

Pengaruh Tokenisasi Kata N-Grams Spam SMS Menggunakan *Support Vector Machine*

Castaka Agus Sugianto ¹, Tri Herdiawan Apandi ²

¹ Teknik Informatika , Politeknik TEDC Bandung.

² Teknik Informatika , Politeknik TEDC Bandung.

Jl. Politeknik-Pesantren KM2 Cibabat Cimahi Utara – Cimahi Jawa Barat – Indonesia

¹ castaka@poltektedc.ac.id, ² h.apandi@gmail.com

Abstrak

Pesan singkat atau *Short Message Service* (SMS) merupakan fasilitas yang ada di telepon seluler. Dengan fasilitas pesan singkat ini banyak yang menyalah gunakan pesan singkat tersebut. Spam SMS adalah proses mengirimkan SMS secara terus menerus tanpa di kehendaki oleh penerimanya baik berupa iklan, jasa maupun penipuan yang dilakukan lewat telepon seluler yang dapat merugikan pengguna. Banyak cara yang dilakukan untuk mencegah spam SMS ini. Salah satunya adalah dengan penyaringan spam SMS, penelitian ini bertujuan untuk menyaring spam SMS dengan menggunakan algoritma *Support Vector Machine* (SVM) sehingga dapat memprediksi mana spam SMS dan mana yang bukan spam SMS. Pesan SMS yang dikumpulkan di lakukan preprocessing dengan melakukan kategorisasi, akronim, tokenisasi, *stop word*, pemecahan isi SMS, pembobotan, pemilihan fitur, pembuatan fitur vector, melakukan pelatihan untuk menghasilkan sebuah model. Pada penelitian ini menunjukkan hasil akurasi yang terbaik dihasil dari pemecahan kata 4-grams. Sehingga untuk menguraikan/ pemecah kata yang tepat akan menghasilkan akurasi yang baik.

Kata kunci: SVM, Spam SMS, N-Grams

Abstract

Short messages or Short Message Service (SMS) is an existing facility on the mobile phone. With this short message facility many who abuse the short message. SMS Spam is the process of sending SMS continuously without being received by the recipient in the form of advertisement, service or fraud done by cellular phone which can harm the user. Many ways are done to prevent SMS spam. One of them is SMS spam filtering, this research aims to filter SMS spam by using Support Vector Machine (SVM) algorithm so as to predict which SMS spam and which are not spam SMS. SMS messages collected by preprocessing by categorization, acronym, tokenisasi, stop word, splitting SMS content, weighting, feature selection, vector feature creation, training to produce a model. In this study showed the best accuracy results from the 4-grams word splitting. So to decipher / solver the right words will produce good accuracy

Keywords: SVM, Spam SMS, N-Grams

I. PENDAHULUAN

Layanan Pesan singkat atau *Short Message Service* (SMS) merupakan kebutuhan dasar bagi pengguna telepon, SMS adalah pesan pendek berupa teks yang merupakan layanan komponen telepon, web atau sistem komunikasi mobile, yang menerapkan protokol standar komunikasi perangkat telepon seluler. Menurut Asosiasi Telekomunikasi Seluler Indonesia (ATSI) jumlah SMS mencapai 260 miliar SMS yang terkirim pada tahun 2011 dan terdapat 27 ribu *terabyte* transaksi data (Khemapatapan, 2010).

Penyalahgunaan isi dari SMS yang bisa merugikan penerima sering disebut *Spam* SMS. Fasilitas SMS ini sering disalahgunakan oleh pihak yang tidak bertanggung jawab sering disebut Spam SMS (Anik, 2013). Spam SMS di Amerika Utara, kurang dari 1% dari seluruh sms yang terkirim ditahun 2011, sedangkan pada bagian Asia jumlah spam SMS hingga mencapai 30% yang mengandung spam SMS (Hastie & Tibshirani, 2009). Di karenakan rendahnya hambatan masuk, sehingga banyak *spammers* yang muncul dan jumlah *spam* SMS sangat tinggi. Untuk itu sangat dibutuhkan proses

penyaringan SMS terlebih untuk mencegah kerugian yang dihadapi oleh pengguna telepon seluler itu sendiri, *provider*, dan masyarakat umum yang banyak menggunakan layanan pesan singkat ini.

