

Técnicas de Processamento de Sinais e Telecomunicações

**Henrique Ajuz Holzmann
(Organizador)**

Henrique Ajuz Holzmann

(Organizador)

Técnicas de Processamento de Sinais e Telecomunicações

Atena Editora
2019

2019 by Atena Editora
Copyright © Atena Editora
Copyright do Texto © 2019 Os Autores
Copyright da Edição © 2019 Atena Editora
Editora Executiva: Prof^a Dr^a Antonella Carvalho de Oliveira
Diagramação: Karine de Lima
Edição de Arte: Lorena Prestes
Revisão: Os Autores

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Conselho Editorial

Ciências Humanas e Sociais Aplicadas

Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Prof^a Dr^a Cristina Gaio – Universidade de Lisboa
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná
Prof^a Dr^a Ivone Goulart Lopes – Istituto Internazionele delle Figlie de Maria Ausiliatrice
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Prof^a Dr^a Lina Maria Gonçalves – Universidade Federal do Tocantins
Prof^a Dr^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof^a Dr^a Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Prof^a Dr^a Vanessa Bordin Viera – Universidade Federal de Campina Grande
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Ciências Agrárias e Multidisciplinar

Prof. Dr. Alan Mario Zuffo – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano
Prof^a Dr^a Daiane Garabeli Trojan – Universidade Norte do Paraná
Prof. Dr. Darllan Collins da Cunha e Silva – Universidade Estadual Paulista
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Prof^a Dr^a Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

Ciências Biológicas e da Saúde

Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás
Prof.^a Dr.^a Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria
Prof. Dr. José Max Barbosa de Oliveira Junior – Universidade Federal do Oeste do Pará

Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Profª Drª Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande

Ciências Exatas e da Terra e Engenharias

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

Conselho Técnico Científico

Prof. Msc. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo
Prof. Dr. Adaylson Wagner Sousa de Vasconcelos – Ordem dos Advogados do Brasil/Seccional Paraíba
Prof. Msc. André Flávio Gonçalves Silva – Universidade Federal do Maranhão
Prof.ª Drª Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico
Prof. Msc. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro
Prof. Msc. Daniel da Silva Miranda – Universidade Federal do Pará
Prof. Msc. Eliel Constantino da Silva – Universidade Estadual Paulista
Prof.ª Msc. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia
Prof. Msc. Leonardo Tullio – Universidade Estadual de Ponta Grossa
Prof.ª Msc. Renata Luciane Polsaque Young Blood – UniSecal
Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)	
T255	Técnicas de processamento de sinais e telecomunicações [recurso eletrônico] / Organizador Henrique Ajuz Holzmann. – Ponta Grossa, PR: Atena Editora, 2019. Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-85-7247-449-8 DOI 10.22533/at.ed.498190807 1. Tecnologia da informação. 2. Telecomunicações. I. Holzmann, Henrique Ajuz. CDD 338.47
Elaborado por Maurício Amormino Júnior – CRB6/2422	

Atena Editora
Ponta Grossa – Paraná - Brasil
www.atenaeditora.com.br
contato@atenaeditora.com.br

APRESENTAÇÃO

A obra Técnicas de Processamento de Sinais e Telecomunicações está organizada de maneira a atender a temas atuais sobre a área de telecom e processamento de sinais de maneira sucinta e otimizada, sendo dividido em 17 capítulos sequenciais.

A transmissão de dados juntamente com suas vertentes representa um dos principais pilares para o progresso econômico de uma nação e para o atendimento de inúmeras necessidades da humanidade, estando presente nos mais diversos setores. Desenvolve-la de maneira eficiente é uma busca constante de grandes empresas e pesquisadores, buscando otimizar e agilizar o processo de troca de informações.

Produzir conhecimento nestas áreas é de extrema importância, a fim de gerar desenvolvimento e ampliar possibilidades nos mais diversos campos. Desta forma um compendio de temas e abordagens que facilitam as relações entre temas referentes a comunicação e processamento de sinais em diferentes níveis de profundidade em pesquisas, envolvendo aspectos técnicos, científicos e humanos é trazido nesta obra.

Boa leitura!

