

**KLASIFIKASI SPAM PADA EMAIL MENGGUNAKAN
METODE SUPPORT VECTOR MACHINE DAN DETEKSI
ANOMALY**



OLEH :

**SITI AISYAH
09011181621024**

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2020**

KLASIFIKASI SPAM PADA EMAIL MENGGUNAKAN METODE SUPPORT VECTOR MACHINE DAN DETEKSI ANOMALY

SKRIPSI

**Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer**



OLEH :

**SITI AISYAH
09011181621024**

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2020**

LEMBAR PENGESAHAN
KLASIFIKASI SPAM PADA EMAIL MENGGUNAKAN
METODE SUPPORT VECTOR MACHINE DAN DETEKSI
ANOMALY

SKRIPSI

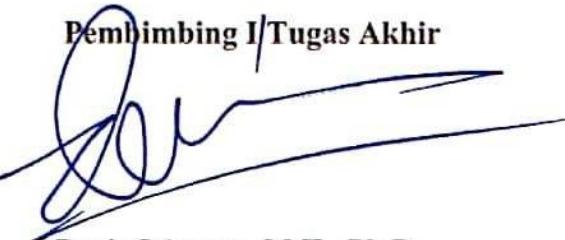
Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer

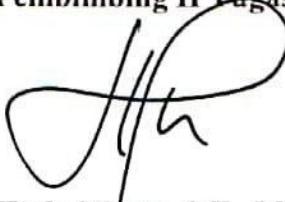
Oleh :

SITI AISYAH
09011181621024

Inderalaya, Juli 2020

Mengetahui
Pembimbing II Tugas Akhir

Pembimbing I/Tugas Akhir

Deris Stiawan, M.T., Ph.D.
NIP. 197806172006041002


Huda Ubaya, S.T., M.T.
NIP. 198106162012121003

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada :

Hari : Jum'at
Tanggal : 19 Juni 2020

Tim Penguji :

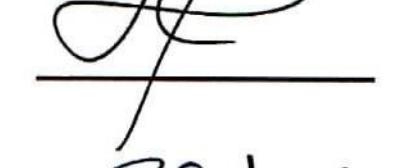
1. Ketua : Sri Desy Siswanti, S.T., M.T.



2. Sekretaris I : Deris Stiawan, M.T., Ph.D.



3. Sekretaris II : Huda Ubaya, S.T., M.T.



4. Anggota I : Ahmad Heryanto, S.Kom., M.T.



5. Anggota II : Sarmayanta Sembiring, S.SI., M.T.



Mengetahui,
Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001

LEMBAR PERNYATAAN

Yang bertanda tangan dibawah ini:

Nama : Siti Aisyah
NIM : 09011181621024
Judul : Klasifikasi Spam pada Email Menggunakan Metode *Support Vector Machine* dan Deteksi *Anomaly*

Hasil Pengecekan *Software iThenticate/Turmitin* : 6%

Menyatakan bahwa laporan tugas akhir saya merupakan hasil karya sendiri dan bukan hasil penjiplakan / plagiat dari penelitian orang lain. Apabila ditemukan unsur penjiplakan / plagiat dalam laporan tugas akhir ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan ketentuan yang berlaku.

Demikian pernyataan ini saya buat dalam keadaan sadar dan tidak dipaksakan.

Inderalaya, Juli 2020

Yang menyatakan,



Siti Aisyah

HALAMAN PERSEMBAHAN

“Sesungguhnya bersama kesulitan pasti ada kemudahan. Maka apabila engkau telah selesai (dari suatu urusan), tetaplah bekerja keras (untuk urusan yang lain).” (Q.S Al-Insyirah : 6-7)

“Dia mengajarkan manusia apa yang tidak diketahuinya.” (Q.S Al-Alaq : 5)

“Niscaya Allah akan mengangkat (derajat) orang-orang yang beriman diantaramu dan orang-orang yang diberi ilmu beberapa derajat.” (Q.S Al-Mujadilah : 11)

“Sesungguhnya Allah tidak akan mengubah keadaan suatu kaum sebelum mereka mengubah keadaan diri mereka sendiri.” (Q.S Ar-Rad : 11)

Tugas Akhir ini kupersembahkan kepada Ayah dan Ibunda tercinta yang setiap saat selalu mendoakan, memberi semangat serta dukungan. Semoga Allah mengampuni semua dosanya dan memberikan kesahatan serta selalu dalam lindungan-Nya. Adik-adik tersayang yang selalu memberi motivasi. Keluarga besar dan saudara-saudara yang selalu memberikan doa, semangat maupun dukungan. Sahabat seperjuangan dalam susah maupun senang. Serta Keluarga besar Sistem Komputer dan Civitas Akademika Universitas Sriwijaya

KATA PENGANTAR

Puji syukur atas kehadirat Allah SWT, atas segala karunia dan rahmat-Nya sehingga penulis dapat menyelesaikan penulisan Proposal Tugas Akhir ini dengan judul **“Klasifikasi Spam pada Email Menggunakan Metode Support Vector Machine dan Deteksi Anomaly”**.

Penulisan Proposal Tugas Akhir ini dilakukan untuk melengkapi salah satu syarat memperoleh gelar Sarjana Komputer di Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya. Adapun sebagai bahan penulisan, penulis mengambil berdasarkan hasil penelitian, observasi dan beberapa sumber literatur yang mendukung dalam penulisan proposal ini. Pada kesempatan ini juga, penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu baik dari segi moril ataupun materil serta memberikan kemudahan, dorongan, saran dan kritik selama dalam proses penulisan Proposal Tugas Akhir ini.

