

**ANALISIS PENERAPAN PENYARINGAN PESAN SPAM  
PADA SMS MENGGUNAKAN METODE MULTINOMIAL  
NAIVE BAYES**

**SKRIPSI**

Diajukan untuk memenuhi salah satu syarat mencapai derajat Sarjana  
Program Studi Informatika



disusun oleh  
**SOFYAN ADI SAPUTRA**  
**19.11.3196**

Kepada  
**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**  
**2022**

**ANALISIS PENERAPAN PENYARINGAN PESAN SPAM  
PADA SMS MENGGUNAKAN METODE MULTINOMIAL  
NAIVE BAYES**

**SKRIPSI**

untuk memenuhi salah satu syarat mencapai derajat Sarjana  
Program Studi Informatika



disusun oleh  
**SOFYAN ADI SAPUTRA**  
**19.11.3196**

Kepada  
**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**  
**2022**

## HALAMAN PERSETUJUAN

### SKRIPSI

### ANALISIS PENERAPAN PENYARINGAN PESAN SPAM PADA SMS MENGGUNAKAN METODE MULTINOMIAL

#### NAIVE BAYES

yang disusun dan diajukan oleh

Sofyan Adi Saputra

19.11.3196

telah disetujui oleh Dosen Pembimbing Skripsi  
pada tanggal 28 Februari 2023

Dosen Pembimbing,

Krisnawati, S.Si., M.T.

NIK. 190302038

**HALAMAN PENGESAHAN**  
**SKRIPSI**  
**ANALISIS PENERAPAN PENYARINGAN PESAN SPAM PADA SMS**  
**MENGGUNAKAN METODE MULTINOMIAL NAIVE BAYES**

yang disusun dan diajukan oleh

**Sofyan Adi Saputra**

**19.11.3196**

Telah dipertahankan di depan Dewan Pengaji  
pada tanggal 28 Februari 2023

**Susunan Dewan Pengaji**

**Nama Pengaji**

Eli Pujastuti, M.Kom  
NIK. 190302227

Ika Nur Fajri, M.Kom  
NIK. 190302268

Krisnawati, S.Si., M.T.  
NIK. 190302038

**Tanda Tangan**



Skripsi ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Sarjana Komputer  
Tanggal 28 Februari 2023

**DEKAN FAKULTAS ILMU KOMPUTER**



Hanif Al Fatta,S.Kom., M.Kom.  
NIK. 190302096

## HALAMAN PERNYATAAN KEASLIAN SKRIPSI

### HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Yang bertandatangan di bawah ini,

Nama mahasiswa : Sofyan Adi Saputra  
NIM : 19.11.3196

Menyatakan bahwa Skripsi dengan judul berikut:

**ANALISIS PENERAPAN PENYARINGAN PESAN SPAM PADA SMS  
MENGGUNAKAN METODE MULTINOMIAL NAIVE BAYES**

Dosen Pembimbing : Krisnawati, S.Si., M.T.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 28 Februari 2023

Yang Menyatakan,



Sofyan Adi Saputra

## HALAMAN PERSEMBAHAN

Alhamdulillahirobbil'almiin, segala puji bagi Allah Subhanahu Wa Ta'ala yang telah mencerahkan rahmat dan karunia-Nya, sehingga Peneliti mampu menyelesaikan Skripsi dengan judul "**Analisis Penerapan Penyaringan Pesan Spam Pada Sms Menggunakan Metode Multinomial Naive Bayes**" ini dengan baik. Shalawat serta Salam tercurahkan kepada sang baginda Rasulullah Muhammad Shalallahu Alaihi Wassalam yang telah membimbing serta menunjukkan jalan dan petunjuk bagi umatnya. Semoga doa dan shalawat dapat menggiring kita semua menuju jalan yang lebih baik dan benar, baik di dunia maupun akhirat. Aamiin Ya Rabbal Alamin.