Henrique Ajuz Holzmann

SUMÁRIO

CAPÍTULO 1	1
ANTENA DE MICROFITA RETANGULAR PARA APLICAÇÃO EM 2,5 GHZ UTILIZANDO SUBSTRATO METAMATERIAL	
Almir Souza e Silva Neto Bruno Pontes Alves da Silva Matheus Mesquita Correa Humberto César Chaves Fernandes Ronilson Mendes Fonseca	
DOI 10.22533/at.ed.4981908071	
CAPÍTULO 2	7
BANDWIDTH ENHANCEMENT OF AN ULTRA WIDE BAND PLANAR INVERTED F-ANTENNA	
Pedro Paulo Ferreira do Nascimento Glauco Fontgalland Raymundo de Amorim Júnior Tagleorge Marques Silveira Rodrigo César Fonseca da Silva	
DOI 10.22533/at.ed.4981908072	
CAPÍTULO 3	14
COMPORTAMENTO DE MODELOS DE DIFRAÇÃO SOBRE MÚLTIPLOS GUMES DE FACA EM VHF E UHF	
Lorenço Santos Vasconcelos Gilberto Arantes Carrijo	
DOI 10.22533/at.ed.4981908073	
CAPÍTULO 4	27
ON-CHIP KOCH FRACTAL ANTENNA ARRAY FOR 60 GHZ ISM BAND APPLICATION	
Paulo Fernandes da Silva Júnior Ewaldo Eder Carvalho Santana Mauro Sérgio Pinto Filho Almir Souza e Silva Neto Elder Eldervitch Carneiro de Oliveira Paulo Henrique da Fonseca Silva Alexandre Jean René Serres Raimundo Carlos Silvério Freire	
DOI 10.22533/at.ed.4981908074	
CAPÍTULO 5	36
PROJETO E ANÁLISE DE UM ARRANJO LINEAR DE ANTENAS UTILIZANDO A CURVA FRACTAL DE KOCH	
Elder Eldervitch Carneiro de Oliveira Pedro Carlos de Assis Júnior Marcelo da Silva Vieira Rodrigo César Fonseca da Silva	
DOI 10.22533/at.ed.4981908075	

CAPÍTULO 6	48
FINDING REPEATER PLACEMENT FOR P2P WIRELESS LINKS WITH NLOS IN EXTREMELY MOUNTAINOUS REGIONS	
Alvaro Javier Ortega	
DOI 10.22533/at.ed.4981908076	
CAPÍTULO 7	60
NOVA ARQUITETURA DE DEMODULADOR $\pi/3$ -BPSK PARA OS SATÉLITES DO SISTEMA BRASILEIRO DE COLETA DE DADOS	
Flavia Vasconcelos Maia	
Antonio Macilio Pereira de Lucena	
Francisco de Assis Tavares Ferreira da Silva	
DOI 10.22533/at.ed.4981908077	
CAPÍTULO 8	73
PROPOSTA DE UM NOVO ALGORITMO QOS-AWARE PARA O ESCALONAMENTO <i>DOWNLINK</i> LTE-A EM CENÁRIOS DE TRÁFEGO MISTO: UMA COMPARAÇÃO DE DESEMPENHO	
Júnio Moreira	
Éderson Rosa da Silva	
Paulo Roberto Guardieiro	
DOI 10.22533/at.ed.4981908078	
CAPÍTULO 9	85
SERVIÇO DE L2VPN EM REDES DE <i>BACKBONE</i> IP: ESTUDO DE CASO DA REDECOMEP-RIO	
Pedro Henrique Diniz da Silva	
Natália Castro Fernandes	
Nilton Alves Jr.	
Márcio Portes de Albuquerque	
DOI 10.22533/at.ed.4981908079	
CAPÍTULO 10	101
SISTEMA DISTRIBUÍDO PARA DETECÇÃO DE AMEAÇAS EM REDES UTILIZANDO <i>DEEP LEARNING</i>	
Fábio César Schuartz	
Mauro Sérgio Pereira Fonseca	
Anelise Munaretto	
DOI 10.22533/at.ed.49819080710	
CAPÍTULO 11	113
UM MÓDULO DE DEFESA PARA ATAQUES DDOS NA CAMADA DE APLICAÇÃO USANDO ESTRATÉGIAS SELETIVAS	
Túlio Albuquerque Pascoal	
João Henrique Gonçalves Corrêa	
Vivek Nigam	
Iguatemi Eduardo da Fonseca	
DOI 10.22533/at.ed.49819080711	

