

Klasifikasi Pesan SMS Menggunakan Metode TF-IDF dan Support Vector Machine

M. Nabil Pratama¹, Danny Putra Ardianto²

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri
E-mail: ¹nabilprtm87@gmail.com, ²dputraardianto@gmail.com

Perkembangan teknologi komunikasi digital membuat layanan pesan singkat (SMS) tetap banyak digunakan karena sifatnya yang sederhana dan tidak memerlukan koneksi internet, namun tingginya penyebaran pesan spam seperti penipuan dan promosi yang tidak diinginkan menimbulkan risiko keamanan bagi pengguna. Pesan-pesan tersebut sering memanfaatkan variasi bahasa sehingga sulit disaring secara manual, sehingga diperlukan sistem deteksi otomatis yang mampu mengidentifikasi pola teks secara akurat. Penelitian ini menawarkan solusi dengan membangun sistem deteksi SMS spam menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF) untuk mengekstraksi fitur penting dari teks dan algoritma Support Vector Machine (SVM) sebagai model klasifikasi utama. Dataset yang digunakan terdiri dari 1.143 pesan SMS berbahasa Indonesia yang terbagi dalam tiga kategori, yaitu Normal, Penipuan, dan Promo. Proses penelitian meliputi tahapan praproses teks, pembobotan TF-IDF, pelatihan model SVM, serta evaluasi performa menggunakan metrik precision, recall, F1-score, dan akurasi. Hasil pengujian menunjukkan bahwa model SVM mampu mengklasifikasikan pesan dengan akurasi 92%, dengan precision, recall, dan F1-score berada pada kisaran 0.84 hingga 0.95 pada ketiga kelas. Sistem ini kemudian diimplementasikan dalam bentuk aplikasi web yang mudah digunakan, sehingga dapat membantu masyarakat mendeteksi pesan berbahaya secara cepat, akurat, dan praktis.

Kata Kunci — SMS Spam, TF-IDF, Support Vector Machine, Klasifikasi Teks

1. PENDAHULUAN

Perkembangan teknologi komunikasi digital memberikan kemudahan bagi masyarakat untuk berinteraksi secara cepat dan praktis[1]. Di antara berbagai media komunikasi yang tersedia, layanan pesan singkat (SMS) masih menjadi sarana yang banyak digunakan karena sifatnya yang sederhana, tidak memerlukan koneksi internet, serta kompatibel dengan seluruh jenis perangkat. Namun, tingginya penggunaan SMS juga membawa dampak negatif dalam bentuk penyebaran pesan tidak diinginkan seperti spam, promosi berlebihan, maupun penipuan digital yang berpotensi merugikan pengguna [2].

Dalam beberapa tahun terakhir, kasus penipuan yang memanfaatkan SMS menunjukkan peningkatan yang signifikan [3]. Pesan spam sering kali mengandung tautan berbahaya, informasi palsu, atau manipulasi psikologis yang dapat menyebabkan pencurian data dan kerugian finansial [4]. Pendekatan manual untuk memfilter pesan seperti ini tentu tidak efisien, terutama karena pelaku terus mengubah pola bahasa agar dapat menghindari sistem pemblokiran. Kondisi tersebut menjadikan pengembangan sistem deteksi otomatis sebagai kebutuhan mendesak untuk meningkatkan keamanan komunikasi masyarakat [5].

Berbagai penelitian sebelumnya telah menerapkan metode berbasis *keyword filtering* [6], *Naive Bayes* [7], *Random Forest* [8], maupun algoritma klasifikasi lainnya untuk mendeteksi spam [9]. Penelitian oleh Sravya dkk yang berjudul “*mobile sms spam filter techniques using machine learning techniques*” dilakukan menggunakan banyak metode salah satunya menggunakan *Support Vector Machine*, akurasi yang didapatkan cukup baik yaitu 85,3% [10], beberapa pendekatan memiliki keterbatasan, terutama dalam menangani variasi bahasa yang dinamis pada pesan spam singkat. Metode berbasis kata kunci mudah dilewati dengan variasi ejaan, sedangkan beberapa algoritma lain kurang optimal pada data berdimensi tinggi. Hal ini menandakan perlunya pendekatan yang lebih adaptif dan mampu melakukan representasi teks secara lebih akurat [11].


