



Perbandingan Algoritma K-Nearest Neighbour (KNN) dan Naive Bayes pada Intrusion Detection System (IDS)

Aditya Dwi Afifaturahman¹, Firmansyah Maulana²

^{1,2} Informatika, Fakultas Teknik, Universitas Siliwangi, Tasikmalaya, Indonesia

¹afifaturahman@gmail.com, ²firmansyah@unsil.ac.id

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 22-03-2021

Revisi Akhir: 30-03-2021

Diterbitkan Online: 31-03-2021

KATA KUNCI

Classification,
IDS,
KNN,
Machine Learning,
Naive Bayes

KORESPONDENSI

Telepon: 082321960404

E-mail: afifaturahman@gmail.com

ABSTRACT

Machine learning techniques are widely used to develop Intrusion Detection Systems (IDS) to detect and classify cyber attacks at the network level and the host level in a timely and automated manner. However, many challenges arise as malicious attacks are constantly changing and occurring in very large volumes requiring a scalable solution. Therefore, this study conducted a comparison of the K-Nearest Neighbor (KNN) and Naive Bayes algorithms. The dataset used in this study is the Ddos features-IDS 2017 dataset published in 2019. This research analyzes the comparison of methods generated from the classification process based on metric accuracy, specificity and sensitivity parameters. The classification process using the K-Nearest Neighbor (KNN) and Naive Bayes algorithms, it can be concluded that the results of the three tests with a percentage split of 60%, 70% and 80% show that the K-Nearest Neighbor (KNN) algorithm gets a higher value than Naive Bayes except the error rate because the error rate indicates that the data failed to be classified properly. Testing on a percentage split of 60% KNN parameter accuracy gets a value of 99.53%, specificity 94.05%, sensitivity 75.20%, testing on a percentage split 70% KNN parameter accuracy gets a value of 99.69%, specificity 94.59%, sensitivity 78.40% and testing on percentage split 80%, KNN parameter accuracy parameter got a value of 99.70%, specificity 94.44%, sensitivity 75.85%.

1. PENDAHULUAN

Keamanan jaringan menggambarkan aspek berguna dalam bidang teknologi data dikala ini. Semakin banyak pengguna serta terus menjadi luas jangkauan komunikasi, hingga terus menjadi banyak pula kesempatan serangan. Selaku cerminan, pada survei yang dicoba oleh Lab Kaspersky 2017, 33% organisasi hadapi serbuan DDoS pada tahun 2017, dibanding dengan 17% di tahun 2016. Dari organisasi yang terserang serbuan DDoS, 20% merupakan bisnis yang sangat kecil, 33% merupakan UKM, serta 41% merupakan industri [1].

Teknik *machine learning* banyak digunakan untuk mengembangkan *Intrusion Detection System* (IDS) untuk mendeteksi dan mengklasifikasikan serangan dunia maya di tingkat jaringan dan tingkat host secara tepat waktu dan cara otomatis. Namun, banyak tantangan muncul karena Halaman 17-25

serangan jahat terus berubah dan terjadi dalam volume yang sangat besar yang membutuhkan solusi yang dapat diskalakan[2]

Intrusion Detection System (IDS) biasanya menggunakan dua jenis teknik yakni *signature based intrusion detection system* dan *anomaly based intrusion detection system*[3]. Deteksi Serangan Denial of Service Menggunakan *Artificial Immune System* berpendapat bahwa mekanisme kinerja dari *Intrusion Detection System* (IDS) dengan menggunakan teknik *signature based* dapat mendeteksi serangan yang telah diketahui dengan efektif, tetapi belum mampu memprediksi serangan lama dengan pola yang baru. Sementara itu, *anomaly based intrusion system* bekerja dengan mengacu pada pola serangan yang ada dalam lalu lintas, tetapi bermasalah apabila lalu lintas tersebut berperilaku tidak normal sehingga tidak bisa

mengirimkan peringatan adanya serangan kepada sistem [4]. Suatu lalu lintas data dikatakan anomali, apabila terjadi peristiwa yang mencurigakan dari perspektif keamanan informasi [5].

Penelitian tentang klasifikasi *anomaly network traffic* dilakukan perbandingan metode yang dihasilkan dari proses klasifikasi bersumber pada nilai akurasi confusion matrix, precision, recall, serta f1 score. Naive Bayes, SVM Linear, SVM Polynomial serta SVM Sigmoid menciptakan persentase akurasi berturut-turut sebesar 85,055%, 99, 995%, 99, 999%, serta 99, 995%. Persentase akurasi paling tinggi diperoleh SVM Polynomial, sebaliknya Naive Bayes menciptakan persentase akurasi terendah [1].

Algoritma Naive Bayes bisa menciptakan akurasi yang optimal dengan informasi latih yang sedikit. Sebaliknya tata cara K- Nearest Neighbor diseleksi sebab tata cara tersebut tangguh terhadap informasi noise. Hasil yang didapatkan menampilkan tata cara Naive Bayes mempunyai kinerja yang lebih baik dengan tingkatan akurasi 70%, sebaliknya tata cara K- Nearest Neighbor mempunyai tingkatan akurasi yang lumayan rendah ialah 40% [6]

Algoritma *K-Nearest Neighbour* mempunyai akurasi yang tinggi dibandingkan dengan algoritma *Support Vector Machine* (SVM) dan *Neural Network* (NN) untuk kategori *accuracy*, *precision* dan *recall*. Hasil tersebut menunjukkan bahwa algoritma *K-Nearest Neighbour* dapat memecah data dalam keadaan *higher-feature space* sehingga dua kelas yang berbeda dapat dikelompokkan dengan baik [7] [8].

Berdasarkan dari paparan permasalahan maka akan berfokus pada klasifikasi dataset *anomaly network traffic* pada *Intrusion Detection System* (IDS) dengan membandingkan algoritma *K-Nearest Neighbour* (KNN) dan Naïve Bayes dengan parameter *metric accuracy*, *sensitivity* dan *specificity* sehingga akan dihasilkan nilai g-means yang pada penelitian sebelumnya belum dijabarkan pada parameter *metric* tersebut[7].

2. ULASAN PENELITIAN TERKAIT

Algoritma Naive Bayes bisa menciptakan akurasi yang optimal dengan informasi latih yang sedikit. Sebaliknya tata cara K- Nearest Neighbor diseleksi sebab tata cara tersebut tangguh terhadap informasi noise. Hasil yang didapatkan menampilkan tata cara Naive Bayes mempunyai kinerja yang lebih baik dengan tingkatan akurasi 70%, sebaliknya tata cara K- Nearest Neighbor mempunyai tingkatan akurasi yang lumayan rendah ialah 40% [6]

Algoritma *K-Nearest Neighbour* mempunyai akurasi yang tinggi dibandingkan dengan algoritma *Support Vector Machine* (SVM) dan *Neural Network* (NN) untuk kategori *accuracy*, *precision* dan *recall*. Hasil tersebut menunjukkan bahwa algoritma *K-Nearest Neighbour* dapat memecah data dalam keadaan *higher-feature space* sehingga dua kelas yang berbeda dapat dikelompokkan dengan baik[7].