CAPÍTULO 12	125
AN EMPIRICAL RATE BALANCED ALIEN XTALK MITIGATION METHOD FOR G.FAST SYSTEMS	
Diego de Azevedo Gomes	
Cláudio de Castro Coutinho Filho	
João Victor Costa Carmona	
Evaldo Gonçalves Pelaes	
DOI 10.22533/at.ed.49819080712	
CAPÍTULO 13	135
REPRESENTAÇÃO ESPARSA UTILIZANDO WAVELETS E VARIAÇÃO TOTAL APLICADOS AO PROCESSAMENTO DE SINAIS DE DESCARGAS PARCIAIS	
Paulo Vitor do Carmo Batista	
Hilton de Oliveira Mota	
DOI 10.22533/at.ed.49819080713	
CAPÍTULO 14	152
REDUÇÃO DE DIMENSÕES USANDO TRANSFORMADA DE KARHUNEN-LOÈVE EM SISTEMAS MIMO MASSIVO DISTRIBUÍDO COM <i>FRONTHAUL</i> LIMITADO	
Ricardo de Souza Cerqueira	
André Noll Barreto	
DOI 10.22533/at.ed.49819080714	
CAPÍTULO 15	167
WSN COVERAGE IMPROVEMENT WITH ROF IN BUS TOPOLOGY FOR SMART CITIES	
Raphael Montali da Assumpção	
Indayara Bertoldi Martins	
Frank Herman Behrens	
Omar Carvalho Branquinho	
Fabiano Fruett	
DOI 10.22533/at.ed.49819080715	
CAPÍTULO 16	179
MODELO ELETROMAGNÉTICO DE UM ARRANJO PLANAR DE NANODIPOLOS SOBRE PLANO DE OURO ATRAVÉS DA FUNÇÃO DE GREEN 3D	
André Felipe Souza da Cruz	
Nadson Welkson Pereira de Souza	
Karlo Queiroz da Costa	
DOI 10.22533/at.ed.49819080716	
CAPÍTULO 17	194
AVALIAÇÃO DE FADIGA MUSCULAR LOCALIZADA EM SINAIS ELETROMIOGRÁFICOS UTILIZANDO TAXA DE AMOSTRAGEM VARIÁVEL NO TEMPO	
Jean Kevyn Correia Pessoa	
Pedro Henrique Melgaço de Oliveira Martins	
Thiago Raposo Milhomem de Carvalho	
DOI 10.22533/at.ed.49819080717	
SOBRE O ORGANIZADOR	207

SISTEMA DISTRIBUÍDO PARA DETECÇÃO DE AMEAÇAS EM REDES UTILIZANDO DEEP LEARNING

Fábio César Schuartz

Universidade Tecnológica Federal do Paraná,
CPGEI
Curitiba - Paraná

Mauro Sérgio Pereira Fonseca

Universidade Tecnológica Federal do Paraná,
CPGEI
Curitiba - Paraná

Anelise Munaretto

Universidade Tecnológica Federal do Paraná,
CPGEI
Curitiba - Paraná

RESUMO: A detecção de ameaças na Internet é um fator essencial para manter a segurança de dados e informações. Um sistema de detecção de ameaças tenta prevenir que esses ataques ocorram através da análise de padrões e do comportamento do fluxo de dados na rede. Este trabalho apresenta uma extensão para a plataforma distribuída de detecção e análise de dados em grande fluxo, através do uso de deep learning para redução do espaço de características. A avaliação do sistema se baseia através da acurácia, do número de falsos positivos e de falsos negativos, onde cada classificador apresentou melhor acurácia ao utilizar 5 e 13 atributos. Ainda, o sistema apresentou menor número de falsos positivos e negativos, permitindo a detecção de ameaças

em tempo real sobre um grande volume de dados, com maior precisão.

PALAVRAS-CHAVE: Aprendizado de máquinas, aprendizagem profunda, grande volume de dados, sistema de detecção de ameaças, tempo real.

ABSTRACT: Detecting threats on the Internet is a key factor in maintaining data and information security. An intrusion detection system tries to prevent such attacks from occurring through the analysis of patterns and behavior of the data flow in the network. This paper presents an extension to the distributed large data flow detection and analysis platform through the use of deep learning to reduce the feature space. The evaluation of the system is based on accuracy, number of false positives and false negatives, where each classifier presented better accuracy using 5 and 13 attributes, besides having fewer false positives and negatives, allowing the detection of real-time threats over a large volume of data with greater accuracy.

KEYWORDS: Big data, deep learning, intrusion detection system, machine learning, real-time.

