

DETEKSI DINI GANGGUAN JARINGAN *DISTRIBUTED DENIAL OF SERVICE (DDOS)* MENGGUNAKAN METODE SHANNON ENTROPY PADA SOFTWARE DEFINED NETWORK (SDN)

Achmad Solichin*¹, Ludi Nugroho²

^{1,2} Universitas Budi Luhur, Jakarta
Email: ¹achmad.solichin@budiluhur.ac.id, ²ludinugroho@gmail.com
*Penulis Korespondensi

(Naskah masuk: 20 Desember 2023, diterima untuk diterbitkan: 06 Mei 2024)

Abstrak

Software Defined Networking (SDN) adalah arsitektur jaringan baru yang memisahkan antara *control* dan *data plane*. Aspek keamanan utama dalam *control plane* salah satunya adalah serangan *DoS* dan *DDoS*. Serangan *DDoS* mengakibatkan terjadinya penurunan performa jaringan yang berjalan sangat lambat. Serangan *DDoS* dilakukan dengan menyusupi dan membanjiri *bandwidth* ke sumber daya target, sehingga dapat menyebabkan penolakan layanan bagi pengguna yang mengaksesnya. Tak hanya itu, serangan *DDoS* menyebabkan penurunan sumber daya jaringan seperti kapasitas memory dan CPU. Akibatnya kerusakan signifikan pada sistem yang menjadi korban serangan dapat mengalami kerugian, baik secara finansial, reputasi bahkan kehilangan pelanggan yang membutuhkan layanan tersebut. Mencegah serangan *DDoS* diperlukan suatu tindakan pencegahan yaitu dengan deteksi dini serangan *DDoS* untuk mengurangi dampak serangan dan memulihkan sistem dengan lebih cepat. Deteksi dini yang disebabkan oleh *DDoS* pada jaringan *SDN* dilakukan melalui pendekatan metrik *entropy* berbasis teori informasi. Penelitian ini memfokuskan pendeteksian dini pada serangan *DDoS* di dalam lingkungan *SDN* melalui metode Shannon *Entropy* dengan mendeteksi lalu lintas atau trafik normal dan *DDoS*. Penelitian ini menggunakan *dataset* publik dari *InSDN* yang diterbitkan pada tahun 2020 untuk menentukan nilai ambang batas lalu lintas normal dan *DDoS*. Hasilnya, penelitian ini berhasil mendeteksi dini lalu lintas normal dan lalu lintas serangan *DDoS* dengan nilai *entropy* sesuai ambang batas, dengan nilai akurasi 100%, presisi 100% dan recall 100% yang dihitung menggunakan *confusion matrix*. Deteksi dini menampilkan akurasi dan performa yang dapat berkontribusi banyak dalam menunjang tingkat keamanan melalui pencegahan tahap awal, sehingga hasilnya dapat meningkatkan keamanan dan efektifitas pada lingkungan *SDN*.

Kata kunci: deteksi dini, *Software Defined Networking*, teori informasi, *distributed denial of service*, *dataset*, lalu lintas.

EARLY DETECTION OF DISTRIBUTED DENIAL OF SERVICE (DDOS) NETWORK INTERFERENCE USING SHANNON ENTROPY METHOD IN SOFTWARE DEFINED NETWORK (SDN)

Abstract

Software Defined Networking (SDN) is a new network architecture that separates the control and data planes. One of the main security aspects in the control plane is *DoS* and *DDoS* attacks. *DDoS* attacks result in a decrease in network performance which is very slow. *DDoS* attacks are carried out by compromising and flooding the bandwidth to the target resource, which can cause a denial of service for users who access it. Not only that, *DDoS* attacks cause a decrease in network resources such as memory and CPU capacity. As a result, significant damage to the system, victims of attacks can suffer losses, both financially, reputationally and even lose customers who need the service. Preventing *DDoS* attacks requires preventive measures, namely early detection of *DDoS* attacks to reduce the impact of attacks and restore the system more quickly. Early detection caused by *DDoS* on *SDN* networks is carried out using an information theory-based entropy metric approach. This research focuses on early detection of *DDoS* attacks in the *SDN* environment using the Shannon Entropy method by detecting normal and *DDoS* traffic. This research uses a public dataset from *InSDN* published in 2020 to determine the threshold values for normal traffic and *DDoS*. As a result, this research succeeded in early detection of normal traffic and *DDoS* attack traffic with entropy values according to the threshold, with values of 100% accuracy, 100% precision and 100% recall calculated using a confusion matrix. Early detection displays accuracy and performance that can

contribute greatly to supporting security levels through early stage prevention, so that the results can increase security and effectiveness in the SDN environment.

Keywords: *early detection, Software Defined Networking, information theory, distributed denial of service, dataset, traffic.*

1. PENDAHULUAN

Software Defined Networking (SDN) adalah arsitektur jaringan baru yang memisahkan antara *control* dan *data plane*. *SDN* dikembangkan untuk mengurangi kompleksitas jaringan dan mengelola seluruh jaringan secara terpusat melalui *control plane*. *Control plane* dalam *SDN* lebih mudah untuk dikelola dibandingkan dengan arsitektur jaringan secara konvensional, yang dimana *control plane* dan *data plane* terdapat di setiap perangkat jaringan seperti *router* maupun *switch*. Komunikasi antara *control plane* dan *data plane* dihubungkan dengan *application programming Interfaces (API)*, sehingga *control plane* dapat melakukan kontrol langsung pada keseluruhan perangkat *data plane*. Melalui *control plane* terpusat, *SDN* dapat mencegah pelanggaran keamanan, akan tetapi dapat juga membawa ancaman dan kerentanan baru, dan *control plane* dapat menjadi satu pusat titik kegagalan dan menjadi target serangan yang membawa *malicious activities* di dalam jaringan *SDN* yang dapat menyebabkan *control plane* menjadi tidak dapat diakses. Aspek keamanan utama dalam *control plane* salah satunya adalah serangan *DoS* dan *DDoS* (Singh and Behal, 2020).

Serangan *distributed denial of service (DDoS)* dilakukan dengan menyusupi dan membanjiri bandwidth ke sumber daya target seperti server, situs web dan sumber daya lainnya, sehingga dapat menyebabkan penolakan layanan bagi pengguna yang mengaksesnya. Akibatnya kerusakan signifikan pada sistem yang menjadi korban serangan dapat mengalami kerugian, baik secara finansial, reputasi bahkan dapat kehilangan pelanggan yang membutuhkan layanan tersebut. Dengan deteksi dini serangan *DDoS*, dapat dilakukan suatu tindakan pencegahan untuk mengurangi dampak serangan dan memulihkan sistem dengan lebih cepat, sebelum menyebabkan kerugian menjadi lebih parah. Misalnya dengan mengalihkan lalu lintas yang tidak perlu atau memblokir lalu lintas yang terindikasi mencurigakan. Serangan *DDoS* biasanya ditandai oleh beberapa perilaku seperti performa jaringan yang berjalan sangat lambat dalam membuka file atau mengakses sebuah situs, kenaikan lalu lintas jaringan yang sangat mendadak, jumlah lalu lintas yang mencurigakan yang berasal dari satu alamat IP atau rentang IP Address, hingga terbatasnya sumber daya jaringan termasuk kapasitas memori dan CPU, sehingga mengganggu layanan yang tersedia oleh sistem.

Control plane dapat dicegah dari serangan *distributed denial of service (DDoS)* melalui deteksi dini pada tahap awal. Perangkat lunak pengontrol

dapat dijalankan di laptop atau server yang kuat, dan istilah "dini" tergantung pada toleransi perangkat dan properti lalu lintas. Namun, jika deteksi terjadi pada beberapa ratus paket pertama, mitigasi dapat diterapkan sebelum pengontrol benar-benar dibanjiri dengan sejumlah besar paket berbahaya (Mousavi and St-Hilaire, 2015).