Karya ini Saya persembahkan untuk :

1. Ayahanda dan Ibunda tercinta, yang sampai saat ini masih terus memberikan doa, dukungan, serta motivasi
2. Seluruh keluarga saya yang telah memberikan segala dukungan, doa, serta semangat.
3. Kepada Ibu Krisnawati, S.Si., M.T. yang telah memberikan bimbingan dalam skripsi ini serta memberikan ilmu baru dalam pengerjaan skripsi.
4. Kepada teman-teman kelas 19 IF 10, terimakasih banyak sudah menemani serta membantu saya mulai dari awal perkuliahan hingga skripsi ini selesai disusun.
5. Kepada teman – teman kos ijo yang telah memberikan semangat dan menemani saya dalam pengerjaan skripsi.
6. Kepada Senior-senior yang telah membantu serta mengarahkan saya mulai dari sebelum masuk dunia perkuliahan hingga sekarang.
7. Almamater serta Kampus tercinta, Universitas AMIKOM Yogyakarta

## KATA PENGANTAR



*Assalamu'alaikum Warahmatullahi Wabarakatuh.*

*Alhamdulliahirobbil'alamin*, puji syukur kehadirat Allah Subhanahu Wa Ta'ala atas segala rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan Skripsi ini dalam rangka memenuhi sebagian persyaratan untuk memperoleh gelar Sarjana pada Program Studi Informatika Universitas Amikom Yogyakarta dengan judul "**Analisis Penerapan Penyaringan Pesan Spam Pada Sms Menggunakan Metode Multinomial Naive Bayes**". Alhamdulillah skripsi ini dapat disusun dengan baik dan lancar atas bantuan, dukungan, serta bimbingan dari berbagai pihak. Untuk itu dalam kesempatan ini peneliti mengucapkan terima kasih kepada:

1. Ayahanda dan Ibunda tercinta, yang sampai saat ini masih terus memberikan doa, dukungan, serta motivasi.
2. Bapak Prof. Dr. M. Suyanto, M.M., selaku Rektor Universitas Amikom Yogyakarta.
3. Bapak Hanif Al Fatta, M.Kom, selaku Dekan Fakultas Ilmu Komputer Universitas AMIKOM Yogyakarta
4. Ibu Windha Mega Pradnya D, M.Kom, selaku Ketua Program Studi Informatika Universitas Amikom Yogyakarta.
5. Ibu Krisnawati, S.Si., M.T., Selaku dosen Pembimbing yang selalu memberikan bimbingan, waktu, dan arahan dalam pembuatan Skripsi ini.
6. Bapak Majid Rahardi, M.Eng, selaku Dosen Wali yang telah banyak membantu dalam membimbing selama masa perkuliahan.
7. Bapak/Ibu Dosen Penguji yang telah meluangkan waktu serta tenaga disaat proses pendadaran/sidang skripsi.
8. Seluruh Dosen Universitas Amikom yang telah memberikan ilmu selama perkuliahan.

9. Kerabat terdekat yang telah memberikan dukungan, doa, serta semangat dalam proses penyusunan skripsi.
10. Teman-teman seperjuangan yang telah menemani, memberikan semangat, serta motivasi untuk terus melangkah maju.
11. Semua pihak yang telah membantu dalam kelancaran penulisan skripsi ini baik langsung maupun tidak langsung yang tidak dapat peneliti sebutkan satu persatu.

Peneliti menyadari bahwa laporan ini masih jauh dari sempurna, meskipun demikian peneliti berharap semoga laporan ini bermanfaat bagi yang membacanya dan peneliti dengan senang hati menerima kritik dan saran yang membangun dari para pembaca.

Akhir kata peneliti berharap semoga hasil karya ini dapat berguna serta bermanfaat bagi perkembangan Teknologi dan Informasi pada khususnya, serta sebagai kajian bagi mahasiswa Universitas Amikom Yogyakarta lainnya dalam pengambilan Skripsi.