Berdasarkan tantangan tersebut, penelitian ini mengusulkan penggunaan *Term Frequency–Inverse Document Frequency (TF-IDF)* untuk mengekstraksi fitur penting dari pesan, dikombinasikan dengan *Support Vector Machine (SVM)* sebagai algoritma klasifikasi utama. *TF-IDF* dinilai mampu memberikan representasi numerik yang efektif terhadap teks pendek seperti SMS[12], sedangkan *SVM* unggul dalam pemisahan kelas pada data berdimensi tinggi [12]. Kombinasi keduanya diharapkan dapat memberikan akurasi yang stabil serta waktu prediksi yang cepat sehingga layak diterapkan pada sistem deteksi spam secara real-time [13].

Penelitian ini bertujuan mengembangkan sistem deteksi SMS spam yang dapat mengklasifikasikan pesan ke dalam kategori Normal, Penipuan, dan Promo secara otomatis. Sistem dibangun melalui tahapan praproses teks, pembobotan *TF-IDF*, pelatihan model *SVM*, serta implementasi dalam bentuk aplikasi dengan antarmuka yang informatif dan mudah digunakan. Kontribusi penelitian ini tidak hanya menghasilkan model klasifikasi yang efektif, tetapi juga menyediakan solusi praktis yang dapat membantu pengguna meningkatkan kewaspadaan terhadap pesan berbahaya dalam kehidupan sehari-hari.

2. METODE PENELITIAN

A. Tahapan-tahapan metode

Metode penelitian pada studi ini terdiri dari beberapa langkah terstruktur yang dimulai dari proses pengumpulan data hingga tahap evaluasi model, sehingga hasil yang diperoleh bersifat akurat dan relevan. Rangkaian tahapan yang digunakan mencakup Pengumpulan Data, Pemrosesan Data, Ekstraksi Fitur, Pelatihan Model, dan Evaluasi Hasil untuk membangun model dengan performa yang optimal. Gambaran mengenai alur metode penelitian tersebut ditampilkan pada Gambar 1.



Gambar 1. Tahapan Klasifikasi Pesan SMS


2.1 Pengumpulan Data

Pada tahap ini dilakukan proses pengumpulan data yang akan digunakan sebagai dasar pengolahan dalam penelitian. Data yang digunakan diperoleh dari situs milik Yudi Wibisono, yang dapat diakses melalui tautan berikut: http://bit.ly/yw_sms_spam_indonesia. Dataset tersebut terdiri dari dua kolom utama, yaitu kolom “Teks” yang berisi isi pesan SMS, serta kolom “label” yang memiliki tiga kategori awal, yaitu SMS normal (label 0), SMS penipuan (label 1), dan SMS promo (label 2).

Dataset ini terdiri atas pesan-pesan SMS berbahasa Indonesia yang telah diberi label ke dalam tiga kategori, yaitu SMS normal, SMS penipuan, dan SMS promo. Struktur pelabelan tersebut sesuai dengan tujuan penelitian dalam membangun model klasifikasi teks menggunakan pendekatan *Natural Language Processing (NLP)*. Pemanfaatan dataset publik ini juga memberikan keuntungan dari segi transparansi, kemudahan akses, serta mendukung kemungkinan replikasi maupun pengembangan lebih lanjut pada penelitian serupa di masa mendatang.

2.2 Pemrosesan Data

Tahap pemrosesan data bertujuan untuk menyiapkan data teks sebelum memasuki proses pemodelan, sehingga teks menjadi lebih bersih, terstruktur, dan konsisten. Proses ini diawali dengan langkah *lowercase*, yaitu mengubah seluruh karakter dalam teks menjadi huruf kecil agar tidak terjadi perbedaan makna antara kata yang sama namun berbeda format penulisannya. Selanjutnya dilakukan pembersihan karakter non-huruf menggunakan pola *regular expression (regex)* `[\^a-zA-Zs]`, yang berfungsi menghilangkan simbol, angka, maupun tanda baca yang tidak memiliki kontribusi penting dalam analisis.