Oleh karena itu, pada kesempatan ini penulis mengucapkan rasa syukur kepada Allah SWT. dan mengucapkan terima kasih kepada yang terhormat :

1. Orang Tua serta keluarga penulis tercinta, yang telah memberikan doa dan restu serta dukungan yang sangat besar selama mengikuti dan melaksanakan perkuliahan di Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya hingga dapat menyelesaikan Proposal Tugas Akhir ini.
2. Bapak Jaidan Jauhari, S.Pd., M.T., selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
3. Dr. Ir. H. Sukemi, M.T. selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Bapak Ahmad Zarkasi, S.T., M.T., selaku Dosen Pembimbing Akademik di Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
5. Bapak Deris Stiawan, M.T., Ph.D., selaku Dosen Pembimbing Satu Tugas Akhir di Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.

6. Bapak Huda Ubaya, S.T., M.T., selaku Dosen Pembimbing Dua Tugas Akhir di Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
7. Mba Winda selaku admin Jurusan Sistem Komputer yang telah membantu mengurus seluruh berkas.
8. Seluruh dosen, staff, serta karyawan Fakultas Ilmu Komputer Universitas Sriwijaya.
9. Seluruh teman-teman seperjuangan angkatan 2016 Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
10. Almamater.

Penulis menyadari bahwa masih banyak kekurangan dalam penulisan Proposal Tugas Akhir ini. Karena sesungguhnya tak ada yang sempurna didunia ini. Untuk itu, segala saran dan kritik sangatlah penting bagi penulis. Akhir kata, semoga Tugas Akhir ini dapat bermanfaat dan berguna bagi khalayak.

Palembang, Juli 2020

Penulis

Spam Classification in Email Using the Support Vector Machine Method and Anomaly Detection

Siti Aisyah (09011181621024)

Department of Computer Systems, Faculty of Computer Science,
Sriwijaya University
Email: aaisyahichaa@gmail.com

Abstract

Email is a written communication tool commonly used in everyday life. The problem with e mail is spam. This study includes a machine learning approach, Support Vector Machine, which is used for spam classification on e-mail. Using two datasets, data that has not been vectorized and data that has been vectorized. For data that has not been vectorized, the first step taken is processing the text so that the data becomes numeric. After the data has been vectorized, the next step for these two data is to detect anomalies using Isolation Forest for removal of outliers in the data. The next step will be the data resampling using SMOTE so that the data becomes balanced. Then the last step is classification using the Support Vector Machine method by sharing data using K-Fold Cross Validation and normalizing using Min Max Scaler. In the research the best validation value for the Emails dataset obtained an average accuracy value of 96.80%, Recall 98.70%, Precision 95.12%, F1 Score 96.88%, FPR 5.11%, AUC 96.79%, Error 3.19%. The best validation values for the Spambase dataset obtained an average accuracy value of 94.08%, Recall 92.55%, Precision 95.31%, F1 Score 93.91%, FPR 4.42%, AUC 94.06%, Error 5 91%. Based on the results, it means that the method used in spam classification on e-mail is the right method.

Keywords: Email Spam, Support Vector Machine, Isolation Forest, SMOTE, Classification.

Klasifikasi Spam pada Email Menggunakan Metode Support Vector Machine dan Deteksi Anomaly

Siti Aisyah (09011181621024)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer,
Universitas Sriwijaya
Email: aaisyahichaa@gmail.com

Abstrak

Email merupakan sebuah alat komunikasi tertulis yang biasa digunakan dalam kehidupan sehari-hari. Permasalahan yang ada pada email adalah spam. Penelitian ini memuat metode pendekatan machine learning yaitu Support Vector Machine yang digunakan untuk klasifikasi spam pada email. Menggunakan dua dataset yaitu data yang belum di vektorisasi dan data yang telah di vektorisasi. Untuk data yang belum di vektorisasi, langkah pertama yang dilakukan adalah pengolahan teks agar data menjadi angka. Setelah data selesai di vektorisasi langkah selanjutnya untuk kedua data ini adalah deteksi anomali menggunakan Isolation Forest untuk penghapusan outlier yang ada pada data. Tahap selanjutnya data akan di resampling menggunakan SMOTE agar data menjadi seimbang. Kemudian tahap terakhir adalah klasifikasi menggunakan metode Support Vector Machine dengan pembagian data menggunakan K-Fold Cross Validation dan normalisasi menggunakan Min Max Scaler. Pada penelitian nilai validasi terbaik untuk dataset Emails didapat rata-rata nilai Akurasi 96,80%, Recall 98,70%, Presisi 95,12%, F1 Score 96,88%, FPR 5,11%, AUC 96,79%, Error 3,19% . Nilai validasi terbaik untuk dataset Spambase didapat rata-rata nilai Akurasi 94,08%, Recall 92,55%, Presisi 95,31%, F1 Score 93,91%, FPR 4,42%, AUC 94,06%, Error 5,91%. Berdasarkan hasil yang ada, berarti metode yang digunakan dalam klasifikasi spam pada email merupakan metode yang tepat.

Kata Kunci: Spam Email, Support Vector Machine, Isolation Forest, SMOTE, Klasifikasi.