*Wassalamu'alaikum Warahmatullahi Wabarakatuh.*

Yogyakarta, 28 Februari 2023

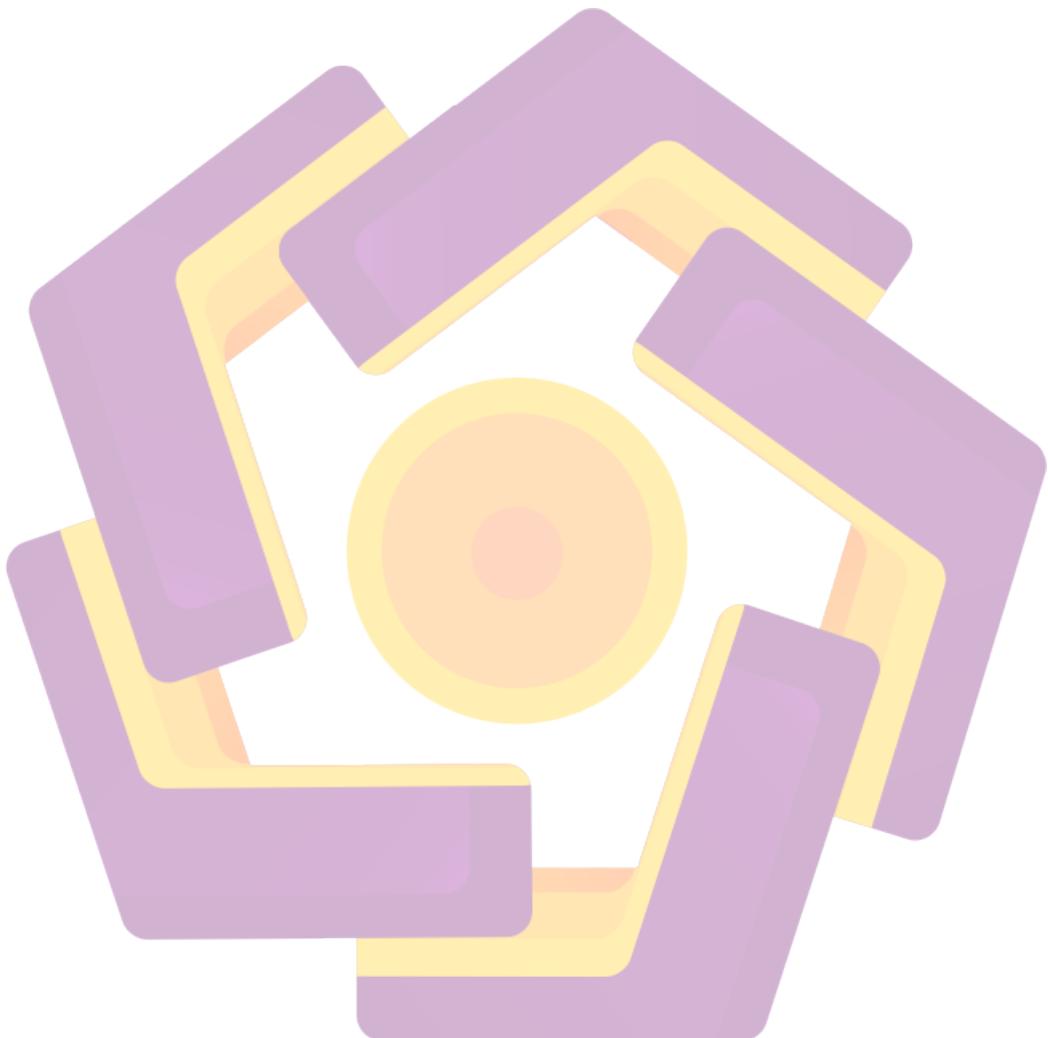
Penulis

## DAFTAR ISI

HALAMAN JUDUL .....	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN .....	iii
HALAMAN PERNYATAAN KEASLIAN SKRIPSI .....	iii
HALAMAN PERSEMBAHAN .....	v
KATA PENGANTAR .....	vi
DAFTAR ISI.....	viii
DAFTAR TABEL.....	xi
DAFTAR GAMBAR.....	xii
INTISARI .....	xiii
ABSTRACT.....	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	4
1.3 Batasan Masalah .....	4
1.4 Tujuan Penelitian .....	4
1.5 Manfaat Penelitian .....	4
1.6 Sistematika Penulisan .....	5
BAB II TINJAUAN PUSTAKA .....	6
2.1 Studi Literatur .....	6
2.2 Dasar Teori .....	9
2.2.1 SMS.....	9
2.2.2 Spam .....	9
2.2.3 Klasifikasi .....	10
2.2.4 Text Preprocessing.....	11
2.2.5 Term Frequency Inverse Document Frequency (TF-IDF).....	13
2.2.6 Multinomial Naïve Bayes .....	13
2.3 Metode Pengujian .....	13
BAB III METODE PENELITIAN .....	16