Pada penelitian sebelumnya mengenai penyaringan spam SMS banyak metode yang penggabungan *Support Vector Machine* dan token memiliki kekurangan pada saat isi dari SMS menggunakan imbuhan jadi tidak maksimal (Hastie & Tibshirani, 2009). *NaiveBayes* (“SMS Spam Overview,” 2012), algoritma ini memberikan hasil bahwa waktu pemrosesannya lebih cepat dan tingkat akurasi yang wajar serta waktu belajar dari algoritma *NaiveBayes* lebih cepat dibandingkan dengan algoritma *Decision Trees*. Kemudian *sampling algorithm* (Hu & Yan, 2010). *Neural Network* memberikan *error* generalisasi yang lebih besar daripada SVM (Almeida et al., 2011). Proses pemecah kalimat menjadi kata dan banyaknya jumlah fitur mempengaruhi nilai akurasi yang dihasilkan, pada penelitian ini pemecahan kata hasil berdasarkan pemilihan 1 kata saja. Sehingga kata “selamat” pada spam SMS dan “selamat” ham SMS mempunyai bobot yang sama, ini akan membingungkan *machine learning* (Apandi & Sugianto, 2015). Untuk itu

pemecahan kata menggunakan N-gram diperlukan untuk membedakan kata yang sama dengan makna yang berbeda, N-Gram dapat diartikan berfungsi dalam pengambilan potongan n karakter dalam suatu string atau kalimat tertentu (Daniel, 2016).

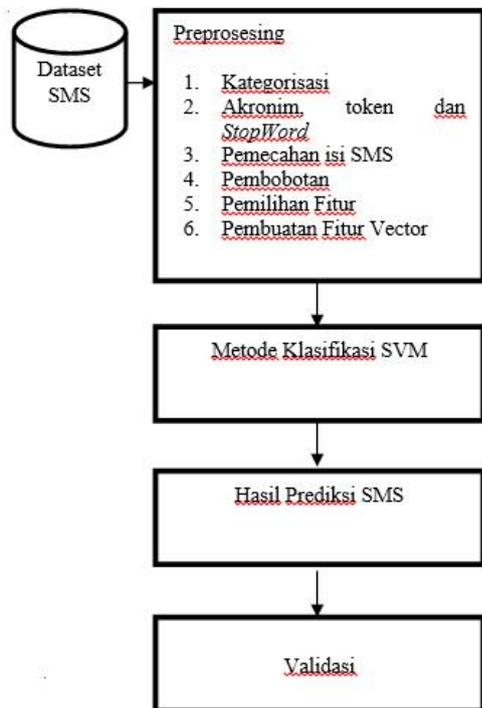
Proses training pada algoritma *Support Vector Machine (SVM)* dilakukan untuk menentukan posisi optimal dari *hyperplane* di *dual space* sedangkan hal ini margin digunakan untuk memisahkan jarak antara fungsi pemisah (*separating hyperplane*) ke masing-masing kelas. Diharapkan pada saat proses training SVM mencari untuk menentukan *training set* yang paling sempurna. Sedangkan pada metoda yang lain dalam proses training untuk mendapatkan kedua kelas secara optimal atau juga *local optimal* perlu dilakukan secara berulang sampai menemukan *local optimal* (Durgesh, 2009). Ini tentu berbeda dengan SVM *training* dilakukan hanya sekali dengan mendapatkan nilai yang optimal, hal ini mencegah terjadinya *overfitting* karena *overtrained*. Berdasarkan hasil pada penelitian sebelumnya, dapat disimpulkan bahwa algoritma SVM memiliki kinerja dasar terbaik (Almeida et al., 2011). Penelitian ini bertujuan untuk mengetahui pengaruh hasil akurasi tokenisasi kata N-Gram dengan menggunakan SVM.

II. METODE PENELITIAN

1. Tipe Metode Penelitian

Dalam penelitian kali ini menggunakan metode penelitian eksperimen, karena responden berkelompok berdasarkan beberapa kriteria sesuai dengan yang ditugaskan, dengan kata lain juga disebut perlakuan kondisi atau perlakuan *variable* (Sugianto, 2015).

2. Metode yang diusulkan



Gambar 1. Metode yang diusulkan

Permodelan yang disajikan pada gambar 1 dimulai dari pengumpulan dataset sampai validasi dataset. Pada fase pertama ini dataset akan dilakukan kategorisasi, akronim, token, *stop word*, pemecahan isi sms, pembobotan, pemilihan fitur, pembuatan fitur *vector*, pada tahap berikutnya hasil dari pengkategorian akan diklasifikasikan dengan metode *Support Vector Machine*, dan fase terakhir akan divalidasi. Penjelasan gambar 1 adalah sebagai berikut.

