yang digunakan dengan memperhitungkan frekuensi masing-masing kemunculan data kata dalam sebuah dokumen dan probabilitas [35], Kelebihan *Naive Bayes Multinomial* diantaranya adalah tingkat akurasi yang tinggi, mudah diimplementasikan, waktu komputasi yang

rendah serta *error rate* yang minimum [34]. Hal inilah yang melatar belakangi penulis untuk menjelaskan metode ini.

Penelitian ini bertujuan untuk mengetahui bagaimana cara untuk mendeteksi berita *hoax* dengan menggunakan Naive Bayes Multinomial dan fitur pembobotan TF-IDF, serta bagaimana hasil akurasi dari pendeteksian berita *hoax* dengan menggunakan Naive Bayes Multinomial dan fitur pembobotan TF-IDF. Menggunakan tweet sebanyak 51.421 data berbahasa Indonesia yang diambil dengan cara crawling secara berkala dari bulan Oktober 2019 hingga Maret 2020, tweet diambil dari trending yang mengandung unsur *hoax* dengan kata kunci “#Kebakaran Hutan”, “#Kerusuhan Wamena”, “#AniesMundurJakartaTeratur”, “#DewanPerampokRakyat, dan “#Demo RKUHP”. Data tersebut diberi label menggunakan excel dengan nilai 1 dan 0, 1 untuk nilai *hoax* dan 0 untuk non-*hoax* data akan dibagi menjadi data latih dan data uji. Selanjutnya, data digunakan untuk performansi metode yang diterapkan confusion matrix adalah akurasi, presisi, recall dan f1-score. Data latih dan data uji dijalankan sebanyak lima kali untuk mendapatkan hasil akurasi rata-rata dan yang akan diambil adalah nilai akurasi tertinggi.

2. Studi Terkait

2.1 Identifikasi Hoax

Sebelumnya sudah ada beberapa penelitian sebelumnya terkait deteksi *hoax*. salah satunya oleh Laode Muhammad Ikhsan, metode yang digunakan adalah Decision Tree dan Analytical Hierarchy Process. Data yang digunakan pada penelitian ini adalah merupakan data yang bertopik musibah. Pengujian data dilakukan berdasarkan informasi dari akun pembuat tweet seperti follower, following, verified user, verified retweet, total tweet, usia akun, konsistensi nama dan juga berdasarkan isi dari tweet seperti sentimen kata, provokasi, permusuhan, dan isi berita. Pengklasifikasian pada penelitian ini menggunakan algoritma ID3 dengan pembobotan AHP yang diuji dengan 4 pembagian data yang berbeda. Untuk pencapaian akurasi tertinggi yaitu pada skenario data training 70% dan data testing 30% dengan akurasi sebesar 98.46% [18].

Penelitian dalam melakukan deteksi *hoax* pun kembali dilakukan oleh Achmad Fauzi, menggunakan metode Term Frequency Inverse Document Frequency (TF-IDF) dan Support Vector Machine (SVM). Penggunaan pembobotan Term Frequency Inverse Document Frequency (TF-IDF) di sistem memberikan nilai bobot pada tweet yang diambil dari kemunculan kalimat berita *hoax* yang disebar oleh seseorang di Twitter. Pengklasifikasian data menggunakan metode Support Vector Machine (SVM) pada sistem untuk memprediksi kemungkinan seorang pengguna akun twitter menyebarkan suatu berita *hoax* berdasarkan perilaku pengguna tersebut. Pengujian data dilakukan berdasarkan isi konten tweets. Dataset disusun berdasarkan attribute yang digunakan seperti jumlah retweet, URL, jumlah hashtag, provokasi, permusuhan, kecemasan, dan berita tidak berimbang. Data hasil olahan dibagi menjadi data training dan data testing. Hasil pengujian data dengan menggunakan semua fitur memperoleh akurasi tertinggi sebesar 78,33% [19].

Penelitian selanjutnya dilakukan oleh Rizal Widiatmaja, Penelitian ini menggunakan metode Metode Lexical Analysis Dalam Mendeteksi Fake News/Hoax pada Sebuah Artikel Web Menggunakan Stance Detection, Stance Detection merupakan cara dalam menentukan secara otomatis apakah penulis teks mendukung, melawan, atau netral terhadap proposisi atau target. Ekstraksi fitur yang digunakan dalam pengimplementasian Stance Detection pada penelitian ini, yaitu n-gram dengan mempertimbangkan nilai $n=1$ (unigram), word overlap, dan fitur induksi serta menggunakan decision tree gradient boosting untuk pengklasifikasiannya dengan learning rate=0.09. Data pada pengujian kali ini menggunakan FNC-1 dataset. Hasil pengujian yang dilakukan berdasarkan hasil confusion matrix didapatkan nilai akurasi yaitu 80.61% [20].