Deteksi dini perlu dilakukan pada tahap awal sebelum pengontrol bermasalah. Deteksi tersebut dilakukan dengan mendeteksi lalu lintas atau trafik normal dan *DDoS*. Jika lalu lintas transmisi lebih rendah dari ambang batas, itu berarti lingkungan jaringan dalam keadaan normal, tidak ada beban berat atau serangan *DDoS* terjadi. Sedangkan jika lalu lintas lebih tinggi dari ambang batas, itu mungkin mewakili kelainan di lingkungan. Beban yang berlebihan dapat berarti bahwa lingkungan jaringan sedang diserang oleh *DDoS* (Hong, Lee and Lee, 2019). Untuk penetapan ambang batas dapat dilakukan dengan menjalankan *dataset* untuk mendapatkan nilai ambang batas yang sesuai dan merupakan kelipatan dari standar deviasi dari nilai *entropy* (Mousavi and St-Hilaire, 2015).

Agar deteksi dini dapat dikatakan berjalan dengan baik maka kriteria yang dibutuhkan adalah metode yang cepat dan efektif, yang dapat berjalan bersama *controller*. Sehingga secara bersamaan dapat mencegah adanya proses penggunaan *power* atau *resources*, terutama saat puncak dari serangan *DDoS* terjadi (Mousavi and St-Hilaire, 2015). Selain itu kriteria lain dari deteksi dini adalah metode keakuratannya dalam melakukan deteksi dini di tahap awal (Sahoo *et al.*, 2018).

Jadi, mencegah *control plane* dari serangan *DDoS* merupakan suatu hal yang penting saat ini, karena setiap layer pada *control plane* dapat menjadi target serangan dengan karakter serangan yang berbeda (Elsayed, Le-Khac and Jurcut, 2020). Serangan *DoS* dan *DDoS* adalah ancaman jaringan umum di *SDN* dan arsitektur jaringan tradisional (Naous *et al.*, 2008). Penyerang *DDoS* mengirim paket SYN untuk menghabiskan sumber daya korban seperti SYN, UDP, ICMP, dan serangan LAND (Tandon, 2020). Berdasarkan *Netscout's 14th Annual Worldwide Infrastructure Security Report* dari tahun 2008 – 2018, serangan *DDoS* terbesar dilaporkan oleh responden survei adalah 841 Gbps pada tahun 2018. Sementara yang lain melaporkan serangan *DDoS* sebesar 450 Gbps, 394 Gbps, dan 300 Gbps (Netscout Systems, 2019). Serangan *DDoS* telah di klasifikasi oleh Arbor Networks seperti serangan *DDoS* Volumetrik, serangan protokol, serangan *DDoS*

tingkat rendah, dan serangan *DDoS* berbasis kerentanan (Tandon, 2020).

Deteksi dini gangguan jaringan yang disebabkan oleh *DDoS* pada jaringan *SDN* dilakukan melalui pendekatan metrik entropi dan divergensi berbasis teori informasi yang banyak digunakan untuk deteksi serangan *DDoS*. Entropi mewakili keacakan dalam fitur jaringan, sedangkan metrik divergensi mewakili kesamaan dua distribusi probabilitas. Konsep pengukuran ketidakpastian awalnya diciptakan oleh Claude Shannon pada tahun 1948 (Shannon, 1948; Singh and Behal, 2020). Dengan menggunakan ukuran entropi, dapat dilihat bagaimana perilaku jaringan saat ini menyimpang dari perilaku jaringan normal, yang berujung pada deteksi serangan *DDoS*. Banyak rekan peneliti memberikan pendekatan pertahanan *DDoS* menggunakan metrik entropi (Singh and Behal, 2020).

Pengklasifikasi berbasis teori informasi ini dapat dilatih untuk menentukan perilaku abnormal lalu lintas jaringan dengan lebih akurat. Beberapa *classifier* yang umum digunakan berdasarkan teori informasi adalah Shannon *Entropy* (Giotis *et al.*, 2014; Wang, Jia and Ju, 2015; Mousavi and St-Hilaire, 2015; Tsai *et al.*, 2017; Boite *et al.*, 2017; Sahoo, Tiwary and Sahoo, 2018; Ahalawat *et al.*, 2019; Bawany and Shamsi, 2019; Cui *et al.*, 2019; Hong, Lee and Lee, 2019; Sun *et al.*, 2019; Maddu and Rao, 2024), ϕ -*Entropy* (Li and Wu, 2020), Generalized *Entropy* (Sahoo *et al.*, 2018; Sahoo, Tiwary and Sahoo, 2018), Generalized Information Distance (GID) (Sahoo, Tiwary and Sahoo, 2018), KL Divergence (Sahoo, Tiwary and Sahoo, 2018), Conditional *Entropy* (Xuanyuan, Ramsurrun and Seeam, 2019) dan Joint *Entropy* (Kalkan *et al.*, 2018). Solusi berdasarkan metrik teori informasi seperti diatas, menggunakan nilai ambang batas yang telah ditentukan sebelumnya (bergantung pada perilaku jaringan dasar) untuk deteksi anomali. Karena jaringan berbasis *SDN* belum digunakan secara publik, maka untuk menentukan perilaku dasar yang benar dari jaringan berbasis *SDN* merupakan tantangan di depan komunitas penelitian (Singh and Behal, 2020).

Adapun beberapa penelitian mengenai serangan *DDoS* pada jaringan *SDN* dengan menggunakan metode *machine learning* seperti penelitian berjudul Detection and defense of *DDoS* attack-based on deep learning in OpenFlow-based *SDN* (Li *et al.*, 2018), TDDAD: Time-based detection and defense scheme against *DDoS* attack on *SDN* controller (Cui *et al.*, 2018), Design of Ensemble Learning Methods for *DDoS* Detection in *SDN* Environment (Deepa, Sudar and Deepalakshmi, 2019), Efficient distributed denial-of-service attack defense in *SDN*-based cloud (Phan and Park, 2019), Machine Learning Approach Equipped with Neighbourhood Component Analysis for *DDoS* Attack Detection in Software-Defined Networking (Tonkal *et al.*, 2021), Low Rate *DDoS*

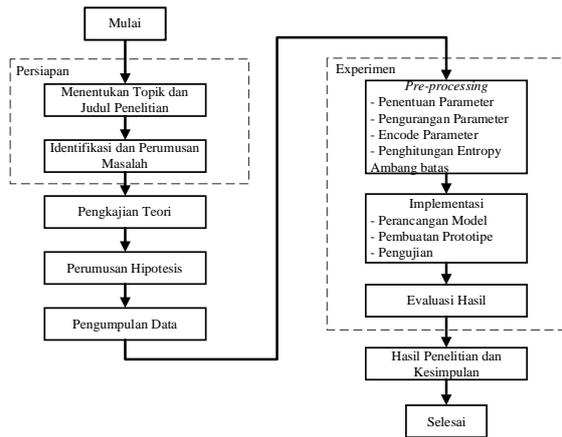
Detection Using Weighted Federated Learning in *SDN* Control Plane in IoT Network (Ali *et al.*, 2023).

Penelitian ini memfokuskan pendeteksian dini pada serangan *DDoS* di dalam lingkungan *SDN* melalui metode Shannon *Entropy*. Alasan utama peneliti menggunakan metode Shannon *Entropy* untuk deteksi serangan *DDoS* adalah kemampuannya untuk mengukur keacakan dalam paket yang masuk ke jaringan. Semakin tinggi keacakan, semakin tinggi entropi, dan sebaliknya (Mousavi and St-Hilaire, 2015; Omar, Ho and Urbina, 2019) Peneliti menggunakan public *dataset* dari *InSDN* yang diterbitkan pada tahun 2020 untuk menentukan nilai ambang batas. Dalam menentukan nilai ambang batas, peneliti menentukan nilai *entropy* terendah dan tinggi, kemudian membandingkan nilai *entropy* tersebut sebagai pembanding (Mousavi and St-Hilaire, 2015). Walaupun ada beberapa public *dataset* yang telah ada sebelumnya seperti KDD'99 dan NSL-KDD, *dataset* tersebut telah usang dan memiliki ketidakcocokan pada lingkungan *SDN*, sehingga peneliti memilih *InSDN* (Elsayed, Le-Khac and Jurcut, 2020).