DAFTAR ISI

	Halaman
Halaman Judul.....	i
Halaman Pengesahan	ii
Halaman Persetujuan.....	iii
Halaman Pernyataan.....	iv
Halaman Persembahan	v
Kata Pengantar	vi
Abstraction	viii
Abstrak	ix
Daftar Isi.....	x
Daftar Gambar.....	xiii
Daftar Tabel	xiv
Daftar Lampiran	xvi

BAB I PENDAHULUAN

1.1. Latar Belakang	1
1.2. Rumusan Masalah	3
1.2.1. Perumusan Masalah	3
1.2.2. Batasan Masalah.....	4
1.3. Tujuan dan Manfaat	4
1.3.1. Tujuan	4
1.3.2. Manfaat	4
1.4. Metodologi Penelitian	5
1.4.1. Metode Literatur.....	5
1.4.2. Metode Konsultasi	5
1.4.3. Metode Pengumpulan Data.....	5
1.4.4. Metode Observasi.....	5
1.4.5. Metode Perancangan <i>Software</i>	5
1.4.6. Metode Analisa dan Kesimpulan	6
1.5. Sistematika Penulisan	6

BAB II TINJAUAN PUSTAKA

2.1. <i>Machine Learning</i>	8
2.2. Spam.....	9
2.3. <i>Email</i>	9
2.4. <i>Text Mining</i>	9
2.5. Anomali.....	10
2.6. <i>Isolation Forest</i>	12
2.6.1. Algoritma <i>Isolation Forest</i>	12
2.6.2. Parameter <i>Isolation Forest</i>	13
2.7. <i>Synthetic Minority Over-sampling Technique</i> (SMOTE)	13
2.7.1. Algoritma SMOTE.....	14
2.7.2. Karakteristik SMOTE	14
2.8. <i>Support Vector Machine</i> (SVM)	15
2.8.1. Algoritma SVM.....	16
2.8.2. Karakteristik SVM	16
2.8.3. Parameter SVM.....	17
2.9. Performa SVM	19
2.10. Validasi	21
2.10.1. Karakteristik K-Fold Cross Validation.....	22
2.11. Dataset.....	22

BAB III METODOLOGI

3.1. Pendahuluan	24
3.2. Kerangka Kerja	24
3.3. Persiapan Data.....	27
3.4. Perancangan Sistem	28
3.5. <i>Pre-processing</i>	30
3.5.1. <i>Text Mining</i>	31
3.5.2. Deteksi Anomali	32
3.5.3. <i>Resampling</i>	33
3.5.4. Pembagian Data	34

3.5.5. Normalisasi	35
3.6. <i>Processing</i>	37
3.6.1. Klasifikasi	37
3.6.2. Validasi	40
 BAB IV HASIL DAN ANALISA	
4.1. Pendahuluan	41
4.2. <i>Pre-processing</i>	41
4.2.1. Dataset.....	41
4.2.2. <i>Text Mining</i>	44
4.2.3. Deteksi Anomali	47
4.2.4. <i>Resampling</i>	51
4.2.5. Pembagian Data	53
4.2.6. Normalisasi	54
4.3. <i>Processing</i>	57
4.3.1. Klasifikasi	57
4.3.2. Validasi	57
4.3.2.1. Hasil Klasifikasi <i>Dataset Spambase</i> pada Skenario 1.....	57
4.3.2.2. Hasil Klasifikasi <i>Dataset Emails</i> pada Skenario 1.....	59
4.3.2.3. Hasil Klasifikasi <i>Dataset Spambase</i> pada Skenario 2.....	62
4.3.2.4. Hasil Klasifikasi <i>Dataset Emails</i> pada Skenario 2.....	64
4.3.2.5. Hasil Klasifikasi <i>Dataset Spambase</i> pada Skenario 3.....	66
4.3.2.6. Hasil Klasifikasi <i>Dataset Emails</i> pada Skenario 3.....	69
4.3.2.7. Hasil Klasifikasi <i>Dataset Spambase</i> pada Skenario 4.....	71
4.3.2.8. Hasil Klasifikasi <i>Dataset Emails</i> pada Skenario 4.....	73
 BAB V KESIMPULAN.....	
5.1. Kesimpulan	76
5.2. Saran.....	77
DAFTAR PUSTAKA	78
LAMPIRAN	81

DAFTAR GAMBAR

Gambar 2.1 Diagram <i>Outlier</i>	11
Gambar 2.2 Skema representasi dari algoritma SMOTE.....	14
Gambar 2.3 Menentukan <i>hyperplane</i> terbaik dari dua <i>class</i>	15
Gambar 2.4 Ilustrasi K-Fold Cross Validation	22
Gambar 3.1 Kerangka Kerja	26
Gambar 3.2 Pembagian Kelas	28
Gambar 3.3 Kerangka kerja dalam perancangan sistem.....	30
Gambar 3.4 Flowchart Vektorisasi Data Text Menjadi Angka.....	31
Gambar 3.5 Flowchart Deteksi <i>Anomaly</i>	32
Gambar 3.6 Arsitektur <i>over-sampling</i>	33
Gambar 3.7 Flowchart <i>Resampling</i> SMOTE	34
Gambar 3.8 Flowchart Pembagian Data	35
Gambar 3.9 Flowchart Normalisasi Data.....	36
Gambar 3.10 Flowchart Algoritma <i>Support Vector Machine</i>	38
Gambar 4.1 Bentuk <i>Dataset</i> Asli Spambase	42
Gambar 4.2 Bentuk <i>Dataset</i> Asli Emails	43
Gambar 4.3 Isi <i>Dataset</i> Emails Baris Pertama	44
Gambar 4.4 Hasil Tokenisasi	44
Gambar 4.5 Hasil <i>Stop Word Removal</i>	45
Gambar 4.6 Hasil Data Bersih <i>Text Mining</i>	46
Gambar 4.7 Hasil Data Emails yang Telah di Vektorisasi	47
Gambar 4.8 Hasil <i>Dataset</i> Spambase yang Terdapat Anomali	48
Gambar 4.9 Hasil <i>Dataset</i> Emails yang Terdapat Anomali	48
Gambar 4.10 <i>Dataset</i> Spambase yang Telah di <i>Resampling</i>	52
Gambar 4.11 <i>Dataset</i> Emails yang Telah di <i>Resampling</i>	53
Gambar 4.12 Potongan <i>Dataset</i> Spambase yang Belum di Normalisasi.....	55
Gambar 4.13 Potongan <i>Dataset</i> Spambase yang Telah di Normalisasi	55
Gambar 4.14 Potongan <i>Dataset</i> Emails yang Belum di Normalisasi.....	56
Gambar 4.15 Potongan <i>Dataset</i> Emails yang Telah di Normalisasi	56