Selanjutnya penelitian dilakukan oleh Eias Reihandtsa Mamuri, penulis menggunakan Algoritma Adaboost dan ANP. Data yang digunakan pada penelitian ini adalah merupakan data yang bertopik olahraga. Pengujian data dilakukan berdasarkan informasi dari akun pembuat tweet seperti jumlah retweet, followers, following, url, verified user, verified retweet, total tweet, hastag, mention, usia akun, konsistensi nama, jumlah hastag, jumlah mention dan juga berdasarkan isi dari tweet seperti sentimen kata, provokasi, permusuhan, kecemasan dan isi berita. Pengklasifikasian pada penelitian ini menggunakan algoritma Adaptive Boosting dengan pembobotan ANP yang diuji dengan 5 pembagian data yang berbeda. Untuk pencapaian akurasi tertinggi yaitu pada skenario data training 50% dan data testing 50% dengan akurasi sebesar 91.71% [21].

Selanjutnya, penelitian dilakukan oleh Ageng Budhiarto, menggunakan metode *Backpropagation*, penggunaan metode *Backpropagation* pada prediksi dan klasifikasi data dapat digunakan untuk memprediksi kemungkinan seorang pengguna akun twitter menyebarkan suatu berita hoax berdasarkan perilaku pengguna tersebut. Pengujian data dilakukan berdasarkan isi konten tweets dan perilaku pengguna. Data set disusun berdasarkan atribut yang digunakan seperti jumlah *followers*, *following*, jumlah tweets dan keaktifan pengguna yang berdampak pada diterimanya dan tersebarnya suatu berita. Data set tersebut digunakan untuk pelatihan (training) pada *Backpropagation* menggunakan algoritma *gradient descent Backpropagation* dan *lavenberg-marquard Backpropagation*. Setelah proses training selesai maka hasil training diuji untuk mengenal 4 jenis pola masukan. Hasil pengujian kemudian dibandingkan untuk melihat kelebihan dan kekurangan kedua algoritma *Backpropagation* tersebut. Pada proses pengujian yang dilakukan dengan metode *lavenberg-marquard Backpropagation* mendapatkan akurasi rata-rata sebesar 72.21% dengan MSE (0.1979) terendah dibandingkan dengan *Backpropagation gradien descent* pada learning rate dengan nilai 0.8, *backpropagation training* memiliki akurasi yang baik namun membutuhkan waktu pelatihan yang relatif lama dengan mencapai batas maksimum *epoch* 1000 [22].

Penelitian yang dilakukan sebelumnya [18], [19], [20], [21], [22] kesimpulan dari penelitian sebelumnya penggunaan metode Decision Tree dan Analytical Hierarchy Process memiliki nilai akurasi lebih unggul dari metode lainnya pada paper [18], pada paper [22] dengan *backpropagation* memiliki kekurangan yaitu membutuhkan waktu pelatihan yang relatif lama dengan mencapai batas maksimum *epoch* 1000. Maka dari hasil *paper* diatas penulis akan melakukan percobaan dengan menggunakan *Naive Bayes Multinomial* dengan pembobotan TF-IDF untuk melihat hasil performansi dari metode tersebut.

2.2 Hoax

Hoax merupakan informasi atau berita yang berisi hal-hal yang belum pasti atau yang benar-benar bukan merupakan fakta yang terjadi [3]. Tujuan dari penyebaran *hoax* beragam, diantaranya sebagai bahan lelucon, iseng, bahan promosi, ataupun sebagai alat untuk menjatuhkan pesaing. Dengan itu, penerima berita *hoax* akan mudah terpancing dan menyebarkannya lagi kepada rekan-rekannya hingga pada akhirnya berita *hoax* tersebar luas secara cepat. Hal ini juga didukung jika si penerima *hoax* kurang memiliki pengetahuan dalam memanfaatkan internet guna mencari kebenaran informasi yang diterima.

Menurut Dewan Pers [11], ciri-ciri *hoax* adalah sebagai berikut:

1. Mengakibatkan kecemasan, kebencian, dan permusuhan.
2. Sumber berita tidak jelas. *Hoax* di media sosial biasanya pemberitaan media yang tidak terverifikasi, tidak berimbang, dan cenderung menyudutkan pihak tertentu.
3. Bermuatan fanatisme atas nama ideologi, judul, dan pengantarnya provokatif, memberikan penghukuman serta menyembunyikan fakta dan data.

2.3 Preprocessing

Preprocessing merupakan proses olah data mentah sebelum ke proses lainnya. dengan cara eliminasi data yang tidak sesuai atau mengubah data menjadi bentuk yang lebih muda diproses oleh sistem [30]. Pada penelitian kali ini *preprocessing* yang digunakan oleh penulis adalah *Case folding*, *Normalization*, *Filtering*, *Stemming*.