Gambar 2. Tahapan Pemrosesan Data

Tahap berikutnya adalah *tokenizing*, yaitu memecah teks menjadi unit kata atau token agar proses analisis dapat dilakukan secara lebih terperinci. Setelah teks dipecah menjadi token, dilakukan *stopword* removal menggunakan daftar *stopword* NLTK bahasa Indonesia untuk menghapus kata-kata umum yang tidak memberikan makna signifikan terhadap konteks teks. Proses selanjutnya adalah *stemming*, yang dilakukan menggunakan library Sastrawi untuk mengubah kata berimbuhan menjadi bentuk dasarnya, sehingga kata-kata memiliki bentuk yang lebih seragam.

Hasil akhir dari keseluruhan proses *preprocessing* ini disimpan dalam kolom *clean_text*, yang kemudian digunakan sebagai input pada tahap ekstraksi fitur dan pemodelan. Dengan *preprocessing* yang terstruktur, data teks menjadi lebih siap untuk dianalisis dan meningkatkan kinerja model yang dibangun.

2.3 Ekstraksi Fitur

Pada tahap Feature Extraction, teks yang telah melalui proses *preprocessing* dikonversi menjadi representasi numerik agar dapat diolah oleh algoritma *machine learning*. Dalam penelitian ini, teknik ekstraksi fitur yang digunakan adalah *TF-IDF* (*Term Frequency–Inverse Document Frequency*). Metode ini bekerja dengan memberikan bobot pada setiap kata berdasarkan frekuensi kemunculannya di dalam suatu dokumen serta seberapa jarang kata tersebut muncul pada keseluruhan korpus. Dengan demikian, kata-kata yang dianggap lebih informatif atau memiliki relevansi lebih tinggi akan memperoleh bobot yang lebih besar.


Penggunaan *TF-IDF* memungkinkan model untuk menangkap kata-kata penting dalam pesan SMS dan mengubah informasi tekstual yang bersifat kualitatif menjadi bentuk numerik yang dapat diproses lebih lanjut oleh algoritma pembelajaran mesin. Representasi vektor yang dihasilkan dari *TF-IDF* inilah yang kemudian digunakan sebagai *input* pada tahap pemodelan.

2.4 Pelatihan Model SVM

Pada tahap Modeling, algoritma *machine learning* diterapkan untuk membangun model klasifikasi teks berdasarkan fitur yang telah diekstraksi menggunakan *TF-IDF*. Dalam penelitian ini, algoritma yang digunakan adalah *Support Vector Machine (SVM)*, yang dikenal efektif dalam menangani data berdimensi tinggi seperti teks.

SVM bekerja dengan mencari *hyperplane* terbaik yang memisahkan setiap kelas secara maksimal. Dengan memanfaatkan margin yang optimal, *SVM* mampu menentukan batas keputusan yang jelas antara kategori pesan SMS, sehingga cocok digunakan untuk tugas klasifikasi dengan struktur data yang kompleks. Kernel linear digunakan untuk memproses representasi numerik hasil *TF-IDF*, karena kernel ini sesuai dengan karakteristik data teks dan mampu memberikan performa yang stabil.

Model *SVM* yang dibangun kemudian dilatih menggunakan data hasil *preprocessing* dan dievaluasi untuk menilai kemampuannya dalam membedakan pesan SMS ke dalam kategori yang telah ditentukan. Kinerja model selanjutnya dianalisis menggunakan metrik evaluasi yang relevan untuk menentukan efektivitas pendekatan ini dalam klasifikasi pesan SMS.