Pada eksperimen ini peneliti menggunakan topologi *SDN* yang disimulasikan dalam *Mininet* emulator (Lantz and O'Connor, 2015), untuk mendeteksi dini serangan *DDoS*. Parameter yang digunakan sebagai kriteria pendeteksian dini adalah *Source IP*, *Destination IP*, *Source Port*, *Destination Port*, dan *protocol*. Parameter tersebut dapat digunakan sebagai dasar untuk menilai apakah lingkungan sistem secara keseluruhan tunduk pada serangan *DDoS* (Hong, Lee and Lee, 2019). Penerapan Shannon *Entropy* pada jaringan *SDN* bertujuan untuk meningkatkan akurasi dalam mendeteksi normal dan *DDoS* trafik. Penelitian ini dapat mendeteksi dini potensi serangan normal dan *DDoS* trafik dari serangan *DDoS* pada jaringan *SDN*, dan berkontribusi banyak dalam menunjang tingkat keamanan. Sehingga dalam hasilnya dapat menampilkan performa dari deteksi dini serangan dalam upaya meningkatkan keamanan dan efektifitas pada lingkungan *SDN*.

2. METODE PENELITIAN

Penelitian yang dilakukan ini termasuk ke dalam metode kuantitatif. Penelitian metode kuantitatif yaitu dengan melakukan perhitungan secara matematis terhadap populasi data atau sampel tertentu. Adapun sifat penelitian berupa penelitian secara eksperimental. Penelitian ini melakukan eksperimen melalui pengujian klasifikasi dalam deteksi dini normal dan *DDoS* trafik dari serangan *distributed denial of service (DDoS)*. Adapun langkah-langkah yang dilakukan dalam penelitian ini akan ditunjukkan oleh gambar 1.



Gambar 1. Langkah-Langkah Penelitian

2.1. Menentukan Topik dan Judul Penelitian

Pada tahap ini adalah awal permulaan dari penelitian dimana peneliti menentukan topik masalah dan judul penelitian dengan membandingkan pada penelitian sebelumnya yang menggunakan metode *machine learning*. Berikut beberapa perbandingan serangan *DDoS* pada penelitian sebelumnya pada tabel 1.

Tabel 1. Tinjauan Studi

Penulis	Judul	Permasalahan	Metode
(Li et al., 2018)	Detection and defense of DDoS attack-based on deep learning in OpenFlow-based SDN	Tingkat misdiagnosis yang masih tinggi dan penilaian yang tidak tepat dalam pemrosesan lalu lintas jaringan dan deteksi serangan DDoS baru	CNN RNN LTSM
(Cui et al., 2018)	TDDAD: Time-based detection and defense scheme against DDoS attack on SDN controller	SDN dapat dengan mudah terganggu oleh serangan DDoS baru yang memicu pesan Paket Masuk yang sangat besar. Karena solusi yang ada berfokus pada pemeriksaan status jaringan saat ini dengan fitur konten untuk mendeteksi serangan, solusi tersebut mungkin dapat menyetakan	BPNN
(Deepa, Sudar and Deepalak)	Design of Ensemble Learning Methods for DDoS	Kesulitan dalam menganalisis jumlah paket yang besar	KNN

Penulis	Judul	Permasalahan	Metode
shmi, 2019)	Detection in SDN Environment	yang mempengaruhi akurasi dalam pendeteksian dan waktu respon	
(Phan and Park, 2019)	Efficient distributed denial-of-service attack defense in SDN-based cloud	Vulnerability pada kontroler SDN yang disebabkan oleh serangan DDoS mengakibatkan kontroler dan switch openflow berhenti bekerja dan kehabisan sumber daya	HIPF
(Myint Oo et al., 2019)	Advanced Support Vector Machine-(ASVM-) based detection for Distributed Denial of Service (DDoS) attack on Software Defined Networking (SDN)	Sulitnya menerapkan klasifikasi multikelas pada SVM. Dan lamanya waktu pelatihan dan pengujian yang diperlukan untuk algoritma SVM	Advanced Support Vector Machine (ASVM)
(Xuanyuan, Ramsurrun and Seeam, 2019)	Detection and mitigation of DDoS attacks using conditional entropy in software-defined networking	Kesulitan dalam mencapai tingkat deteksi tinggi tanpa melibatkan false negative dengan metode entropy yang ada	Conditional Entropy
(Novaes et al., 2020)	Long short-term memory and fuzzy logic for anomaly detection and mitigation in software-defined network environment	Kesulitan dalam melakukan deteksi anomaly dengan algoritma machine learning karena limitasi atribut dalam proses training	LSTM
(Tonkal et al., 2021)	Machine Learning Approach Equipped with Neighbourhood Component Analysis for DDoS Attack Detection in Software-Defined Networking	Kesulitan dalam menentukan trafik normal dan trafik serangan	Neighbourhood Component Analysis (NCA)
(Rafiee and Shirmarz, 2022)	Self-Organization Map (SOM) Algorithm for DDoS Attack Detection in	Kesulitan dalam deteksi flow DDoS pada kontroler SDN	Self-Organization Map (SOM)

Penulis	Judul	Permasalahan	Metode
	Distributed Software Defined Network (D-SDN)		
(Ali et al., 2023)	Low Rate DDoS Detection Using Weighted Federated Learning in SDN Control Plane in IoT Network	Kesulitan dalam mendeteksi dan membedakan low rate DDoS sebagai malicious traffic atau trafik yang sah	Weighted Federated Learning (WFL)

2.2. Identifikasi dan Perumusan Masalah

Pada tahap ini dilakukan identifikasi dan perumusan masalah yaitu adanya penurunan performa jaringan yang berjalan sangat lambat dalam membuka *file* atau mengakses sebuah situs *controller* jaringan *SDN*, peningkatan lalu lintas jaringan yang sangat mendadak hingga penurunan sumber daya jaringan. Berdasarkan identifikasi diatas maka dirumuskan permasalahan dalam penelitian ini adalah bagaimana penggunaan deteksi dini potensi normal dan *DDoS* trafik dari serangan *distributed denial of service (DDoS)* pada jaringan *SDN* untuk meningkatkan akurasi dan performa dengan menggunakan metode Shannon *Entropy*? dan berapa nilai ambang batas yang paling optimal pada model deteksi dini gangguan jaringan *distributed denial of service (DDoS)* dengan metode Shannon *Entropy* pada jaringan *SDN*?

2.3. Pengkajian Teori

Setelah mengetahui permasalahan yang ada, langkah selanjutnya adalah dengan mengumpulkan informasi, konsep, dan teori yang akan dijadikan landasan teori yang berasal dari buku, jurnal ilmiah dan sumber lain yang berkaitan dengan penelitian ini.

2.4. Perumusan Hipotesis

Hipotesis merupakan jawaban sementara dari sebuah penelitian, oleh karena itu suatu hipotesis hendaknya didasarkan pada teori atau asumsi. Hipotesis dari penelitian ini yaitu diduga tingkat akurasi dan performa yang baik pada metode Shannon *Entropy* dapat mendeteksi dini potensi normal dan *DDoS* trafik dari serangan *distributed denial of service (DDoS)* pada jaringan *SDN*, dan diduga nilai ambang batas yang optimal dapat dijadikan model untuk deteksi dini gangguan jaringan *distributed denial of service (DDoS)* dengan metode Shannon *Entropy* pada jaringan *SDN*.