Berdasarkan pemaparan ulasan terkait maka akan berfokus pada klasifikasi dataset *anomaly network traffic* pada *Intrusion Detection System* (IDS) dengan membandingkan algoritma *K-Nearest Neighbour* (KNN)

dan Naïve Bayes dengan parameter *metric accuracy*, *sensitivity* dan *specificity* sehingga akan dihasilkan nilai g-means yang pada penelitian sebelumnya belum dijabarkan pada parameter *metric* tersebut[7].

3. METODOLOGI

Tahapan yang dimulai dari proses pengumpulan data, analisis permasalahan dan pencarian solusi, implementasi solusi sampai pada proses penarikan kesimpulan yang dijelaskan pada gambar 1.



Gambar 1. Tahapan proses

Data merupakan penunjang yang diperoleh melalui studi literatur dan observasi dengan pengamatan langsung. Studi literatur berisi uraian tentang teori, temuan dan bahan penelitian lainnya yang diperoleh dari jurnal nasional maupun jurnal internasional yang berupa survey paper dan technical paper. Observasi data dilakukan dengan mencari data yang tepat untuk melakukan penelitian.

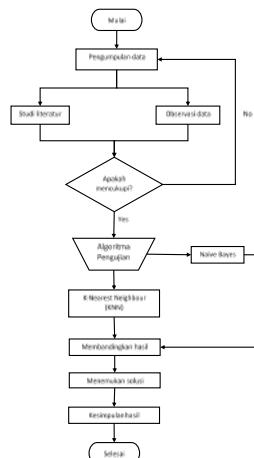
3.1 Analisis Permasalahan dan Pencarian Solusi

Tahapan analisis permasalahan dan oencarian solusi merupakan tahap pengembangan yang dilakukan setelah pengumpulan data. Masalah yang ditemukan terdapat pada proses literatur dan observasi data, kemudian diamatai dan mencari solusi berdasarkan perkembangan ilmu pengetahuan dan teknologi yang ada. Masalah yang ditemukan adalah deteksi anomaly network traffic. Solusi yang dipilih adalah menerapkan algoritma *K-Nearest Neighbour* (KNN) dengan menggunakan tools WEKA

3.2 Implementasi Solusi

Langkah yang dilakukan pada tahap implementasi solusi adalah mencari dataset yang diperoleh setelah melakukan observasi data. Kemudian data yang telah diperoleh diubah dari format “csv” menjadi “arff”. Dataset yang ada dilakukan pemangkasan karena data yang didapat terlalu banyak dan data yang didapat sebanyak 9998 data.

Dataset yang telah didapatkan diolah menggunakan tools WEKA. Data diproses dengan Explorer dan Classify Rule, kemudian proses selanjutnya adalah menerapkan algoritma K-Nearest Neighbour (KNN) sebagai classifier. Hasil dari proses pengujian berupa item summary, detailed accuracy by class dan confusion matrix. Berikut adalah gambaran implementasi solusi dari penelitian ini.



Gambar 2. Alur Implementasi Solusi

Gambar 2 merupakan proses menemukan solusi dimana pada tahapan tersebut meliputi data collection, data preprocessing, klasifikasi menggunakan WEKA, hasil akurasi berupa precision dan recall.

Tabel summary yang menggambarkan hasil dari proses pengujian dataset secara garis besar yang dijelaskan pada tabel 1.

Tabel 1. Overall Summary

No.	Kategori
1.	Correctly Classified Instances
2.	Incorrectly Classified Instances
3.	Kappa statistic
4.	Mean absolute error
5.	Root mean squared error
6.	Relative absolute error
7.	Root relative squared error
8.	Total Number of Instances

Tabel tingkat keakuratan pemrosesan data berdasarkan kelas yang digunakan pada tabel 2.

Tabel 2. Detailed Accuracy By Class

No.	Kategori
1.	TP Rate
2.	Fp Rate
3.	Precision
4.	Recall
5.	F-Measure
6.	MCC
7.	ROC Area
8.	PRC Area

Tabel parameter pengujian merupakan proses data perbandingan berdasarkan parameter yang digunakan pada tabel 3.

Tabel 3. Parameter Pengujian

No.	Parameter
1.	Accuracy
2.	Precision
3.	Recall
4.	Specificity
5.	Sensitivity
6.	Error Rate

Tabel merupakan contoh bentuk Confusion Matrix dari hasil pemrosesan data.

Tabel 4. Confusion Matrix

		< - - Classified as
a	b	a = yes
9	0	a = yes
1	4	b = no

3.3 Penarikan Kesimpulan

Penarikan kesimpulan menjadi tahapan terakhir dari proses dimana hasil yang diperoleh adalah nilai keakuratan dari hasil uji coba penerapan algoritma K-Nearest Neighbour (KNN) dan algoritma Naive Bayes terhadap data yang memuat anomaly network traffic pada dataset Instrusion Detection System (IDS).

4. HASIL DAN PEMBAHASAN

4.1 Pengumpulan Data

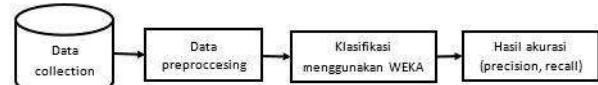
Observasi data dilakukan dengan melakukan pencarian dataset yang berkaitan dengan Intrusion Detection System (IDS). Dataset diperoleh dari kaggle.com/dataset dengan dataset yang bernama alldays_ddos.

4.2 Analisis Permasalahan dan Pencarian Solusi

Objek yang diteliti yakni deteksi anomali network traffic pada Instrusion Detection System (IDS) dan masalah yang ditemukan adalah mendeteksi lalu lintas jaringan yang bersifat anomali pada Intrusiom Detection System (IDS). Penyelesaian yang diseleksi untuk menanggulangi kasus tersebut merupakan menerapkan pengujian tingkatan akurasi dari algoritma K-Nearst Neighbour (KNN) untuk mendeteksi lalu lintas jaringan yang bersifat anomali pada Intrusiom Detection System (IDS). Tools yang digunakan sebagai penunjang penelitian ini adalah WEKA 3.9, Microsoft Excel 2016, dan sublime text.

4.3 Pemrosesan Data

Pemrosesan data ini merupakan tahap optimasi klasifikasi terhadap dataset yang telah diperoleh dari kaggle.com/dataset dengan dataset yang bernama alldays_ddos. Kemudian dirumuskan di Microsoft Exel dengan format CSV.



Gambar 3. Alur Proses Menemukan Solusi

Gambar 3 merupakan alur menemukan solusi yang terdiri dari data collection, data preproccesing, klasifikasi WEKA dan hasil akurasi. Data collection didapatkan dari kaggle.com/dataset yang selanjutnya diproses menggunakan microsoft excel untuk merubah format CSV ke ARFF agar bisa diproses oleh WEKA dan selanjutnya akan diproses sehingga menghasilkan hasil akurasinya.

Gambar 4. dataset Alldays_ddos

Sebelum di proses dengan tools WEKA format CSV harus di konversi terlebih dahulu ke dalam format ARFF agar dapat di proses oleh tools WEKA.