1 | INTRODUÇÃO

O crescimento no uso da Internet criou uma necessidade maior em proteger os dados

e informações guardadas em servidores centralizados e distribuídos, principalmente em sistemas acessados através de uma rede pública. Pessoas ganham benefícios e companhias geram lucro gerenciando seus recursos e transações através da rede, criando maiores oportunidades para usuários maliciosos roubarem informações pessoais e secretas. Segundo Leu et al. (2015), nos últimos anos diversas estatísticas mostram um número crescente de invasões reportadas no Symantec Global Internet Security Threat Report.

Um sistema de detecção de intrusão (IDS - Intrusion Detection System) é um sistema utilizado para monitorar as atividades de outro sistema ou de uma rede, procurando por atividades maliciosas e produzindo mensagens de alerta para a estação de controle, conforme Tan et al. (2014). Um IDS consiste de dois componentes: detecção por assinaturas e detecção por anomalias. A detecção por assinaturas é utilizada para procurar por ataques baseado em padrões extraídos de invasões conhecidas, enquanto a detecção por anomalias tenta descobrir ataques baseado no comportamento do tráfego que difere do padrão normal de comportamento.

Uma maneira de estudar os ataques ocorridos na rede é utilizar técnicas de aprendizagem de máquina, procurando por padrões no tráfego da rede. Um classificador pode estudar diversos exemplos de entradas que produzem resultados conhecidos, através de um aprendizado supervisionado, conforme Harbi e Bahri (2013). Porém, os ataques evoluem e podem não seguir os padrões de ataques anteriores. Assim, as técnicas de aprendizado não supervisionado podem apresentar melhores resultados, pois procuram por variações em padrões conhecidos, ao invés de classificar o tráfego em apenas uma categoria.

O aumento no volume, velocidade e variedade dos dados nas redes atuais demanda uma infraestrutura robusta de segurança. Monitorar e processar dados em altas taxas sem desperdiçar recursos é um enorme desafio atual, segundo Lopez et al. (2018). Uma área de pesquisa atual recebendo grande atenção é o de deep learning. Esta é uma sub-área avançada da aprendizagem de máquina, que permite sobrepujar as limitações do aprendizado superficial. Sua característica superior de camadas de aprendizagem pode resultar em desempenho superior ou equivalente, comparado às técnicas de aprendizado superficiais.

Este trabalho propõe uma expansão do sistema distribuído para detecção de ameaças em tempo real através da análise de grandes volumes de dados, pelo processamento por fluxo, apresentado no trabalho de Schuartz, Fonseca e Munaretto (2017). O objetivo é utilizar o método de deep learning na camada de pré-processamento de dados para obter uma redução no espaço de características dos dados, resultando assim, em maior acurácia na detecção de ameaças, com menor índice de falsos-positivos e falsos-negativos. Foram realizadas simulações para três casos: utilização dos 41 atributos existentes na base de dados (sem uso de deep learning), utilização da redução do espaço das características para 5 atributos e para 13 atributos. Resultados avaliados mostram que utilizando o método de deep learning

é possível obter resultados com maior acurácia e menor incidência de falsos-positivos e falsos-negativos. Para avaliação do sistema, utilizou-se um conjunto de dados com as classes marcadas, contendo dados normais e ataques, proveniente de uma base de dados de teste KDD'99, transformado em fluxos.

Este trabalho é dividido em cinco seções, onde a seção 2 apresenta os trabalhos relacionados. A seção 3 apresenta o sistema proposto. Os resultados obtidos são apresentados na seção 4. Por fim, a seção 5 finaliza o trabalho.

2 | TRABALHOS RELACIONADOS

Em 2017, um sistema de detecção de intrusão em redes (NIDS - Network Intrusion Detection System) baseado em anomalias foi construído por Van, Thinh e Sach (2017) utilizando técnicas de aprendizagem profunda (deep learning). Essa técnicas mostraram o grande poder dos modelos generativos com boa classificação, capazes de deduzir parte do seu conhecimento de dados incompletos e adaptar-se. O trabalho foi capaz de detectar intrusões baseadas em anomalias e classificá-las em cinco grupos, com acurácia baseada nas fontes de dados de rede.

Ainda em 2017, no trabalho de Kim e Aminanto (2017) são mostradas algumas limitações em IDSs anteriores que utilizam aprendizagem de máquina clássicas e introduzem o aprendizado de características, incluindo a construção, extração e seleção de características para superar os desafios. Também discutem algumas técnicas de deep learning e suas aplicações para utilização em IDS.