- a. Dataset : dataset yang dikumpulkan adalah 900, baik berupa spam sms dan yang bukan spam. Rincian dari data spam adalah 450 dan data yang bukan spam/ham adalah 450. Dataset ini akan dibagi menjadi 2, untuk training dan testing. Training sebanyak 800 data dan testing 100 data.
- b. Kategori text : menentukan mana sms yang spam dan yang bukan/ham. Dengan memberi label spam non spam. Cara untuk membedakan spam dan bukan adalah dengan cara memberikan label dari tiap- tiap data. Data yang spam diberi label 1 dan yang bukan/ham diberi 0.
- c. Akromin : mengganti singkatan dengan kata bakunya. Contoh dari tahap ini adalah “jt” menjadi “juta”, “bb” menjadi “blackberry”, dan “dg” menjadi “dengan sesuai”.

Tabel 1. Proses *stopwords*

Sebelum stop word	Setelah stop word
bapak saya mau beli sp three yang 2 gb bisa cod an kapan y? dimana?	bapak saya mau beli sp three2 gb bisa cod an kapan y? dimana?
penawaran istimewa...!!! instan cash credit 100juta=3.056.677/bulan legal proses syarat fotocopy : ktp, kartu kredit hubungi andre : 081382162051.	penawaran istimewa...!!! instan cash credit 100juta.056.677/bulan legal proses syarat fotokopi : ktp, kartu kredit hubungi andre : 081382162051.

- d. Stopwords : membuang kata –kata sambung yang sering muncul dan tidak bermakna apa-apa. Maksud tidak bermakna apa-apa contohnya dapat dilihat di tabel 1.
- e. Tokenisasi : membuang karakter yang tidak perlu, seperti !@#\$%^&*()
- f. Pemecahan isi SMS : pada tahap ini menggunakan algoritma N-Grams ini untuk membantu dalam mengambil potongan-potongan kata dari suatu kalimat SMS. Pada metode yang diusulkan menggunakan 3-grams, 4-grams, dan 5 grams kata.
- g. Pembobotan : Tahap ini dilakukan pembobotan menggunakan teknik pembobotan Biner, *Document Frequency (DF)* dan *Term Frequency (TF)*.

h. Pemilihan Fitur : pemilihan jumlah fitur berdasarkan banyaknya jumlah fitur yang muncul. Jumlah fitur yang digunakan adalah fitur yang mempunyai ranging 50, 10, 150 dan yang terakhir 200.

i. Pembuatan Fitur Vector : mengganti urutan dari bobot yang sudah dipilih menjadi nilai bobotnya, terlebih dulu diberi tanda 1 untuk spam dan 0 untuk ham sms. Contoh pembentukan sebuah kalimat:

Kejutan selamat kepada no simcard mendapatkan hadiah uang tunai rp juta dari pt mtronik pin juta untuk info klik www.ptmtronik.jimdo.com.cs

Setelah dilakukan proses pembentukan vektor fitur akan menjadi seperti dibawah ini:

-1 1:2 4:1 6:1 8:1 10:1 11:1 17:1 21:1 26:1 29:1 33:1 34:1 37:1 38:1 39:1 40:1 41:1 42:1 50:1 51:1 53:1

j. Metoda klasifikasi : metode yang digunakan adalah *Support Vector Machine* (SVM) untuk klasifikasi. Pada klasifikasi menggunakan SVM ini akan menghasilkan model yang dipakai untuk menguji data testing.

k. Hasil prediksi : hasil prediksi dari data training berupa akurasi dari tiap-tiap model.

l. Validasi : Pengujian dilakukan menggunakan k-flip lintas validasi teknik. *Cross-validasi* metode digunakan untuk memprediksi keakuratan data pengujian (Hastie & Tibshirani, 2009).