	Allsys_dossey	X
1	Red Packet Length Std; Average Packet Size; Flow Duration; Flow IAT Std; Label	
2	0.6-0.5;0.4-0.6;BENIGN	
3	0.6-0.9;0.1-0.6;BENIGN	
4	0.6-0.9;0.1-0.8;BENIGN	
5	0.6-0.9;0.1-0.6;BENIGN	
6	0.6-0.9;0.1-0.8;BENIGN	
7	0.6-0.9;0.1-0.8;BENIGN	
8	0.6-0.9;0.1-0.8;BENIGN	
9	11.951.159.572.235.2009;163.636.263.636.260;986;811.519.495.952.227.800;BENIGN	
10	8.845.806.123.385.006;28.615.334.615.384.300;879;8.2.090.550.710.393.620;BENIGN	
11	7.823.472.347.387.340;213.333.333.331.300;1116;0.21.824.566.366.338;BENIGN	
12	8.248.638.795.573.726;512.6;524.0;836.782.196.538.887;BENIGN	
13	0.6-0.9;0.5-0.8;BENIGN	
14	7.854.456.960-0.350-41.466.666.666.666.666;1119;6.19.623.065.391.204.486;BENIGN	
15	8.173.089.469.770;3.301.598.481.138.460;18178;6.32.225.396.276.798.406;BENIGN	
16	8.173.089.469.770;3.301.598.481.138.460;18178;6.32.225.396.276.798.406;BENIGN	
17	8.451.482.483.755.289.27.274.627.976.321.600;876;8.2.091.983.334.740.136;BENIGN	
18	8.025.168.741.735.598.254.254.445.454.545.400;1866;8.2.081.277.988.335.589;BENIGN	
19	11.051.159.572.235.2009;8.163.636.263.636.260;816;8.11.960.625.567.134.180;BENIGN	

Gambar 5. dataset format CSV

Gambar 5 merupakan dataset yang masih berformat CSV yang akan dikonversikan ke dalam format ARFF yang dibuka menggunakan notepad atau bisa menggunakan text editor yang lainnya seperti notepad++, sublime text dan lain-lain.

Gambar 6. dataset dengan format ARFF

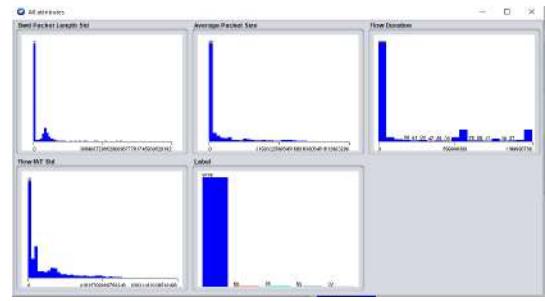
Gambar 6 menunjukkan proses konversi CSV ke dalam format ARFF yang dibuka dengan text editor sublime text. Merubah data CSV kedalam format ARFF mengharuskan mengubah model atau bentuk konten data. Line 1 yang berisi @relation Allday_ddos merupakan judul atau topik dari dataset. Atribut-atribut yang sebelumnya berbentuk tabel, diubah menjadi parafrase script seperti pada line 3 sampai line 7.

Proses optimasi klasifikasi tersebut dilakukan dengan menggunakan tools WEKA untuk melakukan preprocessor terhadap dataset dan buka allday_ddos yang telah dikonversikan kedalam format ARFF. Berikut merupakan data dari Allday_ddos berdasarkan label BENIGN, SSH-Patator, FTP Patator, Dos-slowris dan Dos-Slowhttptest.

Name: Label		Type: Nominal	
Missing: 0 (0%)		Distinct: 5	Unique: 0 (0%)
No.	Label	Count	Weight
1	BENIGN	9780	9780.0
2	SSH-Patator	55	55.0
3	FTP-Patator	75	75.0
4	DoS-slowloris	55	55.0
5	DoS-Slowhttptest	32	32.0

Gambar 7. Perhitungan Atribut pada Label Network Traffic

Gambar 7 merupakan perhitungan jumlah atribut kategori berdasarkan label network traffic yang isinya adalah BENIGN, SSH-Patator, FTP-Patator, Dos-slowloris, Dos-slowhttptest. Perhitungan tersebut menunjukkan bahwa dari 9998 data yang ada pada dataset sebanyak 9780 data benign, 56 data SSH-Patator, 75 data FTP-Patator , 55 data Ddos-slowloris, 32 data Ddos-slowhttptest.



Gambar 8. All Attribute Dataset

Gambar 8 merupakan seluruh atribut yang ada pada dataset Allday_ddos atribut tersebut meliputi Bwd packet length Std, Average Packet Size, Flow duration, Flow IAT Std dan Label.

Pengujian dilakukan sebanyak 3 kali dengan pengujian pertama dilakukan pada percentage split 60%, pengujian kedua dilakukan terhadap percentage split 70% dan pengujian ketiga dilakukan terhadap percentage split 80%. Proses split bertujuan untuk menghindari proses overfitting karena jumlah data yang banyak dari dataset dan maksud dari hasil split ialah untuk membagi antara data latih dan data uji.

4.1 Pengujian 1

Data yang sebelumnya telah dilakukan preprocess kemudian di split menjadi 60%. Proses tersebut merupakan pembagian data latih dan uji dimana 60% merupakan data latih dan 40% data uji. Hasil pengujian ditunjukkan pada gambar 4.14.

Classifier output									
==== Summary ====									
Correctly Classified Instances 3952 98.8247 %									
Incorrectly Classified Instances 47 1.1753 %									
Kappa statistic 0.7107									
Mean absolute error 0.0048									
Root mean squared error 0.0062									
Relative absolute error 26.1892 %									
Root relative squared error 72.77 %									
Total Number of Instances 3999									
==== Detailed Accuracy By Class ====									
TP Rate FP Rate Precision Recall F-Measure MCC ROC Area FRC Area Class									
0.985 0.282 0.393 0.985 0.974 0.786 0.842 0.394 BENIGN									
0.368 0.001 0.383 0.265 0.452 0.162 0.644 0.248 SSH-Patator									
0.639 0.003 0.637 0.639 0.639 0.615 0.615 0.332 FTP-Patator									
0.409 0.001 0.409 0.409 0.409 0.398 0.398 0.111 Dos-slowloris									
0.857 0.001 0.857 0.857 0.857 0.817 0.817 0.336 Dos-Slowhttptest									
Weighted Avg.: 0.988 0.288 0.387 0.668 0.988 0.786 0.842 0.394									
==== Confusion Matrix ====									
a b c d e <-- classified as									
3892 5 10 1 2 1 a = BENIGN									
10 7 2 0 0 b = SSH-Patator									
12 0 23 1 0 c = FTP-Patator									
2 0 0 18 0 d = Dos-slowloris									
2 0 0 0 12 e = Dos-Slowhttptest									

Gambar 9. Classifier Output KNN Pengujian 1

Gambar 9 merupakan hasil pengujian data dari algoritma KNN yang telah di split menjadi 60%. *Classifier output* terdapat 3 bentuk yaitu *Summary*, *Detailed Accuracy By Class* dan *Confusion Matrix*. Penelitian ini hanya menggunakan 2 bentuk *classifier output* yaitu *Detailed Accuracy By Class* dan *Confusion Matrix*.