Em 2017, Alom e Taha (2017) apresentaram um trabalho sobre IDS utilizando técnicas de deep learning não-supervisionadas. As amostras de entrada são codificadas numericamente para a aplicação de técnicas não-supervisionadas, como Auto-Encoder (AE) e Restricted Boltzmann Machine (RBM), para extração de características e redução de dimensionalidade. Então é aplicado agrupamento iterativo k-means para aglomeração em um espaço dimensional menor com apenas 3 atributos.

Em 2017, Schuartz, Fonseca e Munaretto (2017) apresentaram uma proposta de uma plataforma distribuída para detecção de ameaças em tempo real, utilizando big data. A plataforma proposta é capaz de detectar diversos tipos de ataques com precisão acima de 90% e baixo número de falsos-positivos e falsos-negativos. O sistema utiliza 41 atributos da base de dados para o treinamento e detecção de ameaças, resultando em falha na detecção de alguns ataques em específicos, devido ao treinamento imparcial dos diversos tipos de ataques e pela baixa representatividade de tais ataques dentro da base de dados.

Em 2018, Shone et al. (2018) propôs uma técnica de deep learning para detecção de intrusões utilizando um auto-codificador não-simétrico de profundidade (NDAE - Nonsymmetric Deep Autoencoder) para aprendizado de características não-supervisionadas. O modelo de classificação proposto foi desenvolvido utilizando o TensorFlow e uma unidade de processamento gráfica (GPU - Graphics Processing

Unit) e foi avaliada através das bases de dados KDD Cup '99 e NSL-KDD.

Embora existam diversas técnicas e propostas na literatura para a detecção de intrusão, a maioria delas ainda não são eficientes o suficiente para trabalhar com um grande fluxo de dados (Big Data) em tempo real, enquanto outras propostas não apresentam acurácia suficiente. Este trabalho propõe a utilização do método deep learning para a redução do espaço de características dos fluxos de dados, permitindo assim o treinamento e a detecção de ameaças de maneira mais eficiente e precisos.

3 | ESQUEMA PROPOSTO

O sistema proposto visa expandir a plataforma aberta para coleta, distribuição, análise e processamento de dados proveniente de um fluxo de dados, apresentada em (SCHUARTZ; FONSECA; MUNARETTO, 2017). O processo consiste em, durante a fase de normalização das informações coletadas, utilizar o método de deep learning para reduzir o espaço de características dos dados, fornecendo maior acurácia na detecção de ameaças, maior rapidez no treinamento e detecção de anomalias, com redução no número de falsos-positivos e falsos-negativos.

O objetivo do método deep learning é aprender atributos hierárquicos de menor nível em atributos de maior nível. O método pode aprender características independentemente em múltiplos níveis de abstração e então descobrir funções de mapeamento complexas entre a entrada e a saída diretamente dos dados puros sem depender de atributos customizados por especialistas. Em abstrações de alto nível, os humanos normalmente não identificam as relações e conexões de uma entrada sensorial pura. Assim, a habilidade em aprender características complexas, também chamadas de extração de características, se torna necessária em vista do aumento na quantidade de dados (BENGIO et al., 2009).

A extração de características através do codificador automático empilhado (SAE - Stacked Auto Encoder) é capaz de reduzir a complexidade das características originais do conjunto de dados. Entretanto, além de ser um extrator de características, o SAE também pode ser utilizado para tarefas de classificação e aglomeração. É possível melhorar o processo de aprendizagem de características através da combinação da extração de características empilhadas com seleção de características com pesos. A extração de características do SAE é capaz de transformar as características originais em uma representação mais significativa ao reconstruir seus dados de entrada e fornecendo um meio de verificar a informação relevante nos dados capturados. O SAE pode ser eficientemente utilizado no aprendizado não-supervisionado em um conjunto de dados complexos.

A estrutura do SAE é apresentada na Figura 1. O primeiro auto-encoder recebe uma entrada e realiza uma redução nas características, procurando obter como saída, através de um decoder, a entrada original, pelo método de retropropagação (back-propagation). H_1 representa a camada escondida (hidden layer) do auto-encoder 1. Na

sequência, H_1 será a entrada do auto-encoder 2, que irá gerar H_2 através de processo semelhante e que será a entrada do auto-encoder 3, resultando em H_3 . Observando de uma percepção multi-camadas (multilayer), será o equivalente da entrada passar por 3 camadas escondidas, gerando a saída reduzida.