3.1	Alur Penelitian .....	16
3.2	Alat dan Bahan.....	17
3.2.1	Alat Penelitian.....	17
3.2.2	Bahan Penelitian .....	17
3.3	Pengumpulan Data.....	18
3.4	Teks Preprocessing .....	20
3.4.1	Case Folding .....	20
3.4.2	Tokenizing .....	20
3.4.3	Stopword .....	21
3.4.4	Stemming .....	21
3.5	Pembobotan TF-IDF .....	22
3.6	Proses Klasifikasi.....	24
3.6.1	Multinomial Naïve Bayes .....	24
3.6.2	Pengklasifikasian Lanjutan .....	25
3.6.2.1	Bahasa Campuran.....	25
3.6.2.2	Istilah Gaul ( <i>Slang</i> ) .....	26
3.6.2.3	Simbol – Simbol Tertentu .....	26
3.7	Pengujian Model .....	28
<b>BAB IV</b>	<b>HASIL DAN PEMBAHASAN .....</b>	<b>31</b>
4.1	Analisis Model .....	31
4.1.1	Load Dataset .....	31
4.1.2	Visualisasi Data .....	32
4.1.3	Data Cleaning.....	36
4.1.4	Konversi Model Machine Learning .....	37
4.1.5	Implementasi Metode Naïve Bayes dan Pembobotan TF-IDF .....	43
4.1.6	Pengujian Confusion Matrix .....	44
4.2	Implementasi Model .....	45
4.2.1	Load Dataset .....	45
4.2.2	Preprocessing .....	46
4.2.3	Predict Function .....	50
4.2.4	Program Testing.....	51

4.3 Validasi Model.....	54
BAB V PENUTUP .....	56
5.1 Kesimpulan .....	56
5.2 Saran .....	56
REFERENSI .....	57



## DAFTAR TABEL

Tabel 2.1. Keaslian Penelitian .....	7
Tabel 2.2. Contoh Tabel Confusion Matrix .....	14
Tabel 3.1. Confusion matrix .....	28
Tabel 4.1. Data Hasil Preprocessing .....	36
Tabel 4.2. Data Hasil Preprocessing Bahasa Indonesia .....	37
Tabel 4.3. Pembagian Data 20% .....	38
Tabel 4.4. Pembagian Data 20% dataset Bahasa Indonesia.....	38
Tabel 4.5. Pembagian Data 40% .....	39
Tabel 4.6. Pembagian Data 40% dataset Bahasa Indonesia.....	39
Tabel 4.7. Pembagian Data 60% .....	40
Tabel 4.8. Pembagian Data 60% dataset Bahasa Indonesia.....	40
Tabel 4.9. Pembagian Data 80% .....	41
Tabel 4.10. Pembagian Data 80% dataset Bahasa Indonesia.....	41
Tabel 4.11. Pembagian Data 99% .....	42
Tabel 4.12. Pembagian Data 99% dataset Bahasa Indonesia.....	42
Tabel 4.13 Hasil Perhitungan Confusion Matrix .....	44
Tabel 4.14. Pesan Teks dan Label.....	54
Tabel 4.15. Frekuensi Kata .....	54

## DAFTAR GAMBAR

Gambar 3.1. Alur Penelitian .....	16
Gambar 3.2. Dataset SMS Spam Collection.....	18
Gambar 3.3. Penyajian Data Dalam Tabel.....	19
Gambar 3.4. Alur TD-IDF .....	23
Gambar 4.1. Import Library .....	31
Gambar 4.2. Load Dataset.....	31
Gambar 4.3. Load Dataset (Bahasa Indonesia).....	32
Gambar 4.4. Informasi Umum Dataset .....	32
Gambar 4.5. Diagram Perbandingan Jumlah Spam dan Ham .....	33
Gambar 4.6. Diagram Perbandingan Bahasa Indonesia.....	33
Gambar 4.7. Visualisasi Kepadatan Pesan Spam dan Ham .....	34
Gambar 4.8. Visualisasi Kepadatan Pesan Spam dan Ham Dataset Indonesia.....	34
Gambar 4.9. Informasi Frasa atau Kata pada Dataset.....	35
Gambar 4.10. Script Koversi Model .....	37
Gambar 4.11. Script matriks MNB .....	43
Gambar 4.12. Script matriks MNB (Bahasa Indonesia).....	43
Gambar 4.13. Implementasi Load Dataset.....	45
Gambar 4.14. Proses Stopword.....	46
Gambar 4.15. Proses Stopword dengan Dataset Bahasa Indonesia .....	47
Gambar 4.16. Proses Case Folding dan Tokenizing .....	47
Gambar 4.17. Proses Case Folding dan Tokenizing Bahasa Indonesia .....	48
Gambar 4.18. Contoh Kata Spam dan Ham.....	48
Gambar 4.19. Kata Spam dan Ham Bahasa Indonesia .....	49
Gambar 4.20. Fungsi Prediksi.....	50
Gambar 4.21. Pengujian Spam.....	51
Gambar 4.22. Pengujian Ham Bahasa Indonesia .....	51
Gambar 4.23 Pengujian Ham .....	52
Gambar 4.24. Pengujian Ham Bahasa Indonesia .....	52
Gambar 4.25. Pengujian Lain .....	53