DAFTAR TABEL

Tabel 2.1 Confusion Matrix.....	19
Tabel 2.2 Pembagian kelas dan pemberian label pada <i>dataset</i>	23
Tabel 4.1 Pembagian Kelas dan Jumlah <i>Dataset Spambase</i>	42
Tabel 4.2 Pembagian Kelas dan Jumlah <i>Dataset Emails</i>	43
Tabel 4.3 Jumlah <i>Inliers</i> dan <i>Outliers</i> pada <i>Dataset Spambase</i> dan <i>Emails</i>	48
Tabel 4.4 Visualisasi Anomali	49
Tabel 4.5 Jumlah <i>Dataset</i> Setelah Penghapusan <i>Outlier</i>	51
Tabel 4.6 Jumlah <i>Dataset Spambase</i> Setelah Penghapusan <i>Outlier</i>	51
Tabel 4.7 Jumlah <i>Dataset Emails</i> Setelah Penghapusan <i>Outlier</i>	51
Tabel 4.8 Hasil <i>Resampling</i>	52
Tabel 4.9 Akurasi Tertinggi <i>Dataset Spambase</i>	54
Tabel 4.10 Akurasi Tertinggi <i>Dataset Emails</i>	54
Tabel 4.11 Hasil evaluasi data <i>imbalance</i> kernel linear dalam %	57
Tabel 4.12 Nilai <i>confusion matrix</i> iterasi ke 6 kernel linear	58
Tabel 4.13 Hasil evaluasi data <i>imbalance</i> kernel rbf dalam %	58
Tabel 4.14 Nilai <i>confusion matrix</i> iterasi ke 4 kernel rbf	59
Tabel 4.15 Hasil evaluasi data <i>imbalance</i> kernel sigmoid dalam %	59
Tabel 4.16 Nilai <i>confusion matrix</i> iterasi ke 6 kernel sigmoid	59
Tabel 4.17 Hasil evaluasi data <i>imbalance</i> kernel linear dalam %	60
Tabel 4.18 Nilai <i>confusion matrix</i> iterasi ke 2 kernel linear	60
Tabel 4.19 Nilai <i>confusion matrix</i> iterasi ke 6 kernel linear	60
Tabel 4.20 Hasil evaluasi data <i>imbalance</i> kernel rbf dalam %	61
Tabel 4.21 Nilai <i>confusion matrix</i> iterasi ke 3 kernel rbf	61
Tabel 4.22 Hasil evaluasi data <i>imbalance</i> kernel sigmoid dalam %	61
Tabel 4.23 Nilai <i>confusion matrix</i> iterasi ke 3 kernel sigmoid	62
Tabel 4.24 Hasil evaluasi data <i>balance</i> kernel linear dalam %	62
Tabel 4.25 Nilai <i>confusion matrix</i> iterasi ke 2 kernel linear	63
Tabel 4.26 Hasil evaluasi data <i>balance</i> kernel rbf dalam %	63
Tabel 4.27 Nilai <i>confusion matrix</i> iterasi ke 5 kernel rbf	63
Tabel 4.28 Hasil evaluasi data <i>balance</i> kernel sigmoid dalam %	63