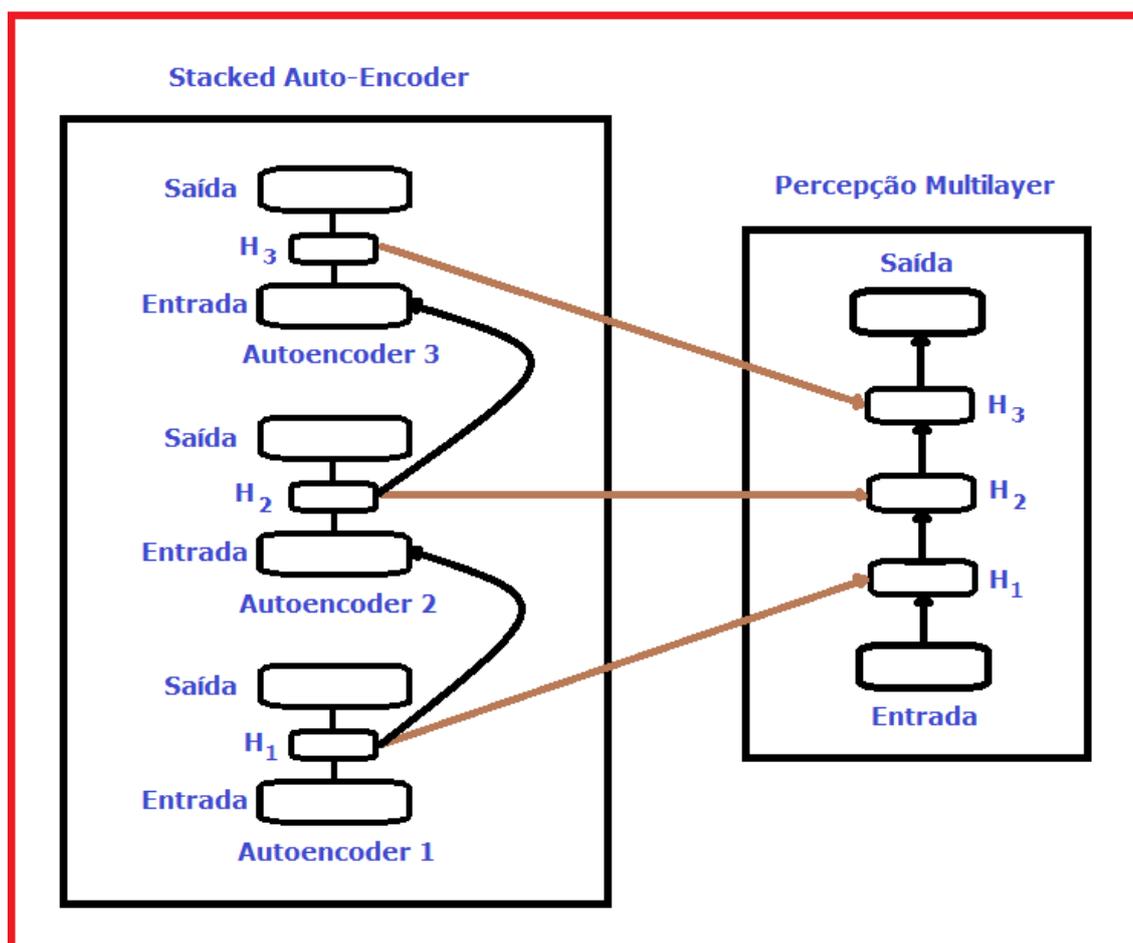


Fig. 1. Exemplo de uma estrutura Stacked Auto-Encoder, para três camadas. Fonte: autoria própria.