==== Confusion Matrix ====					
a	b	c	d	e	<-- classified as
3892	5	10	1	2	a = BENIGN
10	7	2	0	0	b = SSH-Patator
12	0	23	1	0	c = FTP-Patator
2	0	0	18	0	d = Dos-slowloris
2	0	0	0	12	e = Dos-Slowhttptest

Gambar 10. Confusion Matrix KNN Pengujian 1

Gambar 12 merupakan *confusion matrix* dimana setiap label *network traffic* diklasifikasikan menggunakan variabel a,b,c,d dan e. Label BENIGN terdapat 3.892 data TP (*True Positive*), 26 data FP (*False Positive*), 63 data TN (*True Negative*) dan 18 data FN (*False negative*) yang terdeksi. Label SSH-Patator terdapat 7 data TP, 5 data FP, 3975 data TN, 12 FN yang terdeksi Label FTP-Patator terdapat 23 data TP, 12 data FP, 3951 data TN dan 13 data FN yang terdeksi. Label Dos-slowloris terdapat 18 data TP, 2 data FP, 3977 data TN dan 2 data FN yang terdeksi. Label Dos-Slowhttptest terdapat 12 data TP, 2 data FP, 3983 data TN dan 2 data FN yang terdeksi.

TP	TN	FP	FN		TP	TN	FP	FN	
3892	18	26	12		1048	73	818	0	
10	26	5	10		17	85	0	1	a = BENIGN
12	3975	23	12		4	5	0	1	b = SSH-Patator
2	3951	13	0		0	2	0	1	c = FTP-Patator
18	3977	2	12		0	0	11	0	d = Dos-slowloris
2	3983	0	2		0	0	1	6	e = Dos-Slowhttptest

Gambar 11. Parameter KNN Pengujian 1

Gambar 11 merupakan parameter klasifikasi setiap label pada K-Nearest Neighbour dimana perhitungan tersebut diperoleh dari rumus *specificity*, *precision*, *recall*, *accuracy*, *sensitivity* dan *error rate* setelah mengetahui nilai dari TP, FP, TN, FN pada *confusion matrix*.

TP	TN	FP	FN		TP	TN	FP	FN	
3892	18	26	12		1048	73	818	0	
10	26	5	10		17	85	0	1	a = BENIGN
12	3975	23	12		4	5	0	1	b = SSH-Patator
2	3951	13	0		0	2	0	1	c = FTP-Patator
18	3977	2	12		0	0	11	0	d = Dos-slowloris
2	3983	0	2		0	0	1	6	e = Dos-Slowhttptest

Gambar 12. Average pengujian 1 KNN

Gambar 12 merupakan nilai rata-rata *Accuracy*, *Precision*, *Recall*, *specificity*, *sensitivity* dan *Error Rate* dari Algoritma KNN dimana nilai rata-rata tersebut diperoleh dari penjumlahan nilai setiap label dibagi jumlah label itu sendiri.

Classifier output									
==== Summary ====									
Correctly Classified Instances 3970 93.7 %									
Incorrectly Classified Instances 80 6.3 %									
Kappa statistic 0.0441									
Mean absolute error 0.1149									
Root mean squared error 0.1246									
Relative absolute error 1055.6889 %									
Root relative squared error 455.8145 %									
Total Number of Instances 4000									
==== Detailed Accuracy By Class ====									
TP Rate FP Rate Precision Recall F-Measure MCC ROC Area FRC Area Class									
0.935 0.023 0.935 0.935 0.935 0.935 0.935 0.935 BENIGN									
0.344 0.013 0.344 0.200 0.344 0.200 0.344 0.200 SSH-Patator									
0.313 0.037 0.303 0.603 0.303 0.603 0.303 0.603 FTP-Patator									
1.000 0.415 0.013 1.000 0.026 0.026 0.026 0.026 Dos-slowloris									
0.857 0.000 1.000 0.857 0.923 0.923 0.971 0.959 Dos-Slowhttptest									
Weighted Avg.: 0.937 0.025 0.937 0.937 0.937 0.937 0.937									
==== Confusion Matrix ====									
a b c d e <-- classified as									
1048 17 73 818 0 a = BENIGN									
1 4 5 0 b = SSH-Patator									
0 8 5 2 c = FTP-Patator									
0 0 0 11 d = Dos-slowloris									
0 0 0 1 e = Dos-Slowhttptest									

Gambar 13. Classifier Output Naive Bayes Pengujian 1

TP	TN	FP	FN		TP	TN	FP	FN	
2911	5755	4	17		1048	73	818	0	
5755	2371	3869	0		17	85	0	1	a = BENIGN
4	13	0	17		4	5	0	1	b = SSH-Patator
17	3869	0	1		0	2	0	1	c = FTP-Patator
3869	0	1	17		0	0	11	0	d = Dos-slowloris
0	1	17	17		0	0	1	6	e = Dos-Slowhttptest

Gambar 14. Confusion Matrix NB Pengujian 1

TP	TN	FP	FN		TP	TN	FP	FN	
2911	5755	4	17		1048	73	818	0	
5755	2371	3869	0		17	85	0	1	a = BENIGN
4	13	0	17		4	5	0	1	b = SSH-Patator
17	3869	0	1		0	2	0	1	c = FTP-Patator
3869	0	1	17		0	0	11	0	d = Dos-slowloris
0	1	17	17		0	0	1	6	e = Dos-Slowhttptest

Gambar 15. Parameter NB Pengujian 1

Gambar 15 merupakan parameter klasifikasi setiap label pada Naive Bayes dimana perhitungan tersebut diperoleh dari rumus *specificity*, *precision*, *recall*, *accuracy*, *sensitivity* dan *error rate* setelah mengetahui nilai dari TP, FP, TN, FN pada *confusion matrix*.

Accuracy Benign	0.550000025
Accuracy SSH-patator	0.989952455
Accuracy TFP-patator	0.973068511
Accuracy Dos-Slowloris	0.851849123
Accuracy Dos-Slowhttptest	0.89245011
Avg. Accuracy	0.850544411
Specificity Benign	0.970570181
Specificity SSH-Patator	0.973068511
Specificity TFP-Patator	0.980248055
Specificity Dos-Slowloris	0.856477937
Specificity Dos-Slowhttptest	0.89245011
Avg. Specificity	0.890933912
Precision Benign	0.319514012
Precision SSH-Patator	0.053001745
Precision TFP-Patator	0.135333331
Precision Dos-Slowloris	0.213351273
Precision Dos-Slowhttptest	0.232076923
Avg. Precision	0.123993345
Recall Benign	0.550000124
Recall SSH-Patator	0.151704047
Recall TFP-Patator	0.151515533
Recall Dos-Slowloris	1
Recall Dos-Slowhttptest	0.857142857
Avg. Recall	0.112191382
Error Rate Benign	0.448300376
Error Rate SSH-Patator	0.030017547
Error Rate TFP-Patator	0.055311015
Error Rate Dos-Slowloris	0.151518187
Error Rate Dos-Slowhttptest	0.000750939
Avg. Error Rate	0.179624031

Gambar 16. Average Pengujian 1 NB

Gambar 16 merupakan nilai rata-rata *Accuracy*, *Precision*, *Recall*, *specificity*, *sesnsitivity* dan *Error Rate* dari Algortima NB dimana nilai rata-rata tersebut diperoleh dari penjumlahan nilai setiap label dibagi jumlah label itu sendiri.