Tabel 4.29 Nilai <i>confusion matrix</i> iterasi ke 5 kernel sigmoid.....	64
Tabel 4.30 Hasil evaluasi data <i>balance</i> kernel linear dalam %	64
Tabel 4.31 Nilai <i>confusion matrix</i> iterasi ke 2 kernel linear	65
Tabel 4.32 Hasil evaluasi data <i>balance</i> kernel rbf dalam %	65
Tabel 4.33 Nilai <i>confusion matrix</i> iterasi ke 5 kernel rbf	65
Tabel 4.34 Hasil evaluasi data <i>balance</i> kernel sigmoid dalam %	66
Tabel 4.35 Nilai <i>confusion matrix</i> iterasi ke 3 kernel sigmoid	66
Tabel 4.36 Hasil evaluasi data <i>imbalance</i> kernel linear anomali dalam %	67
Tabel 4.37 Nilai <i>confusion matrix</i> iterasi ke 3 kernel linear	67
Tabel 4.38 Hasil evaluasi data <i>imbalance</i> kernel rbf anomali dalam %	67
Tabel 4.39 Nilai <i>confusion matrix</i> iterasi ke 3 kernel rbf.....	68
Tabel 4.40 Hasil evaluasi data <i>imbalance</i> kernel sigmoid anomali dalam %	68
Tabel 4.41 Nilai <i>confusion matrix</i> iterasi ke 6 kernel sigmoid.....	68
Tabel 4.42 Hasil evaluasi data <i>imbalance</i> kernel linear anomali dalam %	69
Tabel 4.43 Nilai <i>confusion matrix</i> iterasi ke 6 kernel linear	69
Tabel 4.44 Hasil evaluasi data <i>imbalance</i> kernel rbf anomali dalam %	69
Tabel 4.45 Nilai <i>confusion matrix</i> iterasi ke 4 kernel rbf	70
Tabel 4.46 Hasil evaluasi data <i>imbalance</i> kernel sigmoid anomali dalam %	70
Tabel 4.47 Nilai <i>confusion matrix</i> iterasi ke 4 kernel sigmoid	71
Tabel 4.48 Hasil evaluasi data <i>balance</i> kernel linear anomali dalam %	71
Tabel 4.49 Nilai <i>confusion matrix</i> iterasi ke 5 kernel linear	71
Tabel 4.50 Hasil evaluasi data <i>balance</i> kernel rbf anomali dalam %	72
Tabel 4.51 Nilai <i>confusion matrix</i> iterasi ke 2 kernel rbf	72
Tabel 4.52 Nilai <i>confusion matrix</i> iterasi ke 4 kernel rbf	72
Tabel 4.53 Hasil evaluasi data <i>balance</i> kernel sigmoid anomali dalam %	72
Tabel 4.54 Nilai <i>confusion matrix</i> iterasi ke 4 kernel sigmoid	73
Tabel 4.55 Hasil evaluasi data <i>balance</i> kernel linear anomali dalam %	73
Tabel 4.56 Nilai <i>confusion matrix</i> iterasi ke 3 kernel linear	74
Tabel 4.57 Hasil evaluasi data <i>balance</i> kernel rbf anomali dalam %	74
Tabel 4.58 Nilai <i>confusion matrix</i> iterasi ke 6 kernel rbf.....	74
Tabel 4.59 Hasil evaluasi data <i>balance</i> kernel sigmoid anomali dalam %	75
Tabel 4.60 Nilai <i>confusion matrix</i> iterasi ke 3 kernel sigmoid	75

DAFTAR LAMPIRAN

Lampiran 1. *Code* untuk Vektorisasi

Lampiran 2. *Code* untuk Deteksi Anomali

Lampiran 3. *Code* untuk *Resampling*

Lampiran 4. *Code* untuk Pembagian Data

Lampiran 5. *Code* untuk Normalisasi

Lampiran 6. *Code* untuk Klasifikasi

Lampiran 7. Berkas Tugas Akhir

BAB I

PENDAHULUAN

1.1. Latar Belakang

Spam merupakan aktivitas kejahatan yang cukup mudah seperti terlihat pada definisinya yang merupakan sebuah tindakan yang dilakukan berulang-ulang. Dengan artian, pengirim informasi yang dikatakan melakukan *spam* (*spammer*) bisa terjadi secara semgaja dengan mengirimkan *spam* untuk berbuat kejahatan atau pengirim *spam* yang tidak disengaja sehingga tidak mengetahui bahwa diri nya telah melakukan *spam* [1]. Seiring dengan pertumbuhan internet dan *Email*, telah terjadi pertumbuhan *spam* dalam beberapa tahun terakhir. *Spam* dapat berasal dari setiap lokasi di seluruh dunia dimana akses internet tersedia. Jumlah pesan *spam* terus meningkat pesat [2]. Pada saat ini, lebih dari 85% dari total *Email* yang masuk adalah *spam* [3].

Dalam rangka untuk melawan masalah yang berkembang, penentuan teknik terbaik untuk melawan *spam* dengan berbagai alat yang tersedia harus dianalisa oleh organisasi [4]. Dalam *dataset* biasanya terdapat sebuah data yang mempunyai karakteristik berbeda dengan kebanyakan data dan merupakan suatu kejadian yang jarang muncul pada suatu kasus pada sebuah sumber data [5]. Item yang tidak terduga atau tidak normal pada *dataset* ini bisa menurunkan hasil performansi dalam suatu penelitian, oleh sebab itu deteksi anomali adalah proses yang bisa dilakukan untuk mengidentifikasi item tak terduga atau yang berbeda dari normal pada *dataset*.

Deteksi anomali merupakan sebuah proses untuk menemukan pola dalam sebuah *dataset* yang perilakunya tidak normal seperti yang diharapkan. Perilaku tak terduga juga disebut sebagai anomali atau *outlier*. Anomali tidak selalu bisa dikategorikan sebagai serangan tetapi bisa menjadi perilaku mengejutkan yang sebelumnya tidak diketahui. Deteksi anomali memberikan informasi yang sangat signifikan dan penting dalam berbagai aplikasi [6]. Terdapat beberapa algoritma deteksi anomali tanpa pengawasan yang terdiri dari empat kelompok utama

diantaranya *Nearest-neighbor based*, *Clustering based*, *Statistical Subspace based* dan *Classifier based/Other*.