2.4 Term Frequency-Inverse Document Frequency (TF-IDF)

TF-IDF atau *Term Frequency-Inverse Document Frequency* merupakan teknik *preprocessing* untuk menghitung bobot dari kata yang paling umum digunakan. Jika pada TF dilakukan pembobotan *term* pada suatu dokumen, IDF mengurangi bobot suatu *term* jika kemunculannya banyak tersebar di seluruh dokumen [24], dengan persamaan

$$W_{dt} = tf_{dt} \times idf_t \quad (1)$$

Dimana W_{dt} adalah bobot *term* t terhadap dokumen d, tf_{dt} adalah jumlah kemunculan *term* t dalam dokumen d dan idf_t adalah nilai *Inverse Document Frequency*. Nilai idf_t didapatkan dari

$$idf = \log \left(\frac{D}{df} \right) \quad (2)$$

Dimana D adalah jumlah atau banyaknya dokumen dalam koleksi dan df adalah jumlah dokumen yang mengandung *term* t.

2.5 N-Gram

N-Gram adalah model probabilistik yang dirancang dan dikembangkan untuk memprediksi item berikutnya dan urutan item. Item terdiri dari huruf, karakter, dan kata sesuai dengan aplikasi yang akan dibuat [31]. Salah satu keuntungan dari metode N-gram ini adalah bahwa bahasa bersifat independen. Dalam koreksi ejaan, N-gram merupakan urutan sebanyak N kata dalam sebuah kata atau string [32]. Dengan menggunakan dataset twitter yang tersedia, penulis melatih model classifier menggunakan frekuensi n-gram dan term frequency-inverse document frequency (TF-IDF) sebagai fitur [32].

Tabel 1. Contoh N-Gram

Data	Anies nikmati hasil proyek
Uni-gram	Anies nikmati hasil proyek
Bi-gram	Anies nikmati hasil proyek
Tri-gram	Anies nikmati hasil nikmati hasil proyek

2.6 Naive Bayes Multinomial

Naive Bayes merupakan sebuah metoda klasifikasi menggunakan metode probabilitas dan statistik yang dikemukakan oleh ilmuwan Inggris Thomas Bayes. Algoritma Naive Bayes memprediksi peluang di masa depan berdasarkan pengalaman di masa sebelumnya sehingga dikenal sebagai Teorema Bayes. Ada beberapa macam model pada Naive Bayes, pada penelitian ini penulis menggunakan Naive Bayes Multinomial. Model multinomial memperhitungkan frekuensi setiap kata yang muncul pada dokumen. Misal terdapat dokumen d dan himpunan kelas c . Untuk memperhitungkan kelas dari dokumen d , maka dapat dihitung dengan rumus [26][28][29][33]:

$$P(c|\text{term dokumen } d) = P(c) \times P(t_1|c) \times P(t_2|c) \times P(t_3|c) \times \dots \times P(t_n|c) \quad (1)$$

$P(c|\text{term dokumen } d)$ adalah probabilitas suatu dokumen termasuk kelas c . t_n yaitu kata dokumen d ke- n . $P(t_n|c)$ merupakan probabilitas kata ke- n dengan diketahui kelas c . Sedangkan $P(c)$ adalah probabilitas prior dari kelas c . Untuk mencari nilai $P(c)$ dapat dihitung dengan rumus [14]:

$$P(c) = \frac{N_c}{N} \quad (2)$$

$P(c)$ adalah jumlah kelas c pada seluruh dokumen, dan N jumlah seluruh dokumen. Sementara rumus Multinomial yang digunakan dengan pembobotan kata TF-IDF adalah sebagai berikut:

$$P(t_n|c) = \frac{W_{ct} + 1}{(\sum_{W' \in V} W'_{ct}) + B'} \quad (3)$$

$P(t_n|c)$ adalah probabilitas kata ke- n dengan diketahui kelas c . W_{ct} adalah nilai pembobotan TF-IDF atau W dari term t di kategori c . $(\sum_{W' \in V} W'_{ct})$ merupakan jumlah total W dari keseluruhan term yang berada di kategori c . (B') yaitu jumlah W kata unik (nilai idf tidak dikali dengan tf) pada seluruh dokumen.

2.7 Confusion Matrix

Confusion Matrix adalah tahap analisis dan evaluasi terhadap performansi sistem yang dirancang. Performansi diukur dengan nilai akurasi, *precision*, dan *recall*. *Confusion matrix* adalah suatu metode yang digunakan untuk melakukan perhitungan akurasi pada konsep *data mining* [1]. Tabel *Confusion matrix* dapat dilihat dalam Tabel 2.

Tabel 2. Confusion Matrix

	Predicted Class Yes (Hoax)	Predicted Class No (Not Hoax)
Actual Class Yes (Hoax)	True Positive (TP)	False Negative (FN)
Actual Class No (Not Hoax)	False Positive (FP)	True Negative (TN)

True Positive (TP) merupakan kelas hasil klasifikasi dan kelas sesungguhnya sama-sama *hoax*. *False Positive* (FP) merupakan kelas hasil klasifikasi *hoax* dan kelas sesungguhnya *no hoax*. *True Negative* (TN) merupakan kelas hasil klasifikasi dan kelas sesungguhnya sama-sama *no hoax*. *False Negative* (FN) merupakan kelas hasil klasifikasi *not hoax* dan kelas sesungguhnya *hoax*.