2.5. Metode Pengumpulan Data

Metode pengumpulan data yang akan digunakan pada penelitian ini adalah capture paket normal dan *DDoS* trafik menggunakan *Scapy tools*. Dan dengan

menggunakan *dataset* public *InSDN* yang diterbitkan pada tahun 2020 pada link <https://aseados.ucd.ie/datasets/SDN/> sebagai penentuan nilai ambang batas. *InSDN* terdiri dari 83 atribut dan 136.743 baris yang berisi benign dan variasi serangan pada setiap kategori yang ada di dalam lingkungan *SDN*, atribut tersebut diantaranya *Flow-id*, *Src-IP*, *Src-Port*, *Dst-IP*, *Dst-Port*, *Protocol-Type* dan lain-lainnya.

2.6. Pre-processing

Pada tahap ini *Pre-processing* dibagi kedalam 4 bagian:

1. Penentuan Parameter

Menentukan parameter yang akan dijadikan acuan sebagai kriteria deteksi *DDoS* pada *SDN* yaitu *Source IP*, *Destination IP*, *Source Port*, *Destination Port*, dan *protocol*.

2. Pengurangan Parameter

Dataset InSDN memiliki 83 parameter, sehingga perlu dikurangi menjadi beberapa parameter penting.

3. Encode Parameter

Dataset yang sudah dilakukan pengurangan parameter dan filter label dilakukan encoding atau mengubah nilai parameter menjadi nilai numerik.

4. Perhitungan *Entropy* Ambang Batas

Dataset yang sudah diubah menjadi nilai numerik kemudian dikalkulasi perhitungan nilai *entropy*, sebagai penentuan nilai ambang batas.

2.7. Implementasi

Pada tahap ini implementasi menggunakan *OpenFlow environment* menggunakan simulasi dari *Mininet*, kemudian mengimplementasikan *POX* sebagai kontroler *SDN*. *Pox controller* memberikan kemudahan dalam implementasi dan efisiensi dalam menjalankan program *Python*. Berikut tahap-tahap dalam implementasi:

1. Membuat perancangan model algoritma deteksi trafik normal dan *DDoS* menggunakan metode Shannon *Entropy*.

2. Membuat prototipe topologi *SDN* pada *Mininet* yang terdiri dari *Pox controller*, *Router*, *OpenFlow Switch* dan *Hosts*.

3. Membuat deteksi trafik normal dan *DDoS* pada *Pox controller* yang sudah ditentukan nilai ambang batas dengan metode Shannon *Entropy* pada pre-processing sebelumnya.

4. Pengujian deteksi dini normal dan *DDoS* trafik serangan *DDoS* menggunakan *Scapy tools*.

2.8. Evaluasi Hasil

Pada proses evaluasi hasil dilakukan dengan cara menghitung nilai akurasi, presisi dan *recall* dengan menggunakan *confusion matrix* pada tabel 2.

Tabel 2. *Confusion Matrix*

Kelas	Terklarifikasi Positif	Terklarifikasi Negatif
Positif	TP (True Positive)	FN (False Negative)
Negatif	FP (False Positive)	TN (True Negative)

Berdasarkan nilai *True Negative* (TN), *False Positive* (FP), *False Negative* (FN), dan *True Positive* (TP) dapat diperoleh nilai akurasi, presisi dan *recall*. Nilai akurasi menggambarkan seberapa akurat sistem dapat mengklasifikasikan data secara benar. Dengan kata lain, nilai akurasi merupakan perbandingan antara data yang terklasifikasi benar dengan keseluruhan data. Nilai akurasi dapat diperoleh dengan Persamaan 1. Nilai presisi menggambarkan jumlah data kategori positif yang diklasifikasikan secara benar dibagi dengan total data yang diklasifikasi positif. Presisi dapat diperoleh dengan Persamaan 2. Sementara itu, *recall* menunjukkan berapa persen data kategori positif yang terklasifikasikan dengan benar oleh sistem. Nilai *recall* diperoleh dengan Persamaan 3 (Solichin, 2017).

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$Presisi = \frac{TP}{FP + TP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{FN + TP} \times 100\% \quad (3)$$

Keterangan:

True Positive (TP) jumlah data positif yang terklarifikasi benar oleh sistem.

True Negative (TN) jumlah data negatif yang terklarifikasi benar oleh sistem.

False Positive (FP) jumlah data positif namun terklarifikasi salah oleh sistem.

False Negative (FN) jumlah data negatif namun terklarifikasi salah oleh sistem.

2.9. Hasil Penelitian dan Kesimpulan

Pada tahap ini diperoleh hasil dari Deteksi Dini Gangguan Jaringan *Distributed denial of service* (DDoS) Menggunakan Metode *Shannon Entropy* pada *Software Defined Network* (SDN), kemudian dibuat kesimpulan dari hasil penelitian.

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Data

Data merupakan sebuah hal penting dalam pelaksanaan penelitian, data yang didapatkan pada penelitian ini adalah data yang bersumber dari *dataset InSDN* (Elsayed, Le-Khac and Jurcut, 2020) dan *capture paket* dari *packet generation* di dalam jaringan *SDN*. *Dataset* tersebut memiliki 83 parameter dan sudah memiliki label. Berikut detail label *dataset* yang ditunjukkan dalam Tabel 3.

Tabel 3. Label *Dataset*

<i>Dataset</i>	BFA	DDoS	DoS	Probe	U2R
Total	295	73529	1145	61757	17
Total Keseluruhan	136743				

Dari label *dataset* yang ditunjukkan pada Tabel 3, penelitian ini memfokuskan pada label *DDoS* dan *DoS* sebagai acuan yang digunakan dalam menentukan nilai ambang batas. Seperti yang ditunjukkan pada Tabel 4.

Tabel 4. Label *Dataset* Setelah di Filter

<i>Dataset</i>	DDoS	DoS
Total	73529	1145
Total Keseluruhan	74674	

Kemudian setelah dilakukan filter, selanjutnya adalah mengurangi parameter dari total 83 parameter menjadi 6 parameter. Dari ke 6 parameter tersebut, dilakukanlah proses *encode* nilai parameter menjadi nilai numerik. Data yang diproses dalam penelitian ini adalah data yang memiliki parameter seperti *Source IP*, *Destination IP*, *Source Port*, *Destination Port*, dan *protocol*.

Pada pengumpulan data menggunakan *capture paket* dari *packet generation*, penelitian ini menggunakan *Scapy tools*. *Scapy* merupakan aplikasi *Python* yang digunakan untuk menghasilkan paket jaringan dengan membuat paket UDP dan memalsukan sumber *IP address*. *Scapy tools* dapat digunakan untuk pengujian deteksi dini normal dan *DDoS* trafik. Trafik *DDoS* yang menuju satu host memiliki rate yang lebih tinggi dibandingkan dengan trafik normal.

3.2. Pre-processing

3.2.1. Penentuan Parameter

Pada tahap pre-processing, dilakukan persiapan *dataset InSDN* yang kemudian di load *dataset* menggunakan *pandas library* pada program *python*. *Dataset* yang di load memiliki 83 atribut. Dan memiliki 136.743 baris yang berisi benign dan variasi serangan yang sudah terlabel, seperti *BFA*, *DDoS*, *DoS*, *Probe* dan *U2R* seperti ditunjukkan pada Tabel 2. Setelah dilakukan proses load *dataset*, selanjutnya dilakukan penentuan parameter dari total 83 parameter menjadi 6 parameter, yaitu *Src IP*, *Src Port*, *Dst IP*, *Dst Port*, *Protocol*, dan Label. Menurut (Hong, Lee and Lee, 2019) dasar penghitungan entropi dapat berupa *Src IP*, *Src Port*, *Dst IP*, *Dst Port*, *Protocol*, dan sebagainya.