Metode SMOTE (*Synthetic Minority Over-sampling Technique*) merupakan metode yang populer untuk menangani data yang tidak seimbang yang merupakan masalah inti dalam deteksi anomali. Teknik ini mensintesis sampel baru dari kelas minoritas untuk menyeimbangkan *dataset* dengan cara sampling ulang sampel kelas minoritas. SMOTE berhasil meningkatkan performa klasifikasi dengan hasil terbaik didapatkan dengan metode Naive Bayes sebesar 90,7% [7].

KNN dengan kombinasi teknik partisi data *K-Fold Cross Validation* dalam mengklasifikasikan *spam* pada *Email* menghasilkan akurasi sebesar 92,28%, metode naive bayes menghasilkan akurasi sebesar 84,30%. Banyak metode yang dilakukan dalam mengklasifikasikan *spam* pada *Email* tetapi yang menggunakan kombinasi teknik partisi data *K-Fold Cross Validation* sedikit sehingga akurasi yang didapatkan tidak terlalu tinggi. SVM akan memberikan hasil ketepatan klasifikasi yang lebih baik jika dikombinasikan dengan teknik partisi data *K-Fold Cross Validation* [8].

SVM adalah model klasifikasi yang berfungsi untuk mesin inferensi dari sistem pakar konstruksi sebuah *hyperplane* keputusan untuk memisahkan dua kelas *spam* dan sah [9]. pengklasifikasi SVM adalah *classifier* menonjol untuk penyaringan *spam* atau klasifikasi [10]. SVM sudah dikenal sebagai algoritma pembelajaran terbaik untuk klasifikasi pada data biner [11]. Keuntungan dari SVM adalah bahwa akurasinya tidak menurunkan bahkan ketika banyak fitur yang hadir. Oleh karena itu, pendekatan tersebut telah diadopsi untuk penyaringan *email spam* [3].

Vanitha, Devaraj, dan Venkatesulu (2015) telah melakukan penelitian klasifikasi data gen *microarray* dengan memperoleh tingkat akurasi tertinggi yaitu 97,77%. Pada penelitian tersebut metode yang digunakan adalah *Support Vector Machine* (SVM) [12]. Itulah yang melatar belakangi penulis mengambil judul “Klasifikasi *Spam* pada *Email* Menggunakan Metode *Support Vector Machine* dan Deteksi *Anomaly*”, dikarenakan metode SVM dianggap memperoleh tingkat akurasi yang baik dalam mengklasifikasikan sebuah data.

1.2. Rumusan Masalah

Dataset yang digunakan berbasas pada *spam*. Data pertama menggunakan *dataset* Spambase. Dalam *dataset* Spambase, data sudah berupa angka dan siap diolah. Pada data ini total kasus *Email* adalah 4601. 1813 dari contoh *Email* ini ditandai sebagai *spam* (39,4%) dan sisanya adalah non-*spam*. *Dataset* Spambase terdiri dari 57 fitur dan 1 atribut klasifikasi, yang merupakan label kelas yang menunjukkan status setiap contoh *Email* apakah itu adalah *spam* (1) atau non-*spam* (0). Sebagian besar fitur (1-54) menunjukkan karakter tertentu atau kata-kata yang berulang kali terjadi di *Email* atau tidak. Fitur 55-57 menyajikan pengukuran untuk panjang huruf kapital berturut-turut[13].

Dataset kedua yang digunakan adalah *dataset Emails*. Pada data ini total kasus *Email* adalah 5728. 1368 dari contoh *Email* ini ditandai sebagai *spam* dan 4360 adalah non-*spam*. Label kelas *spam* ditandai dengan angka (1) dan non-*spam* ditandai dengan angka (0). Data *Emails* ini berbentuk teks sehingga apabila dilakukan klasifikasi harus melewati tahap *text mining*.

Adapun ruang lingkup dan perumusan masalah dalam penulisan Proposal Tugas Akhir ini adalah sebagai berikut:

1.2.1. Perumusan Masalah

Rumusan masalah dalam penulisan Proposal Tugas Akhir ini sebagai berikut:

1. Bagaimana cara mengubah data teks menjadi angka menggunakan *count vecorizer*?
2. Bagaimana cara deteksi anomali pada sebuah *dataset* yang digunakan untuk mengklasifikasi *spam* pada *Email* menggunakan metode *Isolation Forest*?
3. Bagaimana cara mengklasifikasikan *spam* pada *Email* menggunakan metode *Support Vector Machine*?
4. Apa saja *output* yang dihasilkan dari klasifikasi *spam* pada *Email* menggunakan metode *Support Vector Machine*?
5. Apa *software* atau *tools* yang digunakan untuk mengklasifikasikan *spam* pada *Email* menggunakan metode *Support Vector Machine*?

1.2.2. Batasan Masalah

Batasan masalah dalam penulisan Proposal Tugas Akhir ini adalah sebagai berikut:

1. Metode klasifikasi yang digunakan adalah *Support Vector Machine* dari toolbox python.
2. Klasifikasi *spam* yang diteliti hanya pada *Email*.
3. Data yang digunakan adalah *dataset Spambase* dan *dataset Emails*.

1.3. Tujuan dan Manfaat

Adapun tujuan dan manfaat dari penulisan Proposal Tugas Akhir ini adalah sebagai berikut :

1.3.1. Tujuan

1. Mempelajari konsep *text mining* yang digunakan untuk mengubah data *text* menjadi angka.
2. Mempelajari konsep algoritma *Isolation Forest* yang digunakan untuk mendeteksi anomali.
3. Mengimplementasikan metode *Support Vector Machine* untuk klasifikasi *spam* dan *non-spam*.
4. Melakukan pengujian dan validasi pada model yang dipilih.
5. Menganalisa *performance* dari metode yang digunakan dalam mendeteksi dan klasifikasi *spam* menggunakan metode *Isolation Forest* dan *Support Vector Machine*.