Pada tahapan ini akan diukur nilai performansi dari model yang telah dibuat melalui proses perhitungan akurasi, *precision*, dan *recall*. *Precision* adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem. Sedangkan *recall* adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi. Akurasi didefinisikan sebagai tingkat kedekatan antara nilai prediksi dengan nilai aktual.

1. Akurasi

Akurasi adalah tingkat kedekatan antara nilai prediksi dengan nilai sesungguhnya. Akurasi digunakan untuk mengevaluasi banyaknya kelas prediksi yang sesuai dengan kelas aktual. Semakin besar nilai akurasinya, maka performansi klasifikasi yang dihasilkan semakin baik. Berikut persamaan dari akurasi [25]:

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+TN+F} \quad (1)$$

2. Precision

Precision adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem. Dalam *data mining*, *precision* adalah jumlah dokumen yang dengan benar diklasifikasikan dalam sebuah kelas dibagi jumlah total dokumen dalam kelas tersebut. Dengan persamaan [1]:

$$\text{Precision}(P) = \frac{TP}{TP+FP} \quad (2)$$

3. Recall

Recall adalah jumlah pengguna yang dengan benar diklasifikasikan dalam sebuah kelas dibagi dengan jumlah total pengguna dalam kelas tersebut [1]. *Recall* juga sering disebut sebagai tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi. Berikut rumus dari *recall*:

$$\text{Recall}(R) = \frac{TP}{TP+FN} \quad (3)$$

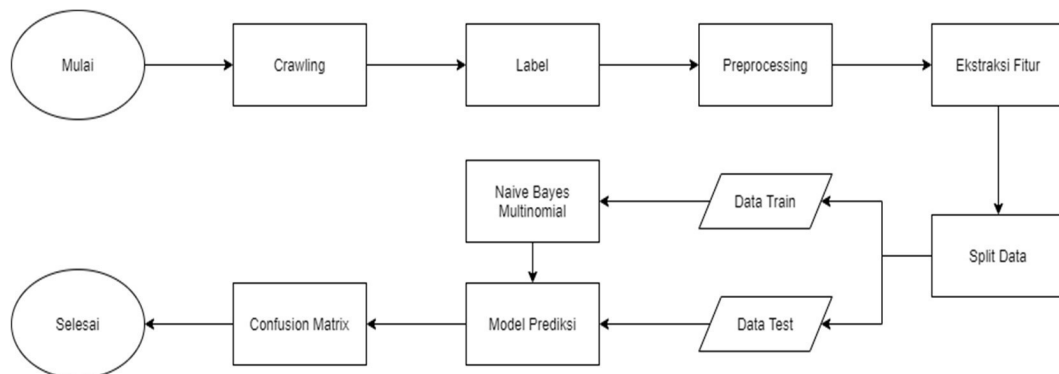
4. F1 Score

F1 Score adalah nilai rata-rata dari perbandingan *precision* dan *recall*[1]. Berikut rumus dari *F1* dapat dilihat sebagai berikut:

$$F1 = \frac{2 \times \text{Precision} \times \text{recall}}{\text{Precision} + \text{recall}} \quad (4)$$

3. Sistem yang Dibangun

Proses yang dilakukan dalam membangun sistem melewati beberapa tahap, dapat dilihat pada gambar 1.



Gambar 1. Sistem Deteksi Berita Hoax

a. Crawling Data

Crawling Data adalah suatu proses pengumpulan data yang akan digunakan sebagai data referensi oleh sistem. Pada penelitian ini pengumpulan API pada Twitter. Setiap sekali melakukan proses crawling data, data twitter yang diperoleh ada 100 *tweet* terbaru. Data yang diambil merupakan *tweet* yang berdasarkan keyword dengan melihat hastag yang diperkirakan mengandung berita hoax pada rentang waktu Oktober 2019 – Maret 2020. Total jumlah data yang terkumpul adalah 51.421 data, Setelah data terkumpul dilakukan proses pelabelan yang menunjukkan jumlah data 25.329 sesuai dengan kelas dengan label HOAX, jumlah 26.029 label NONHOAX.