Gambar 3. Pemodelan SVM

2.5 Evaluasi Model

Tahap evaluasi merupakan langkah akhir dalam proses *Knowledge Discovery in Database (KDD)*. Pada tahap ini, hasil yang diperoleh dianalisis dan disajikan agar lebih mudah dipahami, sehingga diperlukan tampilan informasi yang jelas dan informatif. Evaluasi dilakukan untuk menilai tingkat akurasi serta ketepatan model dalam melakukan klasifikasi. Berbagai penelitian data mining umumnya menggunakan *metrik precision, recall, f-measure*, dan *accuracy* sebagai alat ukur kinerja model [14]. Pada tahap ini, nilai-nilai tersebut dihitung untuk mengetahui sejauh mana kualitas hasil klasifikasi yang dihasilkan.

1. *Precision*

Precision merupakan rasio antara jumlah prediksi positif yang benar dengan total prediksi positif yang dihasilkan, baik yang benar maupun yang salah. [15].

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(1)$$

2. *Recall*

Recall adalah rasio antara jumlah data positif yang berhasil diprediksi dengan benar terhadap total data positif yang ada, termasuk data positif yang salah diprediksi sebagai negatif [15].

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(2)$$

3. *F1-Score*

F-measure merupakan ukuran performa yang menggabungkan *precision* dan *recall* dalam satu metrik. Nilai ini diperoleh dari perhitungan dua kali hasil perkalian *precision* dan *recall*, kemudian dibagi dengan penjumlahan keduanya. Metrik ini digunakan untuk memberikan gambaran keseimbangan antara kemampuan model dalam mendeteksi data positif secara tepat dan lengkap [15].

$$F1 - Score = \frac{Precision*Recall}{Precision+Recall} \dots\dots\dots(3)$$

4. *Accuracy*


Accuracy digunakan untuk mengukur tingkat ketepatan model dalam melakukan klasifikasi secara keseluruhan. Semakin tinggi nilai *accuracy* yang diperoleh, maka semakin baik kinerja model atau kernel yang digunakan dalam proses klasifikasi [15].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(4)$$

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 1.143 data pesan SMS yang telah diklasifikasikan ke dalam tiga kategori utama, yaitu Normal, Penipuan, dan Promo. Setiap pesan SMS pada dataset memiliki dua komponen, yakni teks pesan dan label kategori. Distribusi jumlah data pada masing-masing kategori disajikan pada diagram batang pada Gambar 4, yang menunjukkan proporsi pesan pada setiap kelas.



Gambar 4. Deskripsi Dataset

Secara rinci, dataset terdiri dari:

- 569 data SMS kategori normal, yaitu pesan reguler yang tidak mengandung unsur penipuan maupun promosi.
- 335 data SMS kategori penipuan, yaitu pesan yang mengandung indikasi upaya penipuan seperti pengumuman hadiah palsu, permintaan informasi pribadi, atau manipulasi lainnya.
- 239 data SMS kategori promo, yaitu pesan yang berisi penawaran produk atau layanan tertentu, baik yang resmi maupun tidak resmi.

Distribusi kelas pada dataset tampak tidak sepenuhnya seimbang, dengan kategori Normal memiliki jumlah data terbesar, diikuti kategori Penipuan dan Promo. Ketidakseimbangan ini penting untuk diperhatikan dalam proses pelatihan model karena dapat mempengaruhi performa klasifikasi, khususnya pada kategori dengan jumlah data lebih sedikit. Visualisasi jumlah SMS pada masing-masing kategori ditampilkan pada grafik batang, yang memperlihatkan dominasi kelas Normal dan perbedaan signifikan dengan kelas Penipuan dan Promo. Hal ini memberikan gambaran awal mengenai karakteristik data yang akan diolah lebih lanjut dalam proses preprocessing dan ekstraksi fitur.