3.2.2. Pengurangan Parameter

Setelah dilakukan penentuan parameter menjadi 6 parameter, yaitu *Src IP*, *Src Port*, *Dst IP*, *Dst Port*, *Protocol*, dan Label. Tahap selanjutnya adalah pengurangan parameter dari total 83 parameter menjadi 6 parameter dengan menggunakan *pandas*

library pada program *python* yang sama. Berikut hasil pengurangan parameter yang disajikan dengan 5 data awal dan 5 data akhir, yang ditunjukkan pada Tabel 5.

Tabel 5. Pengurangan Parameter *Dataset InSDN* (Sampel)

No	Src IP	Src Port	Dst IP	Dst Port	Protocol	Label
0	192.168.3.130	3869	200.175.2.130	4444	6	U2 R
1	192.168.3.130	3869	200.175.2.130	4444	6	U2 R
2	200.175.2.130	3374	192.168.3.130	3632	6	U2 R
...
136	200.175.2.130	4479	192.168.3.130	139	6	U2 R
740	192.168.3.130	4196	200.175.2.130	4444	6	U2 R
136	192.168.3.130	4196	200.175.2.130	4444	6	U2 R
742	192.168.3.130	4196	200.175.2.130	4444	6	U2 R

Kemudian setelah parameter dikurangi menjadi 6 parameter, *dataset* dilakukan filter label, dari yang sebelumnya memiliki 5 label menjadi 2 label yaitu *DDoS* dan *DoS*. Pada program *python*, parameter yang sudah ditentukan selanjutnya dipilih parameter "Label" yang berisi nilai "*DDoS*" dan "*DoS*" kemudian dilakukan filter. Adapun kriteria pemilihan label *DDoS* dan *DoS* adalah sebagai berikut:

1. Membatasi analisis hanya pada label *DDoS* dan *DoS*, dan mendapatkan informasi tentang tingkat kompleksitas atau ketidakpastian dalam distribusi serangan pada *dataset*.
2. Fokus pada ancaman *DDoS* dan *DoS* untuk menganalisis serangan yang bertujuan mengancam ketersediaan sistem.
3. Mengidentifikasi pola dan variasi serangan *DDoS* dan *DoS* pada *dataset*.
4. Sebagai acuan untuk perhitungan nilai ambang batas yang bersumber dari *dataset*.

Berikut hasil filter label yang ditunjukkan pada Tabel 6.

Tabel 6. Filter Label *Dataset InSDN* (Sampel)

No	Src IP	Src Port	Dst IP	Dst Port	Protocol	Label
298	6.234.13.2.122	0	192.168.3.130	0	0	<i>DDoS</i>
299	143.97.107.22	0	192.168.3.130	0	0	<i>DDoS</i>
...
749	200.175.2.130	5791	192.168.3.130	80	6	<i>DoS</i>
749	200.175.2.130	5791	192.168.3.130	80	6	<i>DoS</i>

3.2.3. Encode Parameter

Setelah tahap pengurangan parameter dan filter label, tahap selanjutnya adalah melakukan proses *encoding* nilai parameter menjadi nilai numerik, agar nantinya dapat diproses perhitungan nilai *entropy*

sebagai penentuan ambang batas. Proses *encoding* yang digunakan adalah dengan metode label *encoding*. Dimana metode ini mengasosiasikan setiap nilai non-numerik dengan nilai numerik unik, yaitu dengan menetapkan angka 0, 1, 2, dst., secara berurutan pada setiap nilai yang unik yang terdapat pada setiap parameter. Berikut hasil encode nilai parameter yang ditunjukkan pada Tabel 7 yang diurutkan berdasarkan *Src IP*.

Tabel 7. *Encoded Dataset InSDN* (Sampel)

No	Src IP	Src Port	Dst Port	Protocol	Encoded
701	...	0	...	0	0
32	1.1.1.28
614	...	0	...	0	0
96	1.1.1.200
...
613	99.97.15.04	0	0
580	99.99.5.03	0	0
7

3.2.4. Perhitungan *Entropy* Ambang Batas

Tahap akhir dari *pre-processing* adalah perhitungan nilai *entropy* untuk menentukan nilai ambang batas. Penetapan nilai ambang batas dengan perhitungan nilai *entropy* yang diambil dari probabilitas yang muncul dari atribut *dataset* yang sudah ditentukan sebelumnya dan diproses *encode*. Perhitungan *entropy* dilakukan pada atribut *Src IP_encoded*, *Src Port_encoded*, *Dst IP_encoded*, *Dst Port_encoded*, dan *Protocol_encoded* yang telah diubah menjadi nilai numerik menggunakan metode label *encoding*, langkah-langkah perhitungan dijelaskan sebagai berikut:

1. Hitung jumlah kemunculan setiap nilai atribut untuk masing-masing atribut dalam *dataset*. Hal ini akan memberikan gambaran tentang seberapa sering setiap nilai muncul dalam *dataset*.
2. Dengan menggunakan jumlah kemunculan, probabilitas ini akan memberikan informasi tentang seberapa sering nilai tertentu muncul secara relatif terhadap total sampel.
3. Menggunakan rumus umum dari Shannon *entropy* $H(x) = -\sum_1^n p_i \log_2 p_i$ untuk menghitung entropi dari setiap nilai atribut. Dalam rumus ini, probabilitas kemunculan nilai atribut menggunakan rumus $P_i = \frac{f_i}{f_t}$. Proses ini dilakukan untuk setiap nilai atribut dalam setiap atribut yang terlibat.

Dari langkah-langkah diatas menghasilkan nilai *entropy* yang ditunjukkan pada Tabel 8.

Tabel 8. Nilai *Entropy* Parameter

Src IP_encoded	Src Port_encoded	Dst IP_encoded	Dst Port_encoded	Protocol_encoded
16,0441	0,3501	0,0325	0,1934	0,1533

3.3. Perancangan Model

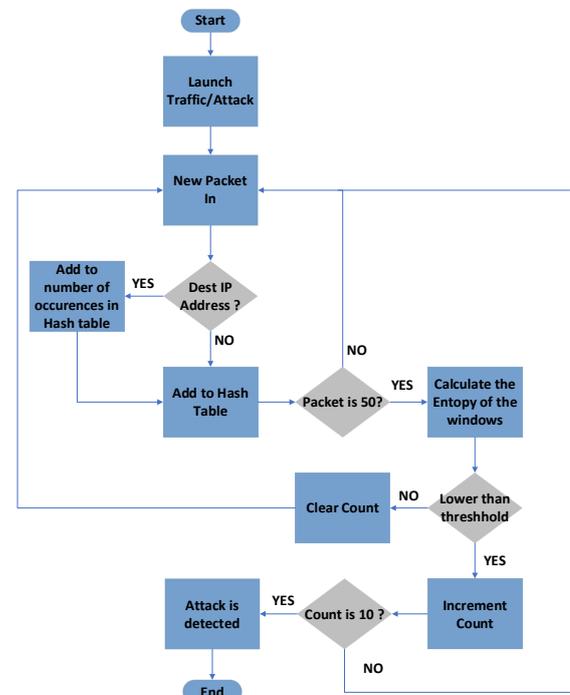
Pada perancangan model deteksi dini gangguan jaringan *distributed denial of service (DDoS)* menggunakan metode Shannon *entropy* pada *software defined network (SDN)* dilakukan pendekatan simulasi trafik yang terdiri dari trafik normal dan *DDoS*. Trafik tersebut berisikan paket *window*, setiap paket *window* yang masuk akan diuraikan untuk menentukan alamat IP tujuan, kemudian jika paket sudah mencapai sebanyak 50 paket *window* maka nilai *entropy* akan dihitung dan dibandingkan dengan nilai ambang batas. Menurut (Mousavi and St-Hilaire, 2015; Omar, Ho and Urbina, 2019; Rajan and Aravindhar, 2023) alasan menggunakan 50 paket *window* adalah sebagai berikut:

1. Terbatasnya jumlah koneksi baru yang masuk ke setiap host di jaringan. Di *SDN*, setelah koneksi dibuat, paket tidak akan melewati pengontrol kecuali ada permintaan baru.
2. Bahwa jumlah switch dan host yang terbatas dapat dihubungkan ke setiap pengontrol.
3. Jumlah komputasi yang dilakukan untuk setiap *window*. Dari daftar 50 paket *window*, nilai dapat dihitung lebih cepat dari 500 paket dan serangan di *window* 50 paket terdeteksi lebih awal.
4. Penggunaan CPU lebih rendah dibandingkan dengan menggunakan lebih dari 50 paket *window*.