4.2 Pengujian 2

Data yang sebelumnya telah dilakukan preprocess kemudian di split menjadi 70%. Proses tersebut merupakan pembagian data latih dan uji dimana 70% merupakan data latih dan 30% data uji. Hasil pengujian ditunjukkan pada gambar 19.

Classifier output									
--- Summary ---									
Correctly Classified Instances 2964 85.033 %									
Incorrectly Classified Instances 35 1.1871 %									
Mean absolute error 0.0049									
Root mean squared error 0.0468									
Relative absolute error 23.079 %									
Root relative squared error 31.9629 %									
Total Number of Instances 3599									
--- Detailed Accuracy By Class ---									
TP Rate FP Rate Precision Recall F-Measure ROC Area ROC Area Class									
0.995 0.001 0.995 0.995 0.994 0.748 0.883 0.994 BENIGN									
0.412 0.001 0.700 0.412 0.519 0.555 0.657 0.530 SSH-Patator									
0.667 0.004 0.975 0.467 0.615 0.614 0.851 0.426 TFP-Patator									
0.932 0.000 0.998 0.932 0.932 0.927 0.972 0.879 Dos-Slowloris									
0.809 0.000 0.809 0.909 0.909 0.909 0.969 0.827 Dos-Slowhttptest									
Weighted Avg. 0.995 0.193 0.995 0.995 0.995 0.995 0.853 0.893									
--- Confusion Matrix ---									
a b c d e -- classified as									
2916 3 10 1 1 i a = BENIGN									
8 7 2 0 0 j b = SSH-Patator									
8 0 16 0 0 k c = TFP-Patator									
1 0 0 15 0 l d = DoS-slowloris									
1 0 0 0 10 l e = DoS-Slowhttptest									

Gambar 17. Classifier Output KNN Pengujian 2

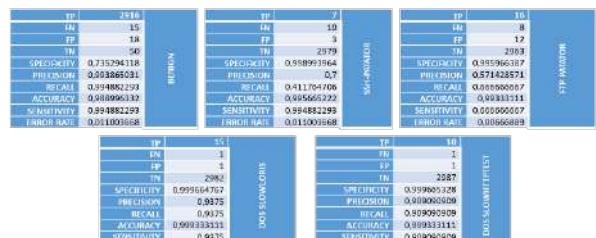
Gambar 17 merupakan hasil pengujian data yang telah di split menjadi 70%. *Classifier output* terdapat 3 bentuk yaitu *Summary*, *Detailed Accuracy By Class* dan *Confusion Matrix*. Pengujian kedua ini hanya menggunakan 2 bentuk *classifier output* yaitu *Detailed Accuracy By Class* dan *Confusion Matrix*.

==== Confusion Matrix ====					
a	b	c	d	e	-- classified as
2916	3	10	1	1	i a = BENIGN
8	7	2	0	0	j b = SSH-Patator
8	0	16	0	0	k c = TFP-Patator
1	0	0	15	0	l d = DoS-slowloris
1	0	0	0	10	l e = DoS-Slowhttptest

Gambar 18. Confusion Matrix KNN Pengujian 2

Gambar 18 merupakan *confusion matrix* dimana setiap label *network traffic* diklasifikasikan menggunakan variabel a,b,c,d dan e. Label BENIGN terdapat 2916 data

TP, 18 data FP, 50 data TN dan 15 data FN yang terdeksi. Label SSH-Patator terdapat 7 data TP, 10 data FP, 2979 data TN, 10 FN yang terdeksi Label FTP-Patator terdapat 16 data TP, 12 data FP, 2963 data TN dan 8 data FN yang terdeksi. Label Dos-slowloris terdapat 15 data TP), 1 data FP, 2982 data TN dan 1 data FN yang terdeksi. Label Dos-Slowhttptest terdapat 10 data TP, 1 data FP, 2987 data TN dan 1 data FN yang terdeksi.


--

Gambar 19. Parameter KNN Pengujian 2

Gambar 19 merupakan parameter klasifikasi setiap label pada KNN dimana perhitungan tersebut diperoleh dari rumus *specificity*, *precision*, *recall*, *accuracy*, *sensitivity* dan *error rate* setelah mengetahui nilai dari TP, FP, TN, FN pada *confusion matrix*.



Gambar 20. Average Pengujian 2 KNN

Gambar 20 merupakan nilai rata-rata dari Algortima KNN dimana nilai rata-rata tersebut diperoleh dari penjumlahan nilai setiap label dibagi jumlah label itu sendiri.

Classifier output									
--- Summary ---									
Correctly Classified Instances 54.3543 %									
Incorrectly Classified Instances 45.4456 %									
Mean absolute error 0.0414									
Root mean squared error 0.277									
Relative absolute error 12.05 %									
Root relative squared error 12.05 %									
Total Number of Instances 2599									
--- Detailed Accuracy By Class ---									
a b c d e -- classified as									
0.995 0.010 0.162 0.222 0.253 i BENIGN									
0.487 0.032 0.040 0.167 0.065 i FTP-Patator									
1.000 0.000 0.000 0.000 0.000 i Dos-Slowloris									
0.995 0.000 0.000 0.000 0.000 i Dos-Slowhttptest									
Weighted Avg. 0.995 0.000 0.000 0.000 0.000									
--- Confusion Matrix ---									
a b c d e -- classified as									
1.001 21 94.124 1 1 i a = BENIGN									
1 4 0 16 0 j b = SSH-Patator									
0 0 0 16 1 k c = TFP-Patator									
0 0 0 1 10 l d = DoS-slowloris									
0 0 0 1 10 l e = DoS-Slowhttptest									

Gambar 21. Classifier ouput NB Pengujian 2

Gambar 21 merupakan hasil pengujian data dengan algoritma Naive Bayes yang telah di split menjadi 70%. *Classifier output* terdapat 3 bentuk yaitu *Summary*, *Detailed Accuracy By Class* dan *Confusion Matrix*. Penelitian ini hanya menggunakan 2 bentuk classifier output yaitu *Detailed Accuracy By Class* dan *Confusion Matrix*.

a	b	c	d	e	-- classified as
1601	21	94	1214	1	a = BENIGN
1	6	2	8	0	b = SSH-Patator
5	10	4	5	0	c = FTP-Patator
0	0	0	16	0	d = DoS-slowloris
0	0	0	1	10	e = DoS-Slowhttptest

Gambar 22. Confusion Matrix NB Pengujian 2

Gambar 22 merupakan *confusion matrix* dimana setiap label *network traffic* diklasifikasikan menggunakan variabel a,b,c,d dan e. Label *BENIGN* terdapat 1601 data TP, 6 data FP, 62 data TN dan 1330 data FN yang terdeksi. Label *SSH-Patator* terdapat 6 data TP, 31 data FP, 2951 data TN, 11 FN yang terdeksi Label *FTP-Patator* terdapat 4 data TP, 96 data FP, 2879 data TN dan 20 data FN yang terdeksi. Label *Dos-slowloris* terdapat 16 data TP, 1228 data FP, 1755 data TN dan 0 data FN yang terdeksi. Label *Dos-Slowhttptest* terdapat 10 data, 1 data FP, 2987 data TN dan 1 data FN yang terdeksi.