3.2 Praprosesing

Tahap *preprocessing* berhasil mengubah data mentah berupa SMS yang awalnya tidak terstruktur, penuh variasi penulisan, serta mengandung banyak unsur informal, menjadi teks yang bersih, terstandarisasi, dan siap diproses lebih lanjut. Proses ini mencakup beberapa langkah penting, yaitu *case folding*, normalisasi kata, tokenisasi, *stopword removal*, dan *stemming*. Setiap langkah memiliki peran spesifik dalam mereduksi *noise*, menyederhanakan bentuk kata, serta meningkatkan relevansi informasi yang terkandung dalam teks. Hasil akhir dari seluruh tahapan *preprocessing* ini disimpan dalam kolom *clean_text*, yang merepresentasikan versi teks yang paling bersih dan paling sesuai untuk tahapan ekstraksi fitur serta pelatihan model klasifikasi.

	teks	label	clean_text
0	[PROMO] Beli paket Flash mulai 1GB di MY TELKO...	2	promo beli paket flash my telkomsel app extra ...
1	2.5 GB/30 hari hanya Rp 35 Ribu Spesial buat A...	2	rupiah ribu spesial pilih aktif promo sd novem...
2	2016-07-08 11:47:11.Plg Yth, sisa kuota Flash ...	2	langgan hormat sisa kuota flash kb download my...
3	2016-08-07 11:29:47.Plg Yth, sisa kuota Flash ...	2	langgan hormat sisa kuota flash kb download my...
4	4.5GB/30 hari hanya Rp 55 Ribu Spesial buat an...	2	rupiah ribu spesial pilih aktif buru skb
...	...	...	...
1138	Yooo sama2. oke nanti aku umumin di grup kelas	0	yooo oke umumin grup kelas
1139	☺ sebelumnya ga ad nulis kerudung. Kirain warn...	0	nulis kerudung kirain warna jins
1140	Mba mau kirim 300 ya	0	mbak kirim ya
1141	nama1 beaok bwrangkat pagi...mau cas atay tra...	0	nama beaok bwrangkat pagimau cas atay tranfer
1142	No bri atas nama kamu mana	0	nomor bri nama

Gambar 5. Hasil *preprocessing*

Pada gambar 5 tersebut menunjukkan bahwa tahapan preprocessing telah berhasil menghasilkan teks yang lebih ringkas, relevan, dan kaya informasi. Kolom *clean_text* yang dihasilkan menjadi fondasi utama dalam proses ekstraksi fitur menggunakan *TF-IDF*. Tanpa *preprocessing*, model akan sulit mengenali pola penting karena data mentah mengandung terlalu banyak variasi bahasa, simbol, dan kata tidak baku. Dengan adanya struktur teks yang sudah distandardisasi, model dapat mempelajari pola tertentu dari setiap kategori SMS baik Normal, Penipuan, maupun Promo secara lebih efektif dan akurat.

3.3 Ekstraksi Fitur

Ekstraksi fitur dilakukan menggunakan metode *TF-IDF* yang merepresentasikan setiap SMS ke dalam bentuk vektor numerik berdasarkan frekuensi kemunculan kata dan tingkat kelangkaannya pada keseluruhan dokumen. Metode ini efektif dalam menonjolkan kata-kata penting pada setiap kategori SMS serta mengurangi pengaruh kata umum yang tidak relevan. Matriks *TF-IDF* yang dihasilkan menjadi dasar utama dalam proses pelatihan model dan terbukti memberikan kontribusi signifikan terhadap peningkatan performa klasifikasi

	Nilai	Fitur
0	0.843018	aa
1	0.419698	aamiiin
2	1.558607	aamiin
3	0.686416	ab
4	0.759870	abadi
...	...	...
3440	1.126664	zalora
3441	0.503012	zarkasi
3442	0.686416	zjt
3443	2.918687	zona
3444	0.835998	ztkm
3445 rows × 2 columns		

Gambar 6. Fitur dengan nilai *TF-IDF*

Pada gambar 6 menunjukkan fitur-fitur dengan nilai *TF-IDF* tertinggi dan terendah. Kata seperti “paket”, “kuota”, “hadiah”, “pin” memperoleh bobot yang tinggi karena kemunculannya yang dominan pada kategori tertentu, terutama SMS promo dan penipuan. Bobot tinggi ini menunjukkan bahwa kata-kata tersebut sangat diskriminatif dan berperan penting dalam membedakan kategori pesan.