Nilai ambang batas sudah ditentukan berdasarkan perhitungan nilai *entropy dataset InSDN* pada tahap *pre-processing*. Jika nilai *entropy* di atas nilai ambang batas maka trafik tersebut adalah trafik normal. Dan jika nilai *entropy* di bawah nilai ambang batas dan berlangsung selama setidaknya hingga lima (5) periode *entropy* secara berturut-turut, maka hal ini dianggap sebagai adanya serangan *DDoS*. Deteksi dalam lima periode *entropy* tersebut mengindikasikan adanya 250 paket *window* yang merupakan intrusi, sehingga dapat memberikan peringatan dini terhadap serangan dalam jaringan. Deteksi dini dalam 5 periode berturut-turut juga memiliki *false positive* terendah. Keuntungan lain adalah mencegah kemungkinan *switch* yang rusak dan memotong beberapa *host* dan mengurangi paket baru yang masuk ke dalam kontroler dan dapat membantu administrator jaringan untuk melakukan aksi pencegahan (Mousavi and St-Hilaire, 2015).

Pada penelitian ini siklus *entropy* yang digunakan adalah dengan 10 periode *entropy* dengan total 500 paket *window*, dan dengan topology jaringan yang lebih sederhana yaitu dengan 1 kontroler, 3 *switch* dan 8 *host*. Alasan peneliti menggunakan 10 periode adalah dengan adanya

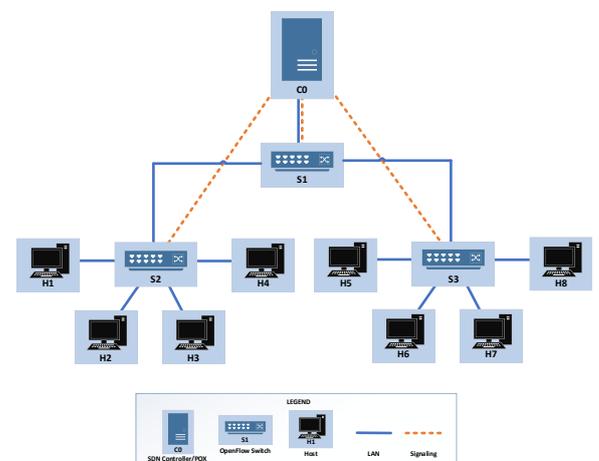
topology lebih sederhana, tidak membuat beban *CPU* menjadi *overload* dan dapat memaksimalkan akurasi penggunaan perhitungan nilai *entropy* dalam deteksi dini serangan *DDoS* jaringan *SDN*. Berikut adalah *flowchart* deteksi *DDoS* yang dapat digunakan untuk menentukan trafik normal dan *DDoS*, seperti ditunjukkan pada gambar 2.



Gambar 2. *Flowchart* Deteksi *DDoS*

3.4. Perancangan Sistem

Agar sistem dapat berjalan dengan baik dibutuhkan juga sebuah topology jaringan *SDN* yang dijalankan di dalam emulator Mininet. Berikut topology yang digunakan pada gambar 3.



Gambar 3. *Topology Jaringan Software Defined Network (SDN)*

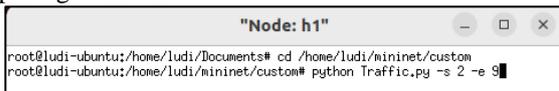
3.5. Pengujian Sistem

Pada tahap pengujian adalah proses menjalankan simulasi trafik normal dan *DDoS* yang kemudian diujikan kepada sistem untuk melakukan

deteksi dini gangguan jaringan *distributed denial of service (DDoS)* menggunakan metode Shannon *entropy*. Berikut beberapa penjelasan mengenai tahap pengujian sebagai berikut:

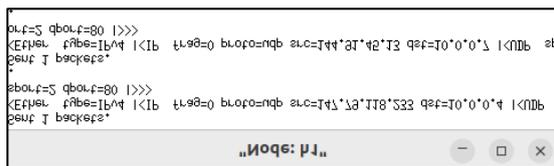
3.5.1. Launch Traffic

Tahap *launch traffic* dilakukan setelah pemilihan *interface* yang akan di *capture* pada *wireshark*, selanjutnya adalah menjalankan *command* “*python Traffic.py -s 2 -e 9*” pada *xterm* terminal di node H1 atau host1 untuk menjalankan trafik, seperti pada gambar 4.



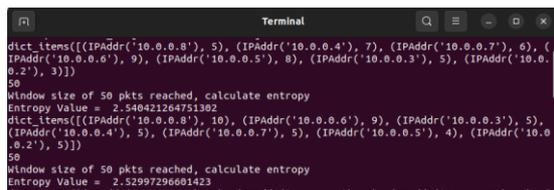
Gambar 4. Tampilan *Launch Traffic*

Setelah *command* “*python Traffic.py -s 2 -e 9*” dijalankan, node H1 akan mengirim paket secara acak ke semua node yang ada di dalam jaringan *SDN*. Paket dikirim sebanyak 2000 paket dengan *source ip address* dibuat secara acak, seperti pada gambar 5.



Gambar 5. Tampilan Proses *Launch Traffic*

Selanjutnya, saat paket dikirimkan oleh node H1, *Pox controller* melakukan kalkulasi nilai *entropy* pada setiap 50 paket yang masuk, seperti pada gambar 6.



Gambar 6. Tampilan Proses *Calculate Entropy Launch Traffic*

3.5.2. Launch Attack

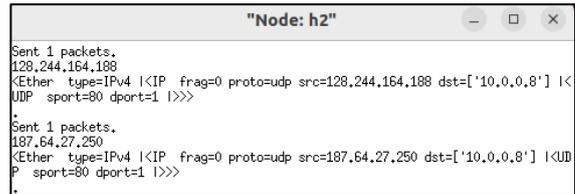
Setelah *launch traffic* selesai, tahap selanjutnya adalah melakukan pemilihan *interface* yang akan di *capture* pada *wireshark*, kemudian menjalankan *command* “*python Attack.py 10.0.0.8*” pada *xterm* terminal di node H2 atau host2 untuk menjalankan *attack* atau serangan *DDoS* ke node H8 dengan *ip address* 10.0.0.8, seperti pada gambar 7.



Gambar 7. Tampilan *Launch Attack*

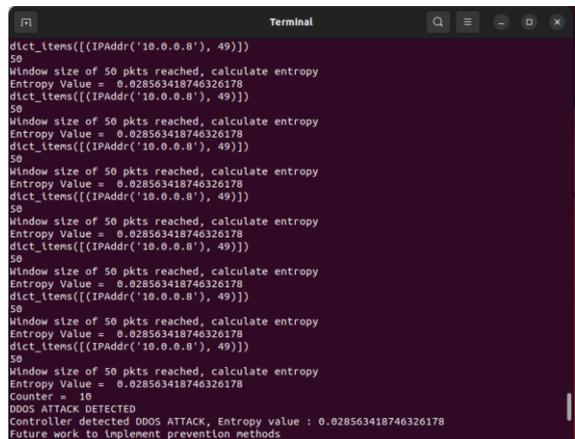
Setelah *command* “*python Attack.py 10.0.0.8*” dijalankan, node H2 akan mengirim paket secara terus menerus ke node H8. Paket dikirim sebanyak 500 paket dengan *source ip address* dibuat secara

acak untuk memalsukan *source ip address* aslinya, seperti pada gambar 8.