1.3.2. Manfaat

- a. Dapat menerapkan algoritma *text mining* untuk mengolah data *text* menjadi angka.
- b. Dapat menerapkan algoritma *Isolation Forest* untuk deteksi anomali.
- c. Dapat menerapkan metode *Support Vector Machine* dalam mengklasifikasikan *spam* pada *Email*.
- d. Membantu mempermudah penelitian mengenai *spam* pada *Email*.

1.4. Metodologi Penelitian

Dalam penulisan tugas akhir ini Metodologi yang digunakan akan melewati beberapa tahapan sebagai berikut :

1.4.1. Metode Literatur

Pada literatur, penulisan dilakukan dengan cara mencari sumber informasi yang dibutuhkan sebagai media pembelajaran yang diantaranya adalah berasal dari internet seperti artikel yang terkait, jurnal ilmiah, buku yang merupakan peran penting dalam penulisan skripsi ini.

1.4.2. Metode Konsultasi

Pada tahap metode konsultasi, dilakukan tanya jawab kepada orang-orang baik secara online maupun tatap muka. Yang dianggap memiliki pengetahuan dan wawasan yang cukup terhadap permasalahan yang akan dibahas dalam pembuatan Proposal Tugas Akhir.

1.4.3. Metode Pengumpulan Data

Dalam metode ini, pengumpulan data dilakukan dengan mencari sebuah *dataset* yang terdapat di *website* seperti UCI, Kaggle dan *website dataset* lainnya sehingga *dataset* yang dipakai dalam penelitian ini adalah Spambase *dataset* dan *Emails* dataset.

1.4.4. Metode Observasi

Pada metode ini, observasi yang dilakukan adalah dengan mengamati, mencatat, dan menganalisa terhadap data yang diperoleh.

1.4.5. Metode Perancangan *Software*

Pada tahap ini perancangan serta pembuatan sistem (*software*) akan dilakukan agar bisa melakukan penelitian untuk klasifikasi *spam* pada *Email* dengan bahasa pemrograman Python di Jupyter dan di spyder.

1.4.6. Metode Analisa dan Kesimpulan

Hasil dari penelitian yang telah di uji akan dilakukan dianalisa yang bertujuan agar dapat mengetahui letak kekurangan pada perancangan dan apa faktor yang menyebakkannya sehingga bisa digunakan untuk mengembangkan penelitian selanjutnya dan dibuat kesimpulan dari hasil penelitian.

1.5. Sistematika Penulisan

Sistematika penulisan pada Proposal Tugas Akhir ini adalah sebagai berikut:

BAB I PENDAHULUAN

Pada bab I akan berisikan latar belakang masalah, tujuan dan manfaat serta metodologi penelitian dan sistematika penulisan.

BAB II TINJAUAN PUSTAKA

Pada Bab II akan berisi dasar teori *Machine Learning*, *Spam*, *Email*, *Text Mining*, Anomali, *Isolation Forest*, Smote, *Support Vector Machine* dan *K-Fold Cross Validation*.

BAB III METODOLOGI

Pada Bab III berisi uraian mengenai kerangka kerja, perancangan sistem dan penjelasan *flowchart* pada tiap tahap yang dilakukan dipenelitian ini.

BAB IV HASIL DAN PEMBAHASAN

Pada Bab IV membahas proses membahas mengenai proses, hasil dan analisa dari penerapan metode *Isolation Forest* dan *Support Vector Machine* pada data *spam Email* dengan melalui tahap pelatihan dan pengujian.

BAB V KESIMPULAN DAN SARAN

Pada bab V berisi kesimpulan dari bab-bab yang sudah dicantumkan mengenai hasil dari cara mengubah data *text* menjadi angka, pengimplementasian metode *Support Vector Machine* dalam

pengklasifikasian *spam* pada *Email* dan pendekripsi anomali menggunakan algoritma *Isolation Forest*. Pada bab ini juga akan berisi saran yang diharapkan dapat digunakan untuk penelitian selanjutnya.