Tabel 3. Keyword hasil Crawling Data

Keyword	Jumlah tweet
#Kebakaranhutan	10.324
#AniesMundurJakartaTeratur	10.436
#KerusuhanWamena	10.358
#DewanPerampokRakyat	10.105
#DemoRKUHP	10.198
TOTAL	51.421

b. Labeling

Labeling adalah proses penentuan kelas dari suatu *tweet* yang dilakukan secara manual dengan memberi label HOAX dan NONHOAX. Dalam penelitian ini *labelling*, 1 *tweet* dilakukan oleh 3 orang berbeda, kemudian dipilih yang terbanyak terkait label yang diberikan, *labelling* dilakukan secara manual dengan melihat berbagai hal, hal yang harus diperhatikan dalam memberikan label pada suatu *tweet*. Pertama penggunaan username akan dicek apakah mengandung simbol atau angka dan apakah menggunakan nama asli atau nama samaran, yang kedua apakah *tweet* mengandung unsur kebencian, kepanikan, kegelisahan, provokasi atau menyudutkan pihak lain, yang ketiga adalah penggunaan lokasi disertai URL disetiap *tweet* dilihat apakah sesuai dengan waktu atau tempat kejadian, selanjutnya membandingkan jumlah followers dan following dan yang terakhir apakah akun tersebut adalah akun yang ter-verifikasi atau tidak.

c. Preprocessing

Dalam mengolah data, dibutuhkan beberapa proses agar data mentah yang telah didapatkan sebelumnya dapat diolah dan dikelola dengan mudah. *PreProcessing* adalah suatu proses perubahan bentuk data teks yang tidak terstruktur menjadi bentuk yang terstruktur sesuai dengan kebutuhannya. Pada sistem yang dibangun, ada 4 tahap *preprocessing* yaitu Pertama *Case Folding* adalah proses mengubah semua huruf pada teks menjadi huruf kecil supaya seragam. Karakter selain huruf a-z dihilangkan dan dianggap *delimiter*. Pada proses ini, semua huruf pada data *tweet* akan diubah menjadi huruf kecil. Karakter selain a-z akan dihilangkan. Kedua *Normalization* adalah mengubah semua kata yang disingkat pada teks menjadi kata yang sesuai dalam kamus bahasa,

Ketiga *Filtering* adalah proses pemilihan kata-kata penting dari hasil *tokenizing* dengan menggunakan algoritma *stoplist* (membuang kata yang dianggap tidak penting) atau algoritma *wordlist* (menyimpan kata-kata penting). Pada proses ini dilakukan pemilihan kata-kata penting dan membuang yang tidak penting, dan *Stemming* untuk mengubah kata yang berimbuhan menjadi kata yang berbentuk kata dasar supaya menghasilkan proses yang lebih optimal. Contoh *Preprocessing* dapat dilihat pada Tabel 4.

Tabel 4. Contoh Preprocessing

<i>Text Awal</i>	@aniesbaswedan Pak Anies menikmati hasil proyek, harus segera ditangkap. #TangkapAnies
<i>Case Folding</i>	pak anies menikmati hasil proyek harus segera ditangkap
<i>Normalization</i>	pak anies menikmati hasil proyek harus segera ditangkap
<i>Filtering</i>	anies menikmati hasil proyek segera ditangkap
<i>Stemming</i>	anies nikmat hasil proyek segera tangkap

d. TF-IDF

Setelah dilakukan *Preprocessing* akan dilakukan pemberian nilai atau bobot pada tiap kata dengan menggunakan TF-IDF. Pembobotan ini memberi pengaruh pada saat mengukur kata dari suatu dokumen. Pembobotan ini akan menggunakan *N-Gram* yang terdiri dari *Unigram*, *Bigram*, *Trigram*, kemudian akan dikombinasikan menjadi *Unigram* dan *Bigram*, *Bigram* dan *Trigram*, lalu terakhir akan dikombinasikan semuanya menjadi *Unigram*, *Bigram*, *Trigram*.

4. Evaluasi

4.1 Hasil dan Pembahasan

Pada penelitian ini penulis menggunakan data hasil dari *Crawling* dengan dataset yang berjumlah 51.421 *tweet* yang telah diberikan label HOAX dan NONHOAX. Pengujian ini dilakukan agar mengetahui tingkat keberhasilan pada sistem yang telah dibuat untuk mendeteksi berita hoax. Kemudian pengujian pada sistem dibagi menjadi 2 skenario pengujian. Pengujian pertama menggunakan pembobotan TF-IDF, lalu yang kedua tidak menggunakan pembobotan TF-IDF. Pada pengujian dengan TF-IDF data akan dipecah karena menggunakan *N-Gram*, pengujian yang akan dilakukan adalah sebagai berikut:

1. Tanpa menggunakan TF-IDF
2. *Unigram*
3. *Bigram*
4. *Trigram*
5. *Unigram dan Bigram*
6. *Unigram dan Trigram*
7. *Unigram, Bigram, dan Trigram*

Skenario Pertama, Pengujian Naive Bayes Multinomial dengan fitur pembobotan TF-IDF dan tanpa fitur pembobotan TF-IDF. Pengujian ini akan menggunakan dataset sebanyak 5 kali dan akan diambil rata-rata 5 kali pengujian data dengan menggunakan data train yaitu 90%, 80%, 70%, 60%, dan 50%.