TP	1601
FN	1330
FP	6
TN	62
SPECIFICITY	0.011764706
Precision	0.996266330
RECALL	0.546229556
ACCURACY	0.654951827
SENITIVITY	0.346229886
ERROR RATE	0.443482827

TP	8
FN	11
FP	31
TN	2951
SPECIFICITY	0.020964292
Precision	0.621626362
RECALL	0.575741176
ACCURACY	0.656930332
SENITIVITY	0.332511176
ERROR RATE	0.314004668

TP	1
FN	20
FP	96
TN	2879
SPECIFICITY	0.067731003
Precision	0.004
RECALL	0.155666867
ACCURACY	0.61119616
SENITIVITY	0.156666867
ERROR RATE	0.8967950

Gambar 23. Parameter NB Pengujian 2

Gambar 23 merupakan parameter klasifikasi pada label *benign* pada Naive Bayes dimana perhitungan tersebut diperoleh dari rumus *specificity*, *precision*, *recall*, *accuracy*, *sensitivity* dan *error rate* setelah mengetahui nilai dari TP, FP, TN, FN pada *confusion matrix*.

Accuracy benign	0.546229556
Accuracy SSH-Patator	0.509951827
Accuracy FTP-patator	0.443482827
Accuracy Dos-Slowloris	0.346229886
Accuracy Dos-Slowhttptest	0.332511176
Avg. Accuracy	0.40424765
Specifity benign	0.011764706
Specifity SSH-Patator	0.020964292
Specifity FTP-patator	0.067731003
Specifity Dos-Slowloris	0.004
Specifity Dos-Slowhttptest	0.004
Avg. Specifity	0.004

Accuracy benign	0.546229556
Accuracy SSH-Patator	0.509951827
Accuracy FTP-patator	0.443482827
Accuracy Dos-Slowloris	0.346229886
Accuracy Dos-Slowhttptest	0.332511176
Avg. Accuracy	0.40424765
Specifity benign	0.011764706
Specifity SSH-Patator	0.020964292
Specifity FTP-patator	0.067731003
Specifity Dos-Slowloris	0.004
Specifity Dos-Slowhttptest	0.004
Avg. Specifity	0.004

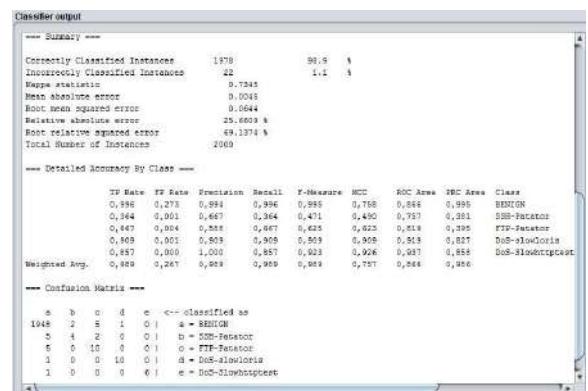
Accuracy benign	0.546229556
Accuracy SSH-Patator	0.509951827
Accuracy FTP-patator	0.443482827
Accuracy Dos-Slowloris	0.346229886
Accuracy Dos-Slowhttptest	0.332511176
Avg. Accuracy	0.40424765
Specifity benign	0.011764706
Specifity SSH-Patator	0.020964292
Specifity FTP-patator	0.067731003
Specifity Dos-Slowloris	0.004
Specifity Dos-Slowhttptest	0.004
Avg. Specifity	0.004

Gambar 24. Average Pengujian 2 NB

Gambar 24 merupakan nilai rata-rata akurasi dari Algoritma Naive Bayes dimana nilai rata-rata tersebut diperoleh dari penjumlahan nilai dari setiap label dibagi jumlah label itu sendiri.

4.3 Pengujian 3

Data yang sebelumnya telah dilakukan preprocess kemudian di split menjadi 80%. Proses tersebut merupakan pembagian data latih dan uji dimana 80% merupakan data latih dan 20% data uji. Hasil pengujian ditunjukkan pada gambar 27.



Gambar 25. Classifier Output KNN Pengujian 3

Gambar 25 merupakan hasil pengujian data yang telah di split menjadi 80%. *Classifier output* terdapat 3 bentuk yaitu *Summary*, *Detailed Accuracy By Class* dan *Confusion Matrix*. Penelitian ini hanya menggunakan 2 bentuk classifier output yaitu *Detailed Accuracy By Class* dan *Confusion Matrix*.

== Confusion Matrix ==

a	b	c	d	e	-- classified as
1948	2	5	1	0	a = BENIGN
5	4	2	0	0	b = SSH-Patator
5	0	10	0	0	c = FTP-Patator
1	0	0	10	0	d = DoS-slowloris
1	0	0	0	6	e = DoS-Slowhttptest

Gambar 26. Confusion Matrix KNN Pengujian 3

Gambar 26 merupakan *confusion matrix* dimana setiap label *network traffic* diklasifikasikan menggunakan variabel a,b,c,d dan e. Label *BENIGN* terdapat 1948 data TP, 12 data FP, 32 data TN dan 8 data FN yang terdeksi. Label *SSH-Patator* terdapat 4 data TP, 2 data FP, 1987 data TN, 7 FN yang terdeksi Label *FTP-Patator* terdapat 10 data TP, 7 data FP, 1987 data TN dan 5 data FN yang terdeksi. Label *Dos-slowloris* terdapat 10 data TP, 1 data FP, 1988 data TN dan 1 data FN yang terdeksi. Label *Dos-Slowhttptest* terdapat 6 data 0 data FP, 1993 data TN dan 1 data FN yang terdeksi.

TP	1948
FN	8
FP	12
TN	1987
SPECIFICITY	0.727272727
PRECISION	0.998800000
RECALL	0.99501027
ACCURACY	0.99
SENITIVITY	0.99501027
ERROR RATE	0.01

TP	5
FN	7
FP	2
TN	1987
SPECIFICITY	0.999564417
PRECISION	0.999999999
RECALL	0.983636364
ACCURACY	0.999564417
SENITIVITY	0.983636364
ERROR RATE	0.000435582

TP	10
FN	1
FP	0
TN	1993
SPECIFICITY	0.999472285
PRECISION	0.999999999
RECALL	0.999472285
ACCURACY	0.999472285
SENITIVITY	0.999472285
ERROR RATE	0.000527715

Gambar 27. Parameter KNN Pengujian 3

Gambar 27 merupakan parameter klasifikasi pada label *benign* pada *K-Nearest Neighbour* dimana perhitungan tersebut diperoleh dari rumus *specificity*, *precision*, *recall*, *accuracy*, *sensitivity* dan *error rate* setelah mengetahui nilai dari TP, FP, TN, FN pada *confusion matrix*.