Sebaliknya, fitur seperti “via”, “kopi”, “maksimal”, “cepat” memiliki nilai *TF-IDF* rendah karena kemunculannya jarang atau tersebar merata pada seluruh kategori, sehingga tidak memberikan kontribusi signifikan terhadap pemetaan kelas. Pola bobot *TF-IDF* ini memperjelas bagaimana representasi numerik mampu menyoroti kata-kata yang lebih relevan untuk proses klasifikasi.

3.4 Pemodelan

```

x = selected_x
y = data.label

x_train, x_test, y_train, y_test = train_test_split(x, y, test_size=0.2, random_state=0)

print('Banyaknya X-tarining :', len(x_train))
print('Banyaknya X-test :', len(x_test))
print('Banyaknya Y-tarining :', len(y_train))
print('Banyaknya Y-test :', len(y_test))

```

✓ 0.2s Python

```


Banyaknya X-tarining : 914
Banyaknya X-test : 229
Banyaknya Y-tarining : 914
Banyaknya Y-test : 229

```

Gambar 7. Pemodelan

Pada gambar 7 merupakan proses pelatihan model dilakukan dengan memanfaatkan representasi TF-IDF sebagai input dan algoritma klasifikasi teks untuk mempelajari pola setiap kategori SMS. Dataset dibagi menjadi data *training* dan *testing* dengan proporsi 80:20. Model kemudian dilatih untuk mengenali karakteristik khusus dari masing-masing kategori, seperti pola kata pada pesan Promo, Penipuan, dan Normal. Model yang telah dilatih siap untuk dievaluasi performanya menggunakan berbagai metrik pengujian.

3.5 Hasil Evaluasi



Gambar 8. *Confusion matrix*

Gambar 8 merupakan *confusion matrix* menunjukkan bahwa model mampu mengenali mayoritas pesan SMS pada semua kategori dengan tingkat ketepatan yang tinggi. Kelas Normal memiliki prediksi paling akurat dengan 120 dari 126 data teridentifikasi dengan benar. Kelas Penipuan dan Promo juga menunjukkan performa baik meskipun terdapat beberapa kesalahan klasifikasi akibat kemiripan pola bahasa antar kelas. Secara keseluruhan, visualisasi ini memperkuat hasil evaluasi bahwa model memiliki performa yang sangat baik dalam mendeteksi SMS Normal, Penipuan, dan Promo.

Tabel 1. Hasil Evaluasi Model

Metode	Precision(%)			Recall(%)			F1-score(%)			Accuracy (%)
	0	1	2	0	1	2	0	1	2	
SVM	0.93	0.92	0.86	0.95	0.89	0.84	0.94	0.91	0.85	0.92

Pada tabel 1 menunjukkan bahwa metode SVM memiliki performa yang cukup baik dalam klasifikasi SMS. *Precision*, *recall*, dan *F1-score* untuk ketiga kelas berada pada kisaran 0.84–0.95, yang berarti model cukup akurat dalam mengenali setiap kategori. Secara keseluruhan, SVM mencapai *accuracy* 92%, sehingga dapat dikatakan bahwa model bekerja dengan baik dalam mengklasifikasikan SMS Normal, Penipuan, dan Promo.

3.6 Tampilan website



Gambar 9. Bagian Informasi SMS Spam

Pada gambar 9 menunjukkan menu informasi SMS spam, halaman ini berisi penjelasan dasar mengenai apa itu SMS spam. Di dalamnya dijelaskan bahwa SMS spam adalah pesan yang tidak diinginkan, biasanya berisi promosi, penipuan, atau informasi yang tidak relevan. Tujuan menu ini adalah memberikan edukasi kepada pengguna agar mereka memahami bahaya SMS spam serta pentingnya melakukan deteksi sebelum mempercayai isi pesan.




Gambar 10. Bagian Langkah-langkah penggunaan Aplikasi

Pada gambar 10 menunjukkan menu panduan aplikasi berisi langkah-langkah cara menggunakan sistem deteksi SMS spam. Pada halaman ini, pengguna diberikan penjelasan singkat agar tidak bingung dalam menjalankan aplikasi. Isi menu ini menjelaskan apa yang harus dilakukan pertama kali, seperti memilih menu “Aplikasi Deteksi SMS”, memasukkan teks pesan, hingga melihat hasil kategorinya. Menu ini membantu pengguna memahami alur penggunaan aplikasi secara mudah dan jelas.