Skenario Kedua, Pengujian Naive Bayes Multinomial dengan *N-Gram* menggunakan fitur pembobotan TF-IDF. Pengujian ini akan menggunakan hasil akurasi *data train* tertinggi dari skenario pertama, model pengujian data rata-rata diambil 5 kali pengambilan secara random pada setiap *N-Gram* untuk mengetahui pengaruh *N-Gram* pada akurasi.

4.2 Analisis Hasil Pengujian

Pengujian pada klasifikasi dengan persentase data uji yang berbeda dapat dilihat pada Tabel 5 untuk hasil dengan TF-IDF dan Tabel 6 untuk hasil tanpa TF-IDF.

Tabel 5. Perbandingan Confusion Matrix dengan TF-IDF

	Akurasi	Presisi	Recall	F1
Data train 90%	71.84%	0.7185	0.7184	0.7183
Data train 80%	72.06%	0.7208	0.7206	0.7206
Data train 70%	71.84%	0.7185	0.7184	0.7183
Data train 60%	71.00%	0.7104	0.7100	0.7100
Data train 50%	70.63%	0.7068	0.7063	0.7063

Tabel 6. Perbandingan Confusion Matrix tanpa TF-IDF

	Akurasi	Presisi	Recall	F1
Data train 90%	71.18%	0.7130	0.7118	0.7113
Data train 80%	71.65%	0.7180	0.7165	0.7161
Data train 70%	71.48%	0.7162	0.7148	0.7143
Data train 60%	71.03%	0.7120	0.7103	0.7099
Data train 50%	70.35%	0.7057	0.7035	0.7029

Dari hasil pengujian yang penulis lakukan dapat dilihat bahwa pembagian data yang diuji dengan *data train* 80% menggunakan fitur pembobotan TF-IDF memperoleh akurasi tertinggi sebesar 72.06%, dan tanpa fitur pembobotan TF-IDF dengan *data train* 80% mendapatkan akurasi sebesar 71.65%. Dengan ini dapat kita lihat bahwa pembagian rasio data berpengaruh dengan hasil dari nilai akurasi. Dan dapat kita lihat juga bahwa hasil rata-rata yang diperoleh menggunakan metode pembobotan TF-IDF lebih besar dibandingkan hasil yang diperoleh tanpa TF-IDF, maka dapat disimpulkan metode pembobotan TF-IDF berpengaruh pada hasil pengujian yang dilakukan.

4.3 Analisis Pengaruh Penggunaan N-Gram pada Akurasi

Hasil menunjukkan bahwa skenario pertama memperoleh akurasi tertinggi dengan *data train* 80% menggunakan fitur pembobotan TF-IDF sebesar 72.06%, Maka ditentukanlah *data train* 80% untuk analisis pengaruh penggunaan *N-Gram* pada akurasi.

Tabel 7. Hasil data train 80% dan data test 20% untuk akurasi N-Gram

Fitur	Dengan TFIDF
Unigram	72.06%
Bigram	65.59%
Trigram	57.19%
Unigram + Bigram	71.89%
Bigram + Trigram	64.57%
Unigram + Bigram + Trigram	71.45%

Berdasarkan Tabel 7, dapat kita lihat untuk *N-Gram* keseluruhan Unigram memiliki nilai akurasi dengan menggunakan metode pembobotan TF-IDF mendapatkan nilai 72.06%. Hal itu dikarenakan fitur kata memiliki frekuensi lebih sering digunakan pada *Unigram* dibandingkan dengan *N-Gram* lainnya, sehingga *Unigram* memiliki pengaruh yang besar untuk menentukan nilai akurasi pada proses sistem pendeteksian berita hoax dari twitter.

Pengujian yang dilakukan mendapatkan hasil analisis performansi dari sistem dengan nilai akurasi 72.06%. Nilai akurasi yang didapatkan dari hasil analisis performansi sistem kurang maksimal karena pengaruh dari proses *labelling* yang dilakukan terdapat kata yang sama dan terdapat data yang hilang saat melakukan preprocessing sehingga sistem tidak dapat menguji secara maksimal yang mengakibatkan penurunannya nilai dari akurasi.

Tabel 8. Fitur pada N-Gram

Label	Unigram	Bigram	Trigram
HOAX	zalim	hujan deras	proyek monas penuh
	jebol	hasil proyek	akibat bakar hutan
	virus	presiden jokiwi	nikmati hasil proyek
	jokowi	bakar hutan	akibat bakar hutan
	war	gubernur dki	banjir wilayah jakarta
NONHOAX	tanam	curah hujan	aktif wujud damai
	narasumber	ridwan kamil	pemprov dki jakarta
	pimpin	warga dampak	gubernur dki jakarta
	pramuka	rumah warga	desain monumen nasional
	wali	pulau jawa	perisa fakta tingkat

Pada Tabel 8 menunjukkan fitur kata yang paling sering muncul pada unigram, bigram, dan trigram yang terdapat pada masing-masing klasifikasi *hoax* dan *nonhoax* yang diperoleh dari hasil sistem pembobotan kata dengan TF-IDF.