## INTISARI

SMS (*Short Message Service*) merupakan salah satu layanan komunikasi yang perkembangannya paling pesat. Pesatnya perkembangan layanan SMS tidak hanya berdampak positif untuk kehidupan namun juga menimbulkan masalah yang serius dikarenakan oknum yang tidak bertanggungjawab. Pesan spam merupakan masalah umum yang berada pada berbagai layanan pengolahan dan pengiriman pesan khususnya layanan SMS. Pesan spam terkadang berisi berbagai macam pesan berupa promosi, iklan, dan sejenisnya. Namun tak jarang pesan spam juga berisi pesan sejelis tautan berbahaya yang berisi *virus*, *malware*, penipuan, dan sejenisnya.

Tujuan peneliti dalam melakukan penelitian yaitu untuk mengembangkan sistem yang secara otomatis dapat mengklasifikasikan dan memfilter pesan SMS sebagai *spam* atau *non-spam (ham)*. Sistem yang diusulkan menggunakan Algoritma Multinomial Naïve Bayes untuk klasifikasi teks, yang merupakan metode dikembangkan dalam NLP (*Natural Language Processing*). Dataset yang digunakan untuk pelatihan (*training*) dan pengujian (*testing*) sistem adalah kumpulan pesan SMS berlabel *spam* atau *ham*.

Sistem filter ini dibuat dengan *Google Colab* dengan bahasa pemrograman Python. Hasil penelitian menunjukkan bahwa Algoritma Multinomial Naïve Bayes adalah metode yang efektif untuk penyaringan teks SMS dengan nilai *accuracy*, *precision*, *recall*, dan *F1-Score* yang tinggi. Sistem mencapai akurasi 87% dalam mengklasifikasikan pesan SMS sebagai *spam* atau *ham* menggunakan dataset Bahasa Inggris dan 77% menggunakan dataset Bahasa Indonesia. Hasil penelitian ini menunjukkan keefektifan penggunaan metode Multinomial Naive Bayes dalam pemfilteran teks SMS dan memberikan dasar untuk penelitian selanjutnya pada bidang ini.

**Kata kunci:** SMS, Spam, Filter, Multinomial Naïve Bayes

## ABSTRACT

*SMS (Short Message Service) is one of the fastest growing communication services. The rapid development of SMS services not only has a positive impact on life but also creates serious problems due to irresponsible persons. Spam messages are a common problem in various message processing and delivery services, especially SMS services. Spam messages sometimes contain various kinds of promotional messages, advertisements, and the like. But not infrequently spam messages also contain messages similar to malicious links that contain viruses, malware, fraud, and the like.*

*The aim of the researcher in conducting the research is to develop a system that can automatically classify and filter SMS messages as spam or non-spam (ham). The proposed system uses the Multinomial Naïve Bayes Algorithm for text classification, which is a method developed in NLP (Natural Language Processing). The dataset used for system training and testing is a collection of SMS messages labeled spam or ham.*

*This filter system is made with Google Colab with the Python programming language. The results showed that the Naïve Bayes Multinomial Algorithm is an effective method for filtering SMS text with high accuracy, precision, recall, and F1-Score values. The system achieved 87% accuracy in classifying SMS messages as spam or ham using the English dataset and 77% using the Indonesian dataset. The results of this study demonstrate the effectiveness of using the Multinomial Naïve Bayes method in filtering SMS text and provide a basis for further research in this field.*

**Keyword:** *SMS, Spam, Filter, Multinomial Naïve Bayes*