Gambar 8. Tampilan Proses *Launch Attack*

Selanjutnya, saat paket dikirimkan oleh node H2, *Pox controller* melakukan kalkulasi nilai *entropy* pada setiap 50 paket yang masuk, seperti pada gambar 9.



Gambar 9. Tampilan Proses *Calculate Entropy Launch Attack*

3.5.3. Hasil Pengujian Trafik Normal

Setelah melakukan pengujian trafik normal diatas, maka didapatkan hasil dengan sebanyak 40 pengujian. Dari setiap 50 paket yang masuk, sistem memulai menghitung nilai *entropy*, kemudian dikomparasi dengan nilai ambang batas. Nilai ambang batas yang digunakan adalah nilai ambang batas yang ditentukan oleh kalkulasi nilai *entropy* pada *pre-processing*. Pada penelitian ini ambang batas yang digunakan adalah ambang batas dari parameter *Dst IP_encoded* yaitu 0,0325 atau dibulatkan menjadi 0,033. Jika nilai *entropy* lebih besar dari nilai *entropy* ambang batas, maka trafik dinyatakan sebagai trafik normal yang ditujukan pada Tabel 9.

Tabel 9. Hasil Pengujian Trafik Normal

No	Paket	Nilai Entropy	Ambang Batas	Hasil (Entropy > Ambang Batas)
1	50	2,540421264751302	0,033	Normal
2	50	2,52997296601423	0,033	Normal
...
39	50	2,467853327389322	0,033	Normal
40	50	2,470687516390848	0,033	Normal

3.5.4. Hasil Pengujian Trafik DDoS

Selanjutnya setelah melakukan pengujian trafik DDoS dengan 2 (dua) serangan, maka didapatkan hasil dengan sebanyak 80 pengujian dengan masing-masing trafik sebanyak 40 pengujian. Dari setiap 50 paket yang masuk, sistem memulai menghitung nilai *entropy*, kemudian di komparasi dengan nilai ambang batas yang didapat dari parameter *Dst IP_encoded* yaitu 0,0325 atau dibulatkan menjadi 0,033. Jika nilai *entropy* lebih kecil dari nilai *entropy* ambang batas, sistem akan melakukan iterasi sebanyak 10 kali, dan jika dalam 10 kali iterasi tersebut nilai *entropy* masih dibawah ambang batas, maka trafik dinyatakan sebagai trafik DDoS atau terdeteksi serangan DDoS yang ditunjukkan pada Tabel 10.

Tabel 10. Hasil Pengujian Trafik DDoS

No	Paket	Nilai Entropy	Ambang Batas	Iterasi	Hasil (Entropy < Ambang Batas)
1	50	0,0285634187 46326178	0,033	10	DDoS Detected
2	50	0,0285634187 46326178	0,033	10	DDoS Detected
...
7	50	0,0285634187 46326178	0,033	10	DDoS Detected
8	50	0,0285634187 46326178	0,033	10	DDoS Detected

3.6. Evaluasi Hasil

Hasil dari pengujian yang telah dilakukan pada penelitian ini dengan menggunakan metode shannon *entropy* terhadap simulasi trafik normal dan DDoS, selanjutnya adalah dengan mengevaluasi hasil yang telah didapatkan dari pengujian dengan menggunakan *confusion matrix* yang ditunjukkan pada Tabel 11.

Tabel 11. Nilai Entropy Parameter

Prediksi Aktual	Trafik Normal	Trafik DDoS
Trafik Normal	40	0
Trafik DDoS	0	8

Sehingga dari data tabel di atas dapat dihitung nilai akurasi, presisi, dan *recall* nya sebagai berikut:

$$Akurasi = \frac{40+8}{40+8+0+0} \times 100\% = 100\% \quad (1)$$

$$Presisi = \frac{40}{0+40} \times 100\% = 100\% \quad (2)$$

$$Recall = \frac{40}{0+40} \times 100\% = 100\% \quad (3)$$

Dari hasil evaluasi terhadap data uji didapat bahwa metode shannon *entropy* dapat melakukan

pendeteksian dini dengan tingkat akurasi, presisi dan *recall* sebesar 100%.

3.7. PEMBAHASAN

Hasil penelitian diatas menunjukkan bahwa metode Shannon *Entropy* yang diterapkan untuk mendeteksi trafik normal dan DDoS memberikan hasil yang sangat memuaskan. Evaluasi model dengan menggunakan *confusion matrix* pada Tabel 10 menunjukkan kinerja yang sangat tinggi, dengan nilai presisi dan recall mencapai 100%. Penting untuk diperhatikan bahwa akurasi 100% menunjukkan bahwa model berhasil mendeteksi semua jenis lalu lintas yang diuji, baik reguler maupun DDoS. Selain itu, nilai akurasinya adalah 100% yang berarti setiap prediksi kelas trafik normal dari model, semuanya sebenarnya trafik normal.

Selain itu, nilai pemulihan yang mencapai 100% menunjukkan kemampuan model dalam mendeteksi dan memulihkan semua kejadian lalu lintas umum yang nyata. Hal ini sangat penting dalam konteks deteksi DDoS, yang mana akurasi dan presisi tinggi merupakan faktor penting. Secara keseluruhan, hasil penelitian ini memberikan keyakinan bahwa metode Shannon *Entropy* merupakan cara yang efektif untuk mendeteksi serangan DDoS pada tahap awal dan memberikan kinerja yang optimal dalam hal presisi, akurasi, dan *recall*. Oleh karena itu, model ini dapat meningkatkan keamanan jaringan secara signifikan, memungkinkan deteksi cepat terhadap potensi ancaman, dan mengoptimalkan respons terhadap serangan DDoS.

4. KESIMPULAN

Metode Shannon *Entropy* berhasil melakukan deteksi DDoS dari paket yang masuk kedalam jaringan SDN. Dari pengujian yang dilakukan dari paket normal sebanyak 40 pengujian diketahui nilai *entropy* diatas ambang batas, sehingga trafik tersebut dikatakan sebagai trafik normal. Sedangkan dari pengujian yang dilakukan dari paket DDoS sebanyak masing-masing 40 pengujian, terdeteksi nilai *entropy* dibawah ambang batas, sehingga trafik tersebut dikatakan sebagai trafik yang terdeteksi DDoS.

Hasil evaluasi terhadap akurasi dan performa metode Shannon *Entropy* dalam deteksi dini potensi serangan DDoS pada jaringan SDN menggunakan *confusion matrix* menghasilkan nilai akurasi 100%, presisi 100% dan *recall* 100%.

DAFTAR PUSTAKA

- AHALAWAT, A. ET AL. 2019 'Entropy Based DDoS Detection and Mitigation in OpenFlow Enabled SDN', Proceedings - International Conference on Vision Towards Emerging Trends in Communication and Networking, ViTECoN 2019, pp. 1-5. Available at: <https://doi.org/10.1109/ViTECoN.2019.889>