DAFTAR PUSTAKA

LAMPIRAN

DAFTAR PUSTAKA

- [1] E. N. Putra, “Pengiriman E-mail Spam sebagai Kejahatan Cyber di Indonesia,” vol. 7, no. 2, pp. 169–182, 2016.
- [2] V. Christina, S. Karpagavalli, and G. Suganya, “Email Spam Filtering using Supervised Machine Learning Techniques,” vol. 02, no. 09, pp. 3126–3129, 2010.
- [3] I. Santos, C. Laorden, X. Ugarte-pedrero, and B. Sanz, “Anomaly Based Spam Filtering,” no. january, pp. 124–133, 2011.
- [4] S. K. Tuteja and N. Bogiri, “Email Spam Filtering using BPNN Classification Algorithm,” pp. 915–919, 2016.
- [5] N. Cholis, “Pencarian Anomali Berdasarkan Kerapatan Data Menggunakan Algoritma Shared Nearest Neighbor Density Anomaly Detection Based on Data Density Using Shared Nearest Neighbors Density Algorithm,” vol. 1, 2006.
- [6] S. Agrawal and J. Agrawal, “Survey on Anomaly Detection using Data Mining Techniques,” *Procedia - Procedia Comput. Sci.*, vol. 60, pp. 708–713, 2015.
- [7] R. Siringoringo, “Klasifikasi Data Tidak Seimbang Menggunakan Algoritma Smote dan K-Nearest Neighbor,” vol. 3, no. 1, pp. 44–49, 2018.
- [8] S. Novelia, D. Pratiwi, B. Sutijo, and S. Ulama, “Klasifikasi Email Spam dengan Menggunakan Metode Support Vector Machine dan k- Nearest Neighbor,” vol. 5, no. 2, pp. 344–349, 2016.
- [9] G. Sanghani and K. Koticha, “Incremental personalized E-mail spam filter using novel TFDCR feature selection with dynamic feature update,” *Expert Syst. Appl.*, vol. 115, pp. 287–299, 2019.
- [10] J. Ara, “A Survey of Existing E-Mail Spam Filtering Methods Considering Machine Learning Techniques,” vol. 1, no. 2, 2018.
- [11] T. Shon, “A hybrid machine learning approach to network anomaly detection,” vol. 177, pp. 3799–3821, 2007.
- [12] W. Agustina, M. T. Furqon, and B. Rahayudi, “Implementasi Metode

- Support Vector Machine (SVM) Untuk Klasifikasi Rumah Layak Huni (Studi Kasus : Desa Kidal Kecamatan Tumpang Kabupaten Malang),” vol. 2, no. 10, pp. 3366–3372, 2018.
- [13] L. M. El Bakrawy, “Hybrid Particle Swarm Optimization and Pegasos Algorithm for Spam Email Detection,” pp. 11–22, 2019.
 - [14] R. Saravanan and P. Sujatha, “A State of Art Techniques on Machine Learning Algorithms: A Perspective of Supervised Learning Approaches in Data Classification,” *2018 Second Int. Conf. Intell. Comput. Control Syst.*, no. Iciccs, pp. 945–949, 2018.
 - [15] J. R. Méndez, T. R. Cotos-yañez, and D. Ruano-ordás, “A new semantic-based feature selection method for spam filtering,” *Appl. Soft Comput. J.*, vol. 76, pp. 89–104, 2019.
 - [16] C. Varol and H. M. T. Abdulhadi, “Comparision of String Matching Algorithms on Spam Email Detection,” *2018 Int. Congr. Big Data, Deep Learn. Fight. Cyber Terror.*, pp. 6–11, 2018.
 - [17] B. Sarrafzadeh, A. H. Awadallah, C. H. Lin, C. Lee, M. Shokouhi, and S. T. Dumais, “Characterizing and Predicting Email Deferral Behavior,” pp. 627–635, 2019.
 - [18] A. Kajian, K. Puspittek, K. P. Serpong, and K. Kunci, “Media Komunikasi Efektif pada Layanan Jasa Informasi : Studi Kasus di Kawasan Pusat Penelitian Ilmu Pengetahuan dan Teknologi (Puspittek),” vol. 26, no. 2, pp. 109–117, 2018.
 - [19] N. F. Shah and P. Kumar, “A Comparative Analysis of Various Spam Classification,” pp. 265–271, 2018.
 - [20] P. Soepomo, “Penerepan Text Mining Pada Sistem Klasifikasi Email Spam Menggunakan Naive Bayes,” *Jurnal Sarj. Tek. Inform.*, vol. 2, pp. 73–83, 2014.
 - [21] M. Luo, K. Wang, Z. Cai, A. Liu, and Y. Li, “Using Imbalanced Triangle Synthetic Data for Machine Learning Anomaly Detection,” vol. 58, no. 1, pp. 15–26, 2019.
 - [22] D. Xu, Y. Wang, Y. Meng, and Z. Zhang, “An improved data anomaly detection method based on isolation forest,” *Proc. - 2017 10th Int. Symp.*

- Comput. Intell. Des. Isc. 2017*, vol. 2, pp. 287–291, 2018.
- [23] G. A. Sandag, R. J. Sambur, and J. Bororing, “Klasifikasi SMS Spam Menggunakan Algoritma Support Vector Machine (SVM),” pp. 291–295, 2018.
 - [24] S. O. Olatunji, “Improved email spam detection model based on support vector machines,” *Neural Comput. Appl.*, vol. 31, pp. 691–699, 2017.
 - [25] J. M. Sma, “Analisa Perbandingan Tingkat Performansi Metode Support Vector Machine dan Naive Bayes Classifier untuk Klasifikasi Jalur Minat SMA,” no. March, 2018.
 - [26] S. Nurhayati, E. T. Luthfi, and U. Y. Papua, “Prediksi Mahasiswa Drop Out Menggunakan Metode Support Vector Machine,” vol. x, no. x, pp. 82–93, 1978.
 - [27] M. Rangga, A. Nasution, and M. Hayaty, “Perbandingan Akurasi dan Waktu Proses Algoritma K-NN dan SVM dalam Analisis Sentimen Twitter,” vol. 6, no. 2, pp. 226–235, 2019.
 - [28] K. Kotipalli, N. Carolina, and S. Suthaharan, “Modeling of Class Imbalance using an Empirical Approach with Spambase Dataset and Random Forest Classification,” pp. 75–80, 2014.
 - [29] H. Adil, A. Algafore, and S. H. Hashem, “Spam Filtering based on Naïve Bayesian with Information Gain and Ant Colony System,” vol. 57, no. 1, pp. 719–727, 2016.