III. HASIL DAN PEMBAHASAN

Data yang dikumpulkan sebanyak 900 data SMS baik yang data SMS spam maupun data yang bukan spam. Setelah terkumpul data dilakukan proses pengolahan tahap awal yaitu pemberian label, akronim, token dan *stop word*. Berikutnya dilakukan proses pemecahan kalimat menjadi kata, isi dari SMS dipecah – pecah kedalam N-Gram, kemudian dilakukan proses pembobotan dengan teknik pembobotan Biner, *Document Frequency* (DF) dan *Term Frequency* (TF). Kemudian dilakukan klasifikasi, setelah itu akan dilihat model mana yang memiliki akurasi yang tinggi dari hasil proses pengujian yang dilakukan.

1. Pengujian

Dalam pengujian ini dilakukan pemilihan jumlah fitur dari 50 sampai dengan 200 fitur dengan pemecah kalimat kedalam kata 3-grams, 4-grams, 5-grams dengan menerapkan teknik pembobotan biner, *document frequency* dan *term frequency*. Adapun sekenario pengujian bisa dilihat pada tabel 2.

Tabel 2. Senenario Pengujian Model

Nama Model	Jumlah Fitur	Pemecah Kalimat	Teknik Pembobotan
Model 1	50	3-grams	Biner

Nama Model	Jumlah Fitur	Pemecah Kalimat	Teknik Pembobotan
		kata	
Model 2	100		
Model 3	150		
Model 4	200		
Model 5	50		Document Frequency
Model 6	100		
Model 7	150		
Model 8	200		
Model 9	50		Term Frequency
Model 10	100		
Model 11	150		
Model 12	200		
Model 13	50	4-grams kata	Biner
Model 14	100		
Model 15	150		
Model 16	200		
Model 17	50		Document Frequency
Model 18	100		
Model 19	150		
Model 20	200		
Model 21	50		Term Frequency
Model 22	100		
Model 23	150		
Model 24	200		
Model 25	50	5-grams kata	Biner
Model 26	100		
Model 27	150		
Model 28	200		

Nama Model	Jumlah Fitur	Pemecah Kalimat	Teknik Pembobotan
Model 29	50		Document Frequency
Model 30	100		
Model 31	150		
Model 32	200		
Model 33	50		
Model 34	100		Term Frequency
Model 35	150		
Model 36	200		

Pada table 2. adalah sekenario pengujian yang dilakukan, dimana terdapat 36 model yang digunakan. Setiap model mempunyai jumlah fitur dan pemecah kalimat yang berbeda-beda. Sekenario pengujian model ini akan menjadi dasar perbandingan.

Pada sekenario table 2 pada dilihat jumlah fitur yang diambil 50 sampai dengan 200. Fitur ini adalah hasil dari pemecahan kata yang teratas dipilihlah 50, 100, 150 dan 200 fitur yang teratas tersebut.

Pada sekenario table 2 terdapat rincian sebagai berikut model 1 sampai dengan 12 menggunakan 3-grams kata, 13 sampai 24 menggunakan 4-grams kata dan sisanya menggunakan 5-grams kata, dengan menggunakan banyak model pemecahan kalimat akan memperkaya hasil perbandingannya.

Pada sekenario table 2. Menggunakan jumlah fitur yang bervariasi dari 50 sampai dengan 200 fitur. Fitur tersebut dipilih karena fitur tersebut yang sering muncul pada dataset.

Terakhir adalah penggunaan teknik pembobotan. Teknik yang dipakai adalah biner, document frequency dan term frequency.

Selanjutnya dari sekenario pada table 1 maka akan dilakukan pengujian akurasi. Pengujian yang dilakukan dengan terlebih dahulu membuat model yang akan diuji tingkat akurasinya. Hasil akurasi dapat diperlihatkan pada tabel 3.

Tabel 3. Hasil Akurasi Dari Model

Nama Model	Akurasi Pengujian
Model 1	91%
Model 2	91%
Model 3	91%
Model 4	89%
Model 5	90%
Model 6	54%
Model 7	54%

Nama Model	Akurasi Pengujian
Model 8	90%
Model 9	90%
Model 10	89%
Model 11	54%
Model 12	54%
Model 13	92%
Model 14	91%
Model 15	90%
Model 16	86%
Model 17	90%
Model 18	60%
Model 19	61%
Model 20	53%
Model 21	57%
Model 22	60%
Model 23	61%
Model 24	61%
Model 25	87%
Model 26	50%
Model 27	82%
Model 28	78%
Model 29	90%
Model 30	62%
Model 31	70%
Model 32	70%
Model 33	90%
Model 34	62%
Model 35	68%
Model 36	69%

Setelah dilakukan uji coba pada datasetnya maka diperoleh hasil akurasi yang diperlihatkan pada tabel 3.