- 9721.
- ALI, M.N. ET AL. 2023 'Low Rate DDoS Detection Using Weighted Federated Learning in SDN Control Plane in IoT Network', *Applied Sciences (Switzerland)*, 13(3). Available at: <https://doi.org/10.3390/app13031431>.
- BAWANY, N.Z. AND SHAMSI, J.A. 2019 'SEAL: SDN based secure and agile framework for protecting smart city applications from DDoS attacks', *Journal of Network and Computer Applications*, 145(April), p. 102381. Available at: <https://doi.org/10.1016/j.jnca.2019.06.001>.
- BOITE, J. ET AL. 2017 'Statesec: Stateful monitoring for DDoS protection in software defined networks', in 2017 IEEE Conference on Network Softwarization (NetSoft). IEEE, pp. 1–9. Available at: <https://doi.org/10.1109/NETSOFT.2017.8004113>.
- CUI, J. ET AL. 2018 TDDAD: Time-based detection and defense scheme against DDoS attack on SDN controller, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Springer International Publishing. Available at: https://doi.org/10.1007/978-3-319-93638-3_37.
- CUI, J. ET AL. 2019 'DDoS detection and defense mechanism based on cognitive-inspired computing in SDN', *Future Generation Computer Systems*, 97, pp. 275–283. Available at: <https://doi.org/10.1016/j.future.2019.02.037>.
- DEEPA, V., SUDAR, K.M. AND DEEPALAKSHMI, P. 2019 'Design of Ensemble Learning Methods for DDoS Detection in SDN Environment', in *Proceedings - International Conference on Vision Towards Emerging Trends in Communication and Networking, ViTECoN 2019*. IEEE, pp. 1–6. Available at: <https://doi.org/10.1109/ViTECoN.2019.8899682>.
- ELSAIED, M.S., LE-KHAC, N.A. AND JURCUT, A.D. 2020 'InSDN: A novel SDN intrusion dataset', *IEEE Access*, 8, pp. 165263–165284. Available at: <https://doi.org/10.1109/ACCESS.2020.3022633>.
- GIOTIS, K. ET AL. 2014 'Combining OpenFlow and sFlow for an effective and scalable anomaly detection and mitigation mechanism on SDN environments', *Computer Networks*, 62, pp. 122–136. Available at: <https://doi.org/10.1016/j.bjp.2013.10.014>.
- HONG, G.C., LEE, C.N. AND LEE, M.F. 2019 'Dynamic threshold for DDoS mitigation in SDN environment', 2019 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference, APSIPA ASC 2019, (November), pp. 1–7. Available at: <https://doi.org/10.1109/APSIPAASC47483.2019.9023229>.
- KALKAN, K. ET AL. 2018 'JESS: Joint Entropy-Based DDoS Defense Scheme in SDN', *IEEE Journal on Selected Areas in Communications*, 36(10), pp. 2358–2372. Available at: <https://doi.org/10.1109/JSAC.2018.2869997>.
- LANTZ, B. AND O'CONNOR, B. 2015 'A Mininet-based Virtual Testbed for Distributed SDN Development', *ACM SIGCOMM Computer Communication Review*, 45(4), pp. 365–366. Available at: <https://doi.org/10.1145/2829988.2790030>.
- LI, C. ET AL. 2018 'Detection and defense of DDoS attack-based on deep learning in OpenFlow-based SDN', *International Journal of Communication Systems*, 31(5), p. e3497. Available at: <https://doi.org/10.1002/dac.3497>.
- LI, R. AND WU, B. 2020 'Early detection of DDoS based on φ -entropy in SDN networks', *Proceedings of 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2020, (It nec)*, pp. 731–735. Available at: <https://doi.org/10.1109/ITNEC48623.2020.9084885>.
- MADDU, M. AND RAO, Y.N. 2024 'Network intrusion detection and mitigation in SDN using deep learning models', *International Journal of Information Security*, 23(2), pp. 849–862. Available at: <https://doi.org/10.1007/s10207-023-00771-2>.
- MOUSAVI, S.M. AND ST-HILAIRE, M. 2015 'Early detection of DDoS attacks against SDN controllers', 2015 International Conference on Computing, Networking and Communications, ICNC 2015, pp. 77–81. Available at: <https://doi.org/10.1109/ICCNC.2015.7069319>.
- NAOUS, J. ET AL. 2008 'Implementing an OpenFlow switch on the NetFPGA platform', *Proceedings of the 4th ACM/IEEE Symposium on Architectures for Networking and Communications Systems, ANCS '08*, pp. 1–9. Available at: <https://doi.org/10.1145/1477942.1477944>.

- NETSCOUT SYSTEMS (2019) 'NETSCOUT's 14th Annual Worldwide Infrastructure Security Report', Retrieved from Netscout, 14(SECR_005_EN-1901-WISR), p. 44. Available at: https://www.netscout.com/sites/default/files/2019-03/SECR_005_EN-1901-WISR.pdf.
- OMAR, T., HO, A. AND URBINA, B. 2019 'Detection of DDoS in SDN Environment Using *Entropy*-based Detection', 2019 IEEE International Symposium on Technologies for Homeland Security, HST 2019, pp. 1–6. Available at: <https://doi.org/10.1109/HST47167.2019.9032893>.
- PHAN, T. V. AND PARK, M. 2019 'Efficient distributed denial-of-service attack defense in sdn-based cloud', IEEE Access, 7(c), pp. 18701–18714. Available at: <https://doi.org/10.1109/ACCESS.2019.2896783>.
- RAJAN, D.M. AND ARAVINDHAR, D.D.J. 2023 'Detection and Mitigation of DDOS Attack in SDN Environment Using Hybrid CNN-LSTM', Migration Letters, 20(S13), pp. 407–419. Available at: <https://doi.org/10.59670/ml.v20is13.6472>.
- SAHOO, K.S. ET AL. 2018 'An early detection of low rate DDoS attack to SDN based data center networks using information distance metrics', Future Generation Computer Systems, 89, pp. 685–697. Available at: <https://doi.org/10.1016/j.future.2018.07.017>.
- SAHOO, K.S., TIWARY, M. AND SAHOO, B. 2018 'Detection of high rate DDoS attack from flash events using information metrics in software defined networks', 2018 10th International Conference on Communication Systems and Networks, COMSNETS 2018, 2018-Janua, pp. 421–424. Available at: <https://doi.org/10.1109/COMSNETS.2018.8328233>.
- SHANNON, C.E. 1948 'A Mathematical Theory of Communication', Bell System Technical Journal, 27(3), pp. 379–423. Available at: <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>.
- SINGH, J. AND BEHAL, S. 2020 'Detection and mitigation of DDoS attacks in SDN: A comprehensive review, research challenges and future directions', Computer Science Review, 37, p. 100279. Available at: <https://doi.org/10.1016/j.cosrev.2020.100279>.
- SOLICHIN, A. 2017 'Mengukur Kinerja Algoritma Klasifikasi dengan Confusion Matrix', Retrieved from Achmatim [Preprint]. Available at: <https://achmatim.net/2017/03/19/mengukur-kinerja-algoritma-klasifikasi-dengan-confusion-matrix/>.
- SUN, G. ET AL. 2019 'DDoS Attacks and Flash Event Detection Based on Flow Characteristics in SDN', Proceedings of AVSS 2018 - 2018 15th IEEE International Conference on Advanced Video and Signal-Based Surveillance [Preprint]. Available at: <https://doi.org/10.1109/AVSS.2018.8639103>.
- TANDON, R. 2020 'A Survey of Distributed Denial of Service Attacks and Defenses'. Available at: <https://doi.org/https://arxiv.org/abs/2008.01345v1>.
- TONKAL, Ö. ET AL. 2021 'Machine learning approach equipped with neighbourhood component analysis for ddos attack detection in software-defined networking', Electronics (Switzerland), 10(11). Available at: <https://doi.org/10.3390/electronics10111227>.
- TSAI, S.C. ET AL. 2017 'Defending cloud computing environment against the challenge of DDoS attacks based on software defined network', Smart Innovation, Systems and Technologies, 63, pp. 285–292. Available at: https://doi.org/10.1007/978-3-319-50209-0_35.
- WANG, R., JIA, Z. AND JU, L. 2015 'An *entropy*-based distributed DDoS detection mechanism in software-defined networking', Proceedings - 14th IEEE International Conference on Trust, Security and Privacy in Computing and Communications, TrustCom 2015, 1, pp. 310–317. Available at: <https://doi.org/10.1109/Trustcom.2015.389>.
- XUANYUAN, M., RAMSURREN, V. AND SEEAM, A. 2019 'Detection and mitigation of DDoS attacks using conditional *entropy* in software-defined networking', Proceedings of the 11th International Conference on Advanced Computing, ICoAC 2019, pp. 66–71. Available at: <https://doi.org/10.1109/ICoAC48765.2019.246818>.