Inventory Design	0.0778	Product Design	0.093877381	Brand Design	0.05931892
Sensitivity SDA Parallel	0.0295	Feasibility SDA Parallel	0.099999997	Realist SDA Parallel	0.019393991
Sensitivity LIP Parallel	0.034	Feasibility FIP Parallel	0.100335254	Realist FIP Parallel	0.010550007
Sensitivity DSS Standard	0.0099	Feasibility DSS Standard	0.000000002	Realist DSS Standard	0.029300003
Sensitivity DSS Modified	0.0985	Feasibility DSS Modified	1	Realist DSS Modified	0.01142857
Rep. Accuracy	0.0073	Rep. Precision	0.032577001	Rep. Recall	0.05485966
Specimen Design	0.04557214	Qualitative Design	0.000000001	Expert Design	0.001
Specimen CSM Parallel	0.000000001	Qualitative SDA Parallel	0.000000001	Expert SDA Parallel	0.0005
Specimen LIP Parallel	0.000000001	Qualitative FIP Parallel	0.000000001	Expert FIP Parallel	0.0001
Specimen DSS Standard	0.000000001	Qualitative DSS Standard	0.000000001	Expert DSS Standard	0.0001
Specimen DSS Modified	0.000000001	Qualitative DSS Modified	0.000000001	Expert DSS Modified	0.0005
L	0	Rep. Accuracy	0.000000001	Rep. Precision	0.000000001
0.001, 0.000000001	0.000000001	0.000000001	0.000000001	0.000000001	0.000000001

Gambar 28. *Average Pengujian 3 KNN*

Gambar 28 merupakan nilai rata-rata akurasi dari Algoritma KNN dimana nilai rata-rata tersebut diperoleh dari penjumlahan nilai dari setiap label dibagi jumlah label itu sendiri.

```

Classifier output

Correctly Classified Instances      1074      55.7 %
Incorrectly Classified Instances    526      44.3 %
Weighted Accuracy                 0.56441
Mean absolute error                0.18469
Root mean squared error            0.42446
Relative absolute error             1054.6098 %
Root relative squared error        455.2249 %
Total Number of Instances          2000

==== Detailed Accuracy By Class ===

           TP Rate   FP Rate   Precision   Recall   F-Measure   MCC   ROC Area   GROC Area   Class
 0.558      0.023     0.938     0.558     0.496     0.521     0.763     0.763      0.558      0.558
 0.414      0.023     0.934     0.414     0.201     0.407     0.763     0.763      0.414      0.414
 0.333      0.437     0.363     0.333     0.106     0.131     0.946     0.946      0.333      0.333
 1.000      0.415     0.913     1.000     0.026     0.088     0.520     0.520      1.000      1.000
 0.357      0.000     1.000     0.357     0.523     0.546     0.971     0.971      0.357      0.357
Weighted Avg.      0.337     0.023     0.902     0.337     0.487     0.515     0.767     0.767      0.337      0.337

==== Confusion Matrix ===

   0  1  b  e  == classified as
1088 17 73 316 0 1  == MEDIUM
 1  4  1  3  0 1  == High-Severity
 0  6  0  3  0 1  == FTR-Positive
 0  0  0  11  0 1  == D2b-Elements
 0  0  0  1  4 1  == D2d-Slowuptest
```

Gambar 29. *Classifier Output* NB Pengujian 3

Gambar 29 merupakan hasil pengujian data dengan algoritma Naive Bayes yang telah di *split* menjadi 80%. *Classifier output* terdapat 3 bentuk yaitu *Summary*, *Detailed Accuracy By Class* dan *Confusion Matrix*. Penelitian ini hanya menggunakan 2 bentuk *classifier output* yaitu *Detailed Accuracy By Class* dan *Confusion Matrix*.

a	b	c	d	e	<-- classified as
1048	17	73	818	0	a = BENIGN
1	4	1	5	0	b = SSH-Patator
0	8	5	2	0	c = FTP-Patator
0	0	0	11	0	d = DoS-slowloris
0	0	0	1	6	e = DoS-Slowhttptest

Gambar 30. *Confusion Matrix* NB Pengujian 3

Gambar 30 merupakan *confusion matrix* dimana setiap label *network traffic* diklasifikasikan menggunakan variabel a,b,c,d dan e. Label *BENIGN* terdapat 1048 data TP, 1 data FP, 43 data TN dan 908 data FN yang terdeksi. Label *SSH-Patator* terdapat 4 data TP, 25 data FP, 1964 data TN, 7 FN yang terdeksi Label *FTP-Patator* terdapat 5 data TP, 74 data FP, 1911 data TN dan 10 data FN yang terdeksi. Label *Dos-slowloris* terdapat 11 data TP, 826 data FP, 1163 data TN dan 0 data FN yang terdeksi. Label *Dos-Slowhttptest* terdapat 6 data, 0 data FP, 1993 data TN dan 1 data FN yang terdeksi.

BENIGN		MALIGNANT		BENIGN	
TP	FP	TP	FP	TP	FP
3,083	908	4	0	1,998	0
TP	FP	TP	FP	TP	FP
43	4	1964	0	1,998	0
SPECIFICITY	PRECISION	SPECIFICITY	PRECISION	SPECIFICITY	PRECISION
0.997272727	0.899046711	0.873933034	0.863635364	0.997272727	0.892891330
RECALL	ACCURACY	RECALL	ACCURACY	RECALL	ACCURACY
0.535762731	0.532617311	0.964	0.964	0.993	0.958
SENSITIVITY	PRECISION	SENSITIVITY	PRECISION	SENSITIVITY	PRECISION
0.535762731	0.4545	0.863635364	0.016	0.333333333	0.042
ERRONEOUS	HIT RATE	ERRONEOUS	HIT RATE	ERRONEOUS	HIT RATE

Gambar 31. Parameter KNN Pengujian 3

Gambar 31 merupakan parameter klasifikasi pada label *benign* pada Naive Bayes dimana perhitungan tersebut diperoleh dari rumus *specificity*, *precision*, *recall*, *accuracy*, *sensitivity* dan *error rate* setelah mengetahui nilai dari TP, FP, TN, FN pada *confusion matrix*.