3.1 Auto-Encoder

Um auto-encoder é uma estratégia de rede neural profunda utilizada no aprendizado de características não-supervisionadas com codificação eficiente. O objetivo principal do AE é o aprendizado e representação (codificação) do dado, tipicamente com a finalidade da redução da dimensionalidade do dado. Esta técnica de AE consiste em duas partes: o codificador e o decodificador. Na fase de codificação, os mapas de amostras de entradas são reduzidas para um espaço de características de dimensão menor, contendo as características construtivas mais importantes. Este processo pode ser repetido até alcançar o espaço dimensional de característica desejada. Na fase de decodificação, são reconstruídas as características originais a partir de uma dimensão menor de características, através do processo de reversão. O diagrama conceitual do AE é mostrado na Figura 2. As transições de codificação e decodificação podem ser representadas por Φ e φ :

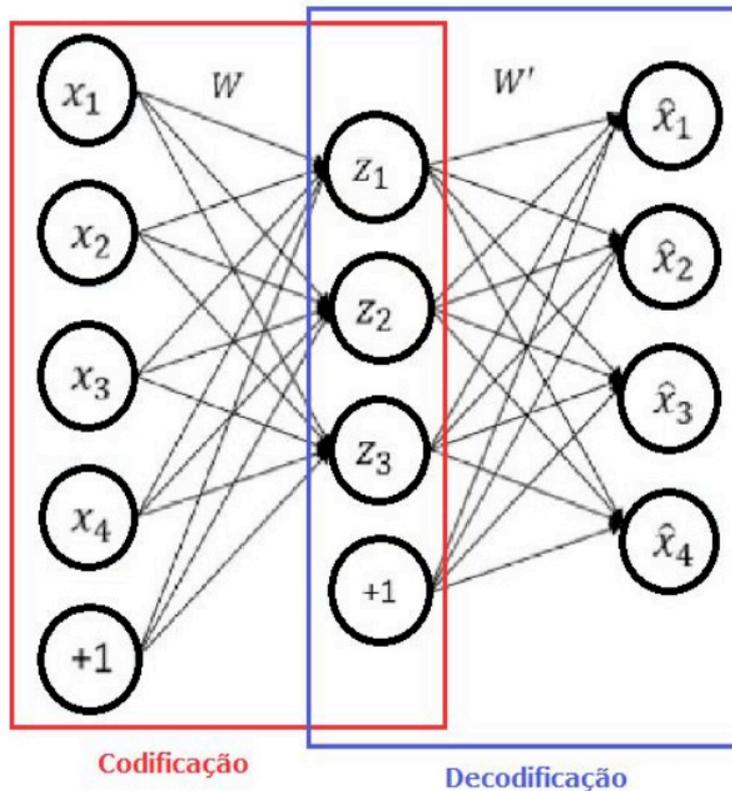


Fig. 2. Diagrama para um auto-encoder com as fases de codificação e decodificação. Fonte: autoria própria.

$$\phi: X \rightarrow F \quad (1)$$

$$\varphi: F \rightarrow X \quad (2)$$

$$\phi, \varphi = \operatorname{argmin}_{\phi, \varphi} \|X - (\phi, \varphi)\|^2 \quad (3)$$

Se considerarmos o AE mais simples com apenas uma camada escondida, onde a entrada é $x \in \mathbb{R}^d = X$, o qual é mapeada em $X \in \mathbb{R}^p = F$, então a expressão pode ser escrita na seguinte operação:

$$z = \sigma_1(W * x + b) \quad (4)$$

onde W é a matriz de peso e b é o bias. σ_1 representa a função de ativação, tal como uma sigmóide ou uma unidade linear retificada (RLU). Considerando z novamente mapeado ou reconstruído em x' , com a mesma dimensão de x , a reconstrução pode ser expressa como:

$$x' = \sigma_2(W' * z + b') \quad (5)$$

Estas técnicas podem ser treinadas com o mínimo de erros de reconstrução:

$$L = \|x - x'\|^2 \equiv \|x - \sigma_2(W' * \sigma_1(W * x + b) + b')\|^2 \quad (6)$$

Normalmente o espaço de características de F possui a menor dimensão do espaço de características de entrada X , que pode ser associada como a representação comprimida da amostra de entrada. No caso de um AE de multicamadas, a mesma operação será incorporada a medida que for necessária nas fases de codificação e decodificação.

3.2 Conjunto de Dados

A base de dados KDD'99 (LEE; STOLFO; MOK, 1999) é um conjunto de dados de referência que foi simulado em ambiente de rede militar em 1998 e derivado em conjunto de atributos em 1999. O pacote da base de dados foi reunido e pré-processado em 41 atributos. A base de dados contém quatro categorias de ataques diferentes (DoS, R2L, U2R e probing), sendo um total de 22 tipos de ataques na base de treinamento e 14 tipos de ataques extras na base de teste que não existem na base de treinamento.