5. Kesimpulan dan Saran

Dalam Penelitian ini digunakan Naive Bayes Multinomial dan fitur pembobotan TF-IDF dengan tujuan untuk mendeteksi berita hoax sedini mungkin sebelum berita tersebut tersebar luas dan menjadi viral, sehingga dapat meminimalisir dampak negatif yang merugikan banyak orang. Kesimpulan yang didapat dari hasil penelitian ini menunjukkan Naive Bayes Multinomial dan metode pembobotan TF-IDF dapat digunakan dalam pendeteksian berita *hoax* pada twitter. Hasil akurasi yang diperoleh dari percobaan yang dilakukan oleh penulis dengan TF-IDF adalah 72.06%, Kemudian hasil akurasi dari N-Gram terbesar yaitu *Unigram* dengan *data train* 80% adalah 72.06%, Dengan adanya fitur pembobotan dengan TF-IDF, *N-Gram* berpengaruh karena membuat hasil akurasi yang didapatkan naik 0.46% lebih besar dibandingkan tanpa menggunakan N-Gram. Nilai akurasi yang didapatkan dari hasil analisis performansi sistem kurang maksimal karena pengaruh dari proses *preprocessing* yang dilakukan terdapat kata yang sama dan terdapat data yang hilang saat melakukan *preprocessing* sehingga sistem tidak dapat menguji secara maksimal yang mengakibatkan penurunannya nilai dari akurasi.

Saran dari penulis untuk penelitian selanjutnya adalah perbaikan pada tahap *preprocessing*, dicek lagi beberapa kali hasil dari data *preprocessing*, karena setelah dilakukan *preprocessing* ada data yang benar-benar hilang karena dari awal isi data tersebut hanya simbol atau link, sehingga saat dilakukan pembobotan tidak bisa diberikan nilai karena isi data tersebut kosong. Kemudian saran untuk penggunaan *stopword*, walaupun sudah menggunakan *stopword* dari korpus yang sudah ada lebih baik menambahkan juga *stopword* dari korpus yang dibuat sendiri, karena setelah dicek masih ada sedikit kata yang tidak terhapus walaupun menggunakan korpus *stopword* yang sudah tersedia.

REFERENSI

- [1] M. K. J. P. Jiawei Han, "DATA MINING Concepts and Technicques," dalam *DATA MINING Concepts and Technicques*, 2012.
- [2] A. B. G. Cahyo Darujati, "PEMANFAATAN TEKNIK SUPERVISED UNTUK," *Jurnal Link Vol 16*, 2012.
- [3] C. Juditha, "Interaksi Komunikasi Hoax di Media Sosial serta Antisipasinya," *Jurnal Pekommas, Vol. 3 No. 1*, pp. 31-44, 2018.
- [4] M. F. A. Y. F. A. A. Ahmad Fauzi, "Sentimen Analisis Berinternet Pada Media Sosial," *Jurnal Informatika*, pp. 77-83, 2019.
- [5] A. D. N. Mulawarman, "Perilaku Pengguna Media Sosial beserta Implikasinya Ditinjau dari Perspektif Psikologi Sosial Terapan," *Buletin Psikologi*, pp. 36-44, 2017.
- [6] Z. F. Nurhadi, "MODEL KOMUNIKASI SOSIAL REMAJA," *Jurnal ASPIKOM, Volume 3 Nomor 3*, pp. 539-549, 2017.
- [7] J. A. AULIA AFRIZA, "Metode Klasifikasi Rocchio untuk Analisis Hoax," *Jurnal Ilmu Komputer Agri-Informatika Volume 5 Nomor 1*, pp. 1-10, 2018.
- [8] A. S. CAHYONO, "PENGARUH MEDIA SOSIAL TERHADAP PERUBAHAN SOSIAL MASYARAKAT INDONESIA," *Jurnal Unita*, pp. 140-157, 2016.
- [9] I. Y. R. P. D. M. R. Faisal Rahutomo, "EKSPERIMEN NAÏVE BAYES PADA DETEKSI BERITA HOAX BERBAHASA INDONESIA," *Jurnal Penelitian Komunikasi dan Opini Publik Vol. 23 No. 1*, pp. 1-15, 2019.
- [10] C. Brogan, *Social Media 101: Tactics and Tips to Develop Your Business Online*, John Wiley & Sons, 2010.
- [11] B. H. d. Protokol, "Pengertian Hoax dan Ciri-Cirinya," 9 Januari 2019. [Online]. Available: <https://www.bulelengkab.go.id/detail/artikel/pengertian-hoax-dan-ciri-cirinya-41>.
- [12] INFORMATIKALOGI, "Algoritma Naive Bayes," 8 April 2017. [Online]. Available: <https://informatikalogi.com/algoritma-naive-bayes/>.
- [13] E. B. S. Z. A. B. Jaka Eka Sembodo, "Data Crawling Otomatis pada Twitter," *Ind. Symposium on Computing*, pp. 11-16, 2016.
- [14] P. Y. SAPUTRA, "IMPLEMENTASI TEKNIK CRAWLING UNTUK PENGUMPULAN DATA," *Jurnal Dinamika Dotcom Volume 8 Nomor 2*, pp. 160-168, 2017.