Gambar 11. Bagian Sistem Deteksi

Pada gambar 11 menunjukkan menu aplikasi deteksi SMS adalah fitur utama dari sistem ini. Pada halaman ini, pengguna dapat memasukkan teks SMS ke dalam kotak yang tersedia, kemudian menekan tombol “Cek Deteksi” untuk mengetahui apakah pesan tersebut termasuk kategori Normal, Penipuan, atau Promo. Halaman ini berfungsi sebagai alat utama untuk melakukan klasifikasi SMS secara langsung dan memberikan hasil deteksi secara cepat dan praktis.



Gambar 12. Bagian Tentang Kami

Pada gambar 12 menunjukkan menu tentang kami berisi informasi singkat mengenai tim yang membuat aplikasi ini. Pada halaman ini dijelaskan bahwa aplikasi dikembangkan oleh dua mahasiswa UNP Kediri sebagai bagian dari tugas Capstone Project. Halaman ini juga memuat visi tim dalam membuat teknologi yang bermanfaat serta alasan pembuatan aplikasi, yaitu untuk membantu masyarakat lebih waspada terhadap pesan-pesan SMS yang berpotensi penipuan. Selain itu, terdapat daftar anggota tim beserta peran masing-masing dalam proses pengembangan aplikasi.

4. SIMPULAN

Penelitian ini berhasil menghasilkan sebuah sistem deteksi SMS spam yang dapat mengklasifikasikan pesan menjadi tiga kategori, yaitu Normal, Penipuan, dan Promo. Proses *preprocessing* seperti *case folding*, normalisasi, tokenisasi, dan penghapusan *stopword* mampu memperbaiki kualitas teks sebelum diproses lebih lanjut. Metode *TF-IDF* juga berhasil mengekstraksi fitur penting dari setiap pesan. Model SVM yang digunakan menunjukkan performa yang baik dengan akurasi 92%, sehingga mampu mendeteksi SMS spam secara cukup akurat. Sistem ini kemudian diimplementasikan dalam bentuk aplikasi web yang mudah digunakan, dilengkapi dengan informasi, panduan, fitur deteksi, dan halaman pengembang. Secara keseluruhan, sistem yang dibangun dapat membantu pengguna mengidentifikasi pesan berbahaya dan meningkatkan kewaspadaan terhadap SMS penipuan.

5. SARAN

Berdasarkan hasil penelitian dan pengembangan sistem deteksi SMS spam ini, terdapat beberapa saran yang dapat dipertimbangkan untuk peningkatan di masa mendatang. Pertama, jumlah dataset dapat ditambah agar model dapat belajar lebih banyak variasi pesan sehingga hasil deteksi menjadi lebih akurat. Kedua, metode klasifikasi lain seperti *Random Forest*, *Neural Network*, atau model *deep learning* dapat dicoba sebagai pembandingan untuk memperoleh performa yang lebih optimal.

Selain itu, fitur aplikasi web dapat dikembangkan lebih lanjut, misalnya dengan menambahkan riwayat deteksi, penyimpanan data, atau fitur pelaporan SMS penipuan oleh pengguna. Sistem juga dapat dikembangkan menjadi aplikasi mobile agar lebih mudah diakses. Dengan pengembangan tambahan tersebut, diharapkan sistem deteksi SMS spam ini dapat menjadi lebih lengkap, akurat, dan bermanfaat bagi masyarakat.