3.3 Protótipo do Sistema Proposto

Inicialmente, a coleta de dados é feita em um único ponto da rede. Esses dados foram extraídos de uma base de dados KDD'99, amplamente utilizada e testada na comunidade. Os dados são pré-processados e caracterizados em fluxos compostos de 41 atributos, utilizados para detectar 22 tipos de ataques. Estes fluxos de dados são encaminhados para o SAE (Stacked Auto-Encoder), composto por três camadas escondidas que irão realizar a redução no espaço de características de entrada de 41 atributos para 5 e 13 atributos principais. Esses mapas reduzidos serão então publicados na rede.

Em outro ponto da rede, três unidades distintas de processamento de fluxos irão receber as informações publicadas na rede, agindo, cada um, como um assinante para o mesmo fluxo de dados. Cada unidade irá, então, alimentar esse fluxo para a topologia criada no Apache Storm. Dentro do Storm, é criado um classificador utilizando a ferramenta Weka. Os classificadores foram treinados utilizando um conjunto de dados de treinamento do KDD'99. Cada unidade possuirá um algoritmo de aprendizagem de máquina diferente e irá processar o fluxo de dados recebido, caracterizando o mesmo em um tipo específico de ataque ou em um fluxo normal de dados. Por último, os resultados obtidos por cada unidade de processamento são enviados para uma única interface de visualização, onde serão exibidos. Cada unidade realizará três modelos de treinamento e classificação. Inicialmente será alimentado um fluxo contendo os 41 atributos, sem o uso de deep learning. Em seguida, o processo será repetido, porém com um fluxo contendo 5 atributos. E por último, o processo será feito com um fluxo de dados contendo 13 atributos, sendo esses dois últimos processos utilizando o método

de deep learning para redução do espaço de características na base de dados.

Neste protótipo, foram escolhidos três classificadores presentes na ferramenta Weka:

a) Árvores de Decisão

Uma árvore de decisão, ou árvore de classificação, é um sistema de suporte à decisão que utiliza um gráfico na forma de árvore para a tomada de decisões e seus possíveis efeitos posteriores. O algoritmo é usado para aprender uma função de classificação que decide o valor de um atributo dependente (uma variável), considerando os valores dos atributos independentes de entrada, conforme Bhargava et al. (2013).

A árvore de decisão J48 é a implementação do algoritmo ID3 (Iterative Dichotomiser 3) pelo WEKA. Maiores detalhes do algoritmo pode ser encontrado no trabalho de Quinlan (2014).

b) Naive Bayes

Naive Bayes é uma técnica probabilística para construção de classificadores baseado no teorema de Bayes, onde assume-se uma forte independência entre os atributos.

Classificadores Naive Bayes são escalonáveis e podem processar um grande número de variáveis lineares (parâmetros) em uma tarefa de aprendizagem. Em uma única iteração dos dados de treinamento, o algoritmo calcula a probabilidade de distribuição condicional de cada atributo de um determinado rótulo, seguido pela aplicação do teorema de Bayes para determinar a distribuição da probabilidade condicional do rótulo, usado para a previsão do resultado, de acordo com Aggarwal (2014).

Maiores informações da implementação do Naive Bayes pelo WEKA pode ser encontrado no trabalho de John e Langley (1995).

c) Tabelas de Decisão

Uma tabela de decisões é uma tabela que associa condições com ações a serem tomadas, apresentando um resultado após seguir uma série de decisões relacionadas. Ela permite modelar um conjunto complexo de regras com suas ações correspondentes.

No trabalho de Kohavi (1995), podem ser encontradas maiores informações da Tabela de Decisão implementada pelo WEKA.

Neste protótipo, o objetivo é a prova de conceito da caracterização dos fluxos de dados em tempo real. Assim, não será utilizado o processamento em lotes e o armazenamento das informações em um banco de dados, que permitem a realimentação de parâmetros para os algoritmos se adaptarem em tempo real. Os parâmetros calculados no processamento off-line com os dados históricos servem

para ajustar o modelo de processamento em tempo real, dando ao sistema uma característica adaptativa, pois os parâmetros podem ser atualizados, se ajustando a novos padrões de uso.

4 | RESULTADOS NUMÉRICOS

O desempenho do sistema será avaliado através de duas métricas: a acurácia (percentual de acerto da classificação sobre a base de teste), e o número de falsos positivos e falsos negativos de cada classe.

A acurácia é a relação entre