Pada tabel 3 diperoleh akurasi yang tertinggi pada model 13, model 13 adalah pemecahan kata 4-grams kata dan menggunakan pembobotan biner. Ini menunjukkan dataset yang dikumpulkan rata-rata memiliki kesamaan 4-grams kata, sehingga mempengaruhi tingkat akurasinya.

Akurasi terendah ditunjukkan pada model 26 menggunakan 5-grams kata dan menggunakan biner. Sedangkan menggunakan 5-grams kata memiliki tingkat akurasi yang

terendah dibandingkan yang lain. Ini menunjukkan dengan menggunakan 5-grams kata hanya ada beberapa SMS saja, tidak merata diseluruh dataset.

Pada pemilihan fitur dengan banyak 50 fitur menunjukkan hasil akurasi yang stabil disemua tipe pembobotan baik dari *biner*, *document frequency* dan *term frequency*. Pemilihan fitur 50 teratas menghasilkan akurasi yang stabil menunjukkan bahwa semakin banyak fitur yang dipilih semakin tidak konsisten hasil akurasinya, ini disebabkan banyak nilai bobot fitur 100, 150 dan 200 memiliki nilai bobot 1. Nilai bobot satu menunjukkan fitur itu hasil sedikit dikumpulan dataset.

Dilihat dari data pengujian akurasi menunjukkan bahwa pembobotan menggunakan *term frequency* dan *biner* menunjukkan hasil akurasi yang stabil, dikarenakan pembobotan menggunakan *term frequency* dan *biner* akan melihat seluruh data fitur yang berada di dataset. Berbeda dengan *document frequency* menjadikan pembobotan ini memiliki hasil akurasi yang tidak stabil, dikarenakan fitur yang dipilih hanya hasil yang berada di dalam satu *document*/SMS bukan diseluruh dataset.

IV. KESIMPULAN

Pada penelitian ini menunjukkan bahwa pemilihan 50 fitur dan menggunakan 4-grams karakter menunjukkan hasil akurasi yang sangat baik dan stabil baik dengan dengan pemilihan fitur *document frequency*, *term frequency* dan *biner*. Pemilihan jumlah pemecahan kata sangat berpengaruh pada hasil akurasi. Penggunaan pembobotan *document frequency* dan *biner* menunjukkan hasil yang baik tetapi tidak terlalu signifikan peneliti menyarankan menggunakan pembobotan *mutual information* untuk melihat keterhubungan antara 1 fitur dengan fitur lain pada penelitian selanjutnya.

DAFTAR PUSTAKA

- Almeida, T. A., Gomes, J. M., & Yamakami, A. (2011). Contributions to the Study of SMS Spam Filtering : New Collection and Results, 1–4.
- Anik, M.(2013). Collaborative Filtering SMS Spam Berbahasa Indonesia Menggunakan Algoritma Naïve Bayes
- Apandi, T. H., & Sugianto, C. A. (2015). Penyaringan Spam Short Message Service Menggunakan Support Vector Machine. In *Seminar Nasional Teknologi Informasi dan Komunikasi Terapan (SEMANTIK)* (pp. 111–116).
- Daniel Jurafsky & James Martin, *Speech and Language Processing Second Edition*. New Jersey: Pearson Prentice Hall,2016.
- Durgesh K. Srivastava & Lekha Bhambhu (2009)DATA CLASSIFICATION USING SUPPORT VECTOR MACHINE. in *Journal of Theoretical and Applied Information Technology*.
- Hastie, & Tibshirani. (2009). *Cross Validation Bootstrap Methods*, 18–26.
- Hu, X. I. A., & Yan, F. U. (2010). SAMPLING OF MASS SMS FILTERING ALGORITHM BASED ON FREQUENT TIME-DOMAIN AREA, 548–551. <https://doi.org/10.1109/WKDD.2010.50>
- Khemapatapan, C. (2010). Thai-English Spam SMS Filtering, 226–230.
- SMS Spam Overview. (2012). *Cloudmark*, pp. 1–7.
- Sugianto, C. A. (2015). ANALISIS KOMPARASI ALGORITMA KLASIFIKASI UNTUK MENANGANI DATA TIDAK SEIMBANG PADA DATA KEBAKARAN HUTAN. *Techno.com*, 14(4), 336–342.