DAFTAR PUSTAKA

- [1] T. Fajriah and E. R. Ningsih, "Pengaruh Teknologi Komunikasi Terhadap Interaksi Sosial di Era Digital," *Merdeka Indonesia Journal International (MIJI)*, vol. 4, no. 1, pp. 149–158, 2024, [Online]. Available: (PDF lokal)
- [2] R. Deddy, H. Lumbantobing, E. Melati Manalu, D. Sartika, P. Sitinjak, and T. W. Manurung, "Roy Deddy Hasiholan Lumban Tobing: Rancangan Aplikasi Mobile Pendeteksi Spam... Sejarah penerimaan," 2021.
- [3] L. Mamoto, "PERANAN HUKUM PIDANA DALAM MENANGGULANGI PENIPUAN LEWAT SMS SERTA PENEGAKAN HUKUMNYA 1 Oleh: Lavinia Mamoto 2," 2016. [Online]. Available: www.gebyartelkomsel.com
- [4] M. Spam *et al.*, "Understanding Spam on the Digitalization of the Sei Balai Plantation Village Community, Sei Balai District, Batubara Regency," 2023. [Online]. Available: <https://jurnal.unity-academy.sch.id/index.php/japamas151>
- [5] M. B. M. Amin *et al.*, "Deteksi Spam Berbahasa Indonesia Berbasis Teks Menggunakan Model Bert," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 6, pp. 1291–1302, Dec. 2024, doi: 10.25126/jtiik.2024118121.
- [6] E. I. Hanif *et al.*, "Malay SMS Spam Detection Tool Using Keyword Filtering Technique," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Mar. 2021. doi: 10.1088/1742-6596/1793/1/012064.
- [7] A. Wahid, M. Baharulloh, R. Kahfiansyah, T. Abrilianto, A. Saifudin, and S. Mulyati, "Identifikasi SMS Spam Menggunakan Metode Naive Bayes," vol. 6, no. 3, pp. 536–539, 2021, doi: 10.32493/informatika.v6i3.11558.

-
- [8] I. Fitriyanto, T. Radillah, L. Tambunan, and A. Fauziyyah, “IMPLEMENTASI METODE RANDOM FOREST PADA TEXT MINING UNTUK KLASIFIKASI SMS SPAM MENGGUNAKAN PYTHON,” *Manajemen dan Komputer*, vol. 17, no. 1, pp. 2580–3042, 2025.
 - [9] D. Irawan, E. B. Perkasa, Y. Yurindra, D. Wahyuningsih, and E. Helmud, “Perbandingan Klassifikasi SMS Berbasis Support Vector Machine, Naive Bayes Classifier, Random Forest dan Bagging Classifier,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 10, no. 3, pp. 432–437, Dec. 2021, doi: 10.32736/sisfokom.v10i3.1302.
 - [10] G. Sai Sravya and G. Pradeepini, “Mobile Sms Spam Filter Techniques Using Machine Learning Techniques,” 2020, [Online]. Available: www.ijstr.org
 - [11] “PENERAPAN METODE NAÏVE BAYES UNTUK SISTEM KLASIFIKASI SMS PADA SMARTPHONE ANDROID.”
 - [12] N. Arifin, U. Enri, and N. Sulistiyowati, “STRING (Satuan Tulisan Riset dan Inovasi Teknologi) PENERAPAN ALGORITMA SUPPORT VECTOR MACHINE (SVM) DENGAN TF-IDF N-GRAM UNTUK TEXT CLASSIFICATION,” 2021.
 - [13] L. N. Lota and B. M. M. Hossain, “A Systematic Literature Review on SMS Spam Detection Techniques,” *International Journal of Information Technology and Computer Science*, vol. 9, no. 7, pp. 42–50, Jul. 2017, doi: 10.5815/ijitcs.2017.07.05.
 - [14] A. M. Argina, “Indonesian Journal of Data and Science Penerapan Metode Klasifikasi K-Nearest Neighbor pada Dataset Penderita Penyakit Diabetes,” vol. 1, no. 2, pp. 29–33, 2020.
 - [15] W. P. Anggraini and M. S. Utami, “KLASIFIKASI SENTIMEN MASYARAKAT TERHADAP KEBIJAKAN KARTU PEKERJA DI INDONESIA,” *Faktor Exacta*, vol. 13, no. 4, p. 255, Feb. 2021, doi: 10.30998/faktorexacta.v13i4.7964.