- [15] Mastel.id, "Hasil Survey Wabah HOAX Nasional 2019," 10 April 2019. [Online]. Available: <https://mastel.id/hasil-survey-wabah-hoax-nasional-2019/>.
- [16] tunisah, "KEMENTRIAN KOMUNIKASI DAN INFORMATIKA REPUBLIK INDONESIA," 20 Februari 2017. [Online]. Available: https://www.kominfo.go.id/content/detail/9325/panggil-twitter-kominfo-bahas-hoax/0/sorotan_media.
- [17] Maxmanroe.com, "Maxmanroe.com," [Online]. [Diakses 10 November 2019].
- [18] E. B. S. S. M. Laode Muhammad Ikhsan, "Deteksi hoax pada twitter menggunakan metode Decision Tree dan Analytical Hierarchy Process," *Open Library Katalog*, 2019.
- [19] E. B. S. S. M. D. Z. K. A. B. S. M. Achmad Fauzi, "Deteksi Berita Hoax Di Twitter dengan Metode Term Frequency Inverse Document Frequency dan Support Vector Machine," *Open Library Katalog*, 2019.
- [20] Y. S. Rizal Widiatmaja, "Analisis dan Implementasi Metode Lexical Analysis Dalam Mendeteksi Fake News/Hoax pada Sebuah Artikel Web Menggunakan Stance Detection," *Open Library Katalog*, 2019.
- [21] E. B. S. S. M. Eias Raihandtsa Mamuri, "Mendeteksi Pesan Berita Palsu (Hoax) pada Twitter dengan Algoritma AdaBoost dan ANP," *Open Library Katalog*, 2019.
- [22] F. N. A. B. Kemas Muslim Lhaksmana, "KLASIFIKASI PENGGUNA MEDIA SOSIAL TWITTER DALAM PERSEBARAN HOAX MENGGUNAKAN METODE BACKPROPAGATION," *Open Library Katalog*, 2017.
- [23] M. G. S. B. S. K. R. C. DEISY, "A NOVEL TERM WEIGHTING SCHEME MIDF," *Journal of Engineering Science and Technology*, vol. Vol.5, pp. 94 - 107, 2010.
- [24] A. Wibowo, "Binus University Graduate Program," 24 November 2017. [Online]. Available: <https://mti.binus.ac.id/2017/11/24/klasifikasi/>.
- [25] F. Guillet, *Quality Measures in Data Mining*, Springer-Verlag Berlin Heidelberg, 2007.
- [26] E. T. L. Kusriani, *ALGORITMA DATA MINING*, Yogyakarta: Andi, 2009.
- [27] A. W. P. Arni Darliani Asy'arie, "Automatic news articles classification in Indonesian language by using Naive Bayes Classifier method," *Proceedings of the 11th International Conference on Information Integration and Webbased Applications & Services*, pp. 658-662, 2009.
- [28] INFORMATIKALOGI, "Informatikalogi.com Portal Belajar, Berbagi Ilmu Informatika & Komputer," 8 April 2017. [Online].
- [29] B. S. D. S. M. Y. Y. N. S. M. Meilani T.H. Bunga, "MULTINOMIAL NAIVE BAYES UNTUK KLASIFIKASI STATUS KREDIT," *J-ICON*, vol. 6, pp. 30-34, 2018.
- [30] S. Mujilawati, "PRE-PROCESSING TEXT MINING PADA DATA TWITTER," *Seminar Nasional Teknologi Informasi dan Komunikasi 2016 (SENTIKA 2016)*, pp. 49-56, 2016.
- [31] L. S. R. Sendy Andrian Sugianto, "PEMBUATAN APLIKASI PREDICTIVE TEXT," *Semantic Scholar*, pp. 944-946, 2017.
- [32] K. H. Reynald Karisma Wibowo, "Penerapan Algoritma Winnowing Untuk Mendeteksi Kemiripan Teks Pada Tugas Akhir Mahasiswa," *Techno.COM*, vol. 15, pp. 303-311, 2016.
- [33] A. Rahman, "Online News Classification Using Multinomial Naive," *ITSMART: Jurnal Ilmiah Teknologi dan Informasi*, vol. 6, pp. 32-38, 2017.
- [34] E. F. P. H. Ashraf M. Kibriya, "Multinomial Naive Bayes for Text Categorization Revisited," *AI 2004: AI 2004: Advances in Artificial Intelligence*, pp. 488-499, 2004.
- [35] J. S. J. k. D. Rennie, "Tackling the poor assumptions of naive Bayes text classifier," In : *Proceeding of Twentieth International Conference on Machine Learning, AAAI Press (2003)*, pp. 616-623, 2003.