Accuracy Design	0.945	Precision Design	0.989068713	Recall Design	0.915794931
Accuracy SSI posterior	0.984	Precision SSI Posterior	0.532930014	Recall SSI-Posterior	0.303610364
Accuracy PEP posterior	0.958	Precision PEP Posterior	0.92891195	Recall PEP-Posterior	0.333333333
Accuracy Ds-Skewness	0.987	Precision Ds-Skewness	0.351824274	Recall Ds-Skewness	0.857142857
Accuracy Ds-Skewness	0.9905	Precision Ds-Skewness	1	Recall Ds-Skewness	0.857142857
Avg. Accuracy	0.982125	Avg. Precision	0.42052212	Avg. Recall	0.617093975
<hr/>					
Specificity Design	0.997777	Specificity Design	0.971074733	Error Rate Design	0.049
Specificity SSI-Potitor	0.9874587	Specificity SSI-Potitor	0.982882881	Error Rate SSI-Potitor	0.016
Specificity PEP-Potitor	0.96737403	Specificity PEP-Potitor	0.923333333	Error Rate PEP-Potitor	0.012
Specificity Ds-Skewness	0.98473938	Specificity Ds-Skewness	1	Error Rate Ds-Skewness	0.013
Specificity Ds-Skewness	1	Specificity Ds-Skewness	0.867142817	Error Rate Ds-Skewness	0.0005
Avg. Specificity	0.982427988	Avg. Specificity	0.812770975	Avg. Error Rate	0.0152

Gambar 32. *Average Pengujian 3 NB*

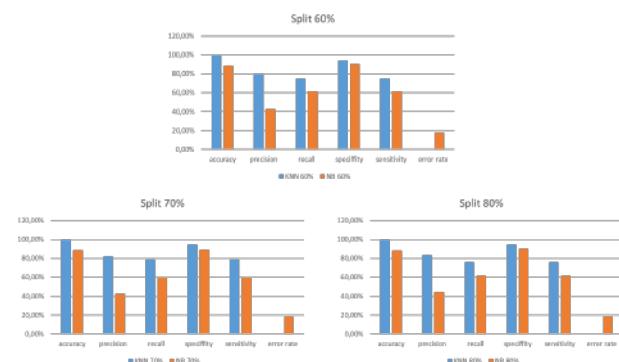
Gambar 32 merupakan nilai rata-rata akurasi dari Algoritma Naive Bayes dimana nilai rata-rata tersebut diperoleh dari penjumlahan nilai dari setiap label dibagi jumlah label itu sendiri.

4.4 Penarikan Kesimpulan

Algoritma	Accuracy	Precision	Recall	Specificity	Sensitivity	Error Rate	Avg.
K-NN 60%	99,53%	79,82%	75,20%	94,05%	75,20%	0,47%	70,55%
Naïve Bayes 60%	88,55%	42,40%	61,14%	90,09%	61,14%	17,96%	54,23%
Algoritma	Accuracy	Precision	Recall	Specificity	Sensitivity	Error Rate	Avg.
K-NN 70%	99,69%	82,24%	78,40%	94,59%	78,40%	0,47%	72,14%
Naïve Bayes 70%	88,43%	42,41%	59,50%	89,14%	59,50%	18,17%	53,47%
Algoritma	Accuracy	Precision	Recall	Specificity	Sensitivity	Error Rate	Avg.
K-NN 80%	99,70%	83,16%	75,85%	94,44%	75,85%	0,44%	71,43%
Naïve Bayes 80%	88,21%	44,27%	61,80%	90,24%	61,80%	18,52%	54,63%

Gambar 33. Rekap Data Pengujian

Gambar 33 merupakan rekap data dari pengujian yang telah dilakukan *percentage split* 60%, 70% dan 80%.



Gambar 34. Diagram Perbandingan *percentage Split* 60%,70% dan 80%

Gambar 34 merupakan diagram perbandingan antara *K-Nearest Neighbour* dengan Naive Bayes dimana *K-Nearest Nighbour* lebih tinggi dibanding Naive Bayes dari Parameter *Accuracy*, *Precision*, *Recall*, *Specificity* dan *Sensitivity* sedangkan pada *Error Rate* Naive Bayes lebih tinggi dari *K-Nearest Neighbour*.

5. KESIMPULAN

Berdasarkan hasil penelitian pada Instrusion Detection System (IDS) yang memuat data dari berbagai kategori *anomaly traffic* yang selanjutnya dilakukan proses klasifikasi dengan menggunakan algoritma *K-Nearest Neighbour* (KNN) dan Naive Bayes, maka dapat disimpulkan hasil dari ketiga pengujian dengan *percentage split* 60%, 70% dan 80% menunjukkan bahwa algoritma K-Nearest Neighbour (KNN) mendapatkan nilai yang lebih tinggi dari Naive Bayes kecuali *error rate* karena *error rate* menunjukkan bahwa data gagal diklasifikasi dengan baik. Pengujian pada percetage split 60% KNN parameter *accuracy* mendapatkan nilai 99,53%, *specificity* 94,05%, *sensitivity* 75,20%, pengujian pada percentage split 70% KNN parameter *accuracy* mendapatkan nilai 99,69%, *specificity* 94,59%, *sensitivity* 78,40% dan pengujian pada percetage split 80% parameter KNN parameter *accuracy* mendapatkan nilai 99,70%, *specificity* 94,44%, *sensitivity* 75,85% untuk melakukan klasifikasi pada dataset *anomaly network traffic* dengan menggunakan bantuan *tools* WEKA.

Journal of Applied Informatics, vol. 4, no. 2, p. 107, Aug. 2020.

BIODATA PENULIS

Aditya Dwi Afifaturahman

Mahasiswa Prodi Informatika Universitas Siliwangi Tasikmalaya

Firmansyah Maulana SN., S.T., M.Kom

Dosen Prodi Informatika Universitas Siliwangi Tasikmalaya

DAFTAR PUSTAKA

- [1] M. F. Fibrianda and A. Bhawiyuga, “Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naïve Bayes Dan Support Vector Machine (SVM),” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 9, pp. 3112–3123, 2018.
- [2] R. Vinayakumar, M. Alazab, K. P. Soman, P. Poornachandran, A. Al-Nemrat, and S. Venkatraman, “Deep Learning Approach for Intelligent Intrusion Detection System,” *IEEE Access*, vol. 7, pp. 41525–41550, 2019.
- [3] Candra Adi Winanto, “Deteksi Serangan Denial of Service Menggunakan Artificial Immune System,” vol. 2, no. 1, pp. 456–459, 2016.
- [4] B. Agarwal and N. Mittal, “Hybrid Approach for Detection of Anomaly Network Traffic using Data Mining Techniques,” *Procedia Technology*, vol. 6, pp. 996–1003, 2012.
- [5] P. García-Teodoro, J. Díaz-Verdejo, G. Maciá-Fernández, and E. Vázquez, “Anomaly-based network intrusion detection: Techniques, systems and challenges,” *Computers and Security*, vol. 28, no. 1–2, pp. 18–28, 2009.
- [6] R. N. Devita, H. W. Herwanto, and A. P. Wibawa, “Perbandingan Kinerja Metode Naive Bayes dan K-Nearest Neighbor untuk Klasifikasi Artikel Berbahasa indonesia,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 4, p. 427, 2018.
- [7] R. Doshi, N. Aphorpe, and N. Feamster, “Machine learning DDoS detection for consumer internet of things devices,” *Proceedings - 2018 IEEE Symposium on Security and Privacy Workshops, SPW 2018*, no. MI, pp. 29–35, 2018.
- [8] I. N. Rizkiana, A. Rahmatulloh, and R. Gunawan, “Penerapan Metode Clustering K-Means Untuk Menentukan Nilai Burst Header Packet Flooding Attack Pada Optical Burst Switching,” *Indonesian*