

FUZDETECT: SISTEMA DE DETECÇÃO E CLASSIFICAÇÃO DE ATAQUES DE NEGAÇÃO DE SERVIÇO

Data de aceite: 03/04/2023

Ariane Ventura

Programa de Pós Graduação em Informática (PPGI), Universidade Federal da Paraíba
João Pessoa-PB, Brasil

Vivek Nigam

Programa de Pós Graduação em Informática (PPGI), Universidade Federal da Paraíba
João Pessoa-PB, Brasil

Iguatemi Fonseca

Programa de Pós Graduação em Informática (PPGI), Universidade Federal da Paraíba
João Pessoa-PB, Brasil

RESUMO: Ataques de negação de serviço podem variar de acordo com sua natureza, porém todos eles têm o objetivo de impedir que o servidor alvo receba novas solicitações de usuários legítimos. Este artigo propõe o FuzDetect, um novo sistema que não apenas alerta quando um ataque está acontecendo, mas também o classifica. O sistema FuzDetect recolhe dados de um Rede Definida por Software e em seguida os repassa para um sistema de classificação com Lógica Fuzzy. Tal classificação é

capaz de se adaptar à rede dinamicamente, com o uso da Otimização por Enxame de Partículas. Nossos resultados, com diferentes tipos de tráfego, demonstraram a eficiência do método proposto.

PALAVRAS-CHAVE: SDN, DDoS, Lógica Fuzzy, PSO.

1 | INTRODUÇÃO

Ataques de negação de serviço, quando executados com várias máquinas agindo como atacantes, de forma distribuída, são reconhecidos como Ataques de Negação de Serviço Distribuídos (DDoS) - Distributed Denial of Service Attacks). Conforme o Cert. BR(1), estes ataques podem ser divididos em: **ataques de exaustão**, cujo objetivo é saturar a capacidade dos recursos computacionais (memória, processamento e outros) e **ataques volumétricos** que tentam exaurir a banda disponível do alvo. Este artigo propõe o FuzDetect cujas contribuições são: **detectar e categorizar ataques**, acima mencionados, por meio da Lógica Fuzzy. Em Lógica Fuzzy,

os valores entre o intervalo [0,1] são usados para representar graus de associação, diferentemente da lógica de conjuntos clássica. Seu principal benefício é aproximar-se ao comportamento de sistemas onde as relações numéricas são complexas (2). Uma outra contribuição é a **adaptação do classificador fuzzy à rede**, uma vez que cada rede possui suas particularidades de tráfego e isto é obtido por meio da Otimização por Enxame de Partículas (PSO - *Particle Swarm Optimization*). PSO tem sido usado com sucesso em outras aplicações onde os problemas são de alta complexidade (3). E por último, **coletar dados da rede de forma leve** (dados de entrada do classificador), sem inspeção de pacotes, por meio de fluxos de uma Rede Definida por *Software* (SDN - *Software Defined Networking*) (4).

Em Mondal *et al.* (5) é apresentado um esquema de detecção com Lógica Fuzzy, porém a quantidade de regras é alta (aumentando o tempo computacional), a quantidade de parâmetros analisados é baixa, facilitando falsos negativos e nenhum mecanismo é utilizado para que o sistema pudesse se adaptar à rede. Dickerson *et al.* (6) propõe um sistema de detecção de ataques DDoS, entretanto o mesmo utiliza inspeção de pacotes, além disso, os ataques detectados não são especificados, tampouco é apresentado algum mecanismo que torne o classificador adaptado à rede analisada.

2 | FUZDETECT - FUNCIONAMENTO

Nesta etapa foi montado um ambiente virtual com variações de tráfego similar a uma rede real. A partir deste tráfego, variáveis foram coletadas (por meio de fluxos SDN), estabelecidas e utilizadas como entrada pelo sistema.

a) **Estabelecimento das variáveis de entrada - Variância de portas (VP) e bytes (VB):** durante os ataques, a dispersão em função da média foi alterada, tanto quanto aos *bytes* como quanto a média de portas. **Porcentagem de bytes em portas (PBP):** foi identificado, ao longo dos experimentos, que existem variações na relação entre a média de portas e a média de *bytes*, de acordo com o tipo de tráfego. **Mediana de bytes (MB) e pacotes (MP):** as motivações no uso destas encontram-se no trabalho de Braga *et al.* (7).

b) **Sistema de classificação - Lógica Fuzzy:** Na Tabela I, as variáveis de entrada representam as variáveis mencionadas anteriormente e os seus respectivos conjuntos: A - alto, B - baixo e M - médio e as variáveis de saída são: AV - ataque volumétrico, AE - ataque de exaustão e TNM - tráfego não malicioso, estas últimas também com seus respectivos conjuntos. Seguem as regras usadas no sistema *Fuzzy* aqui proposto, conforme Tabela II. A conversão das siglas é a mesma da Tabela I e o arranjo destas regras foi feito de forma empírica, a partir de observações acerca do tráfego. De acordo com a Tabela II, na primeira linha, é definido que se **MP é baixa** e **VP é alta** ou **MB é alta** e **PBP é alta**, então, **AV: alta** chance de acontecer, **AE: chance baixa** e para **TNM: média** chance (siglas mencionadas anteriormente). No processo de saída das regras (*defuzzyficação*), é gerada uma

saída numérica, informando assim, as chances dos tipos de tráfego mencionados estarem ocorrendo.

Variáveis de Entrada					Variáveis de Saída		
VP	VB	MB	MP	PBP	AV	AE	TNM
B	B	B	B	B	B	B	B
M	M	-	-	-	M	M	M
A	A	A	A	A	A	A	A

Tabela I - VARIÁVEIS DE ENTRADA E DE SAÍDA E SEUS RESPECTIVOS CONJUNTOS

c) **Otimização do FuzDetect – PSO:** O PSO é utilizado a fim de tornar o classificador adaptado à rede, por meio de ajustes nos conjuntos *fuzzy* e isto é obtido por meio de tráfego previamente identificado. Quanto mais acertos na classificação do tráfego, por conjuntos testados, maior a chance destes serem usados no classificador. Para mais detalhes acerca do PSO no FuzDetect, consultar (12) (Seção 4.0.5 e 5.3.1).

Regras	Tráfego
$((MP - B \text{ AND } VP - A) \text{ OR } (MB - A \text{ AND } PBP - A))$	$(AV - A) (AE - B) (TNM - M)$
$((VP - A \text{ AND } VB - B) \text{ OR } (MP - B \text{ AND } PBP - B))$	$(AV - M) (AE - A) (TNM - B)$
$((VP - B \text{ OR } VP - M) \text{ AND } (MP - A)) \text{ OR } (MB - A \text{ AND } MP - A)$	$(AV - B) (AE - M) (TNM - A)$

Tabela II - REGRAS FUZZY DO FUZDETECT

3 I EXPERIMENTOS, RESULTADOS E CONSIDERAÇÕES FINAIS

Os *hosts* e *switches* virtuais que simularam clientes legítimos e atacantes foram executados no Mininet. Para a simulação de ataques volumétricos, utilizou-se o *dnssdrdos* (8) e o *Hping3* (9). Já para a execução de ataques de exaustão do serviço, o *Hping3* também. Por último, para simular conexões de clientes legítimos, foi utilizado o *Siege* (10) e um *script* HTTP foi criado usando a biblioteca Python, *Urllib3* (11) (nas referências destas ferramentas são apresentados detalhes sobre a configuração e parametrização das mesmas, respectivamente). Foram executados dois experimentos diferentes na topologia apresentada na Fig. 1. De acordo com a mesma, no experimento I, durante os ataques volumétricos (fluxo identificado por um redirecionador não pontilhado), o tráfego de ataque

se originou em S1, onde o atacante acessou servidores DNS com alto fator de amplificação e retornou a resposta ao alvo, no *switch* S5. Já no experimento II, durante os ataques por exaustão (redirecionador com linha pontilhada), o ataque se originou em S5 e possuiu como alvo um servidor *web* em S0. Demais *switches* da rede geraram exclusivamente tráfego legítimo (linha sem redirecionador e sem estar pontilhada), exceto os *switches* S0, S1, S4 e S5 que simultaneamente receberam e repassaram tráfego legítimo e de ataque, por experimento.

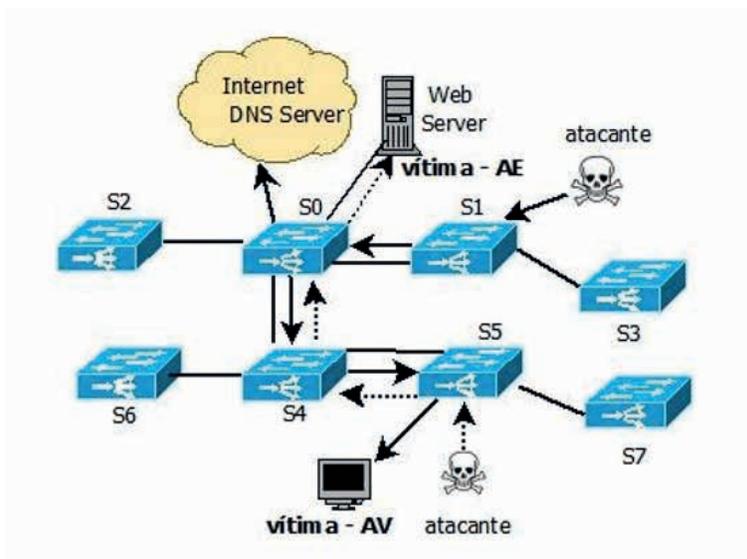


Figura 1. Topologia I

Na Tabela III, os resultados estão separados por experimento, podendo ser AV - ataques volumétricos ou AE - ataques de exaustão e por *switch*, de acordo com a Fig. 1. Para cada experimento / *switch* o valor da variável de saída esperada é destacado em negrito (devendo o valor desta ser maior que as demais, em todos os casos). Por exemplo, na Tabela III, no experimento I (AV), foi esperado que no *switch* S0 o tráfego de maior predominância identificado tenha sido o de ataque volumétrico e foi, com 64,5% de chance de ocorrer, já no experimento II (AE), esperou-se que em S1 o tráfego não malicioso tenha sido o de maior predominância e assim ocorreu (com 77% de chance de acontecer).

Neste trabalho, falsos positivos corresponderam a classificação errônea, em que em um *switch* trafegando unicamente dados legítimos, o classificador identifique este como de ataque. Já para falsos negativos, qualquer *switch* com tráfego de ataque, mas que não tenha sido considerado como tal. O FuzDetect foi preciso em todas as classificações, para todos os casos a saída em negrito sempre foi maior que as demais, indicando assim a precisão na identificação do tráfego.

experimento I - AV			experimento II - AE			Switch
AV	AE	TNM	AV	AE	TNM	
64,5%	31,8%	53%	24,7%	74,7%	50%	S0
74,7%	24,7%	24,7%	30%	16%	77%	S1
57%	42,9%	59,2%	25%	50%	75%	S2
50%	50%	59,2%	30%	18%	78%	S3
74,4%	24,7%	24,1%	20,1%	79,2%	50%	S4
73%	22%	53,7%	16,6%	82,6%	50%	S5
56,1%	43,5%	62%	25%	50%	80%	S6
44,4%	36,1%	63,3%	28,3%	50%	75%	S7

Tabela III - RESULTADOS - TOPOLOGIA I - EXPERIMENTO I E II

REFERÊNCIAS

- (1) CertBR - Ataques Distribuídos de Negação de Serviço (DDoS) - 2016. Disponível em: <https://www.cert.br/docs/whitepapers/ddos>. Acessado em: 1 de jul. 2018.
- (2) T. J. Ross. Fuzzy Logic: With Engineering Applications. Third Edition. West Sussex, United Kingdom: WILEY, 2010.
- (3) K. Chia-Nan and W. Chia-Ju. A PSO-Tuning Method for Design of Fuzzy PID Controllers. Journal of Vibration and Control, Los Angeles, CA, USA, v. 14, n. 3, p. 375-395, Marc, 2008.
- (4) T. D. Nadeau e K. Gray. SDN: Software Defined Networks: An Authoritative Review of Network Programmability Technologies. First Edition. Gravenstein Highway, Sebastopol: "O'Reilly Media, Inc.", 2013.
- (5) Mondal, H. Shekhar and Hasan, Md Tariq and Hossain, M. Bellal and Rahaman, M. Ekhlasar and Hasan e Rabita. Enhancing Secure Cloud Computing Environment by Detecting DDoS Attack Using Fuzzy Logic. Electrical Information and Communication Technology (EICT), 2017 3rd International Conference on, Khulna, Bangladesh, pages 1-4. IEEE, Dec, 2017.
- (6) J. E. Dickerson e J. A. Dickerson. Fuzzy Network Profiling for Intrusion Detection. Fuzzy Information Processing Society 2000. NAFIPS. 19th International Conference of the North American, Atlanta, GA, USA, pages 301-306. IEEE, Jul, 2000.
- (7) R. Braga, E. Mota e A. Passito. Lightweight DDoS Flooding Attack Detection using Nox/Openflow. Local Computer Networks (LCN) 2010, IEEE 35th Conference on, Denver, CO, USA, pages 408-415. IEEE, Oct, 2010.
- (8) DDoS Amplification Attacks - 2018. Disponível em: <https://www.noction.com/blog/ddos-amplification-attacks>. Acessado em: 19 de Ago. 2018.
- (9) Hping usage examples - 2009. Disponível em: <https://www.rationallyparanoid.com/articles/hping.html>. Acessado em: 19 de Ago. 2018.
- (10) Load Testing Web Servers - 2015. Disponível em: <https://www.linode.com/docs/tools-reference/tools/load-testing-with-siege/>. Acessado em: 19 de Ago. 2018.

(11) Urllib3 Documentation - 2018. Disponível em: <https://urllib3.readthedocs.io/en/1.5/#connectionpool>. Acessado em: 19 de Ago. 2018.

(12) A. Falcão, \emph{FuzDetect: Sistema de Detecção e Classificação de Ataques de Negação de Serviço}. 2018. 91f. Qualificação de Mestrado - UFPB, PB, 2018. <https://www.dropbox.com/s/91bl63tl9ppg36o/doc.pdf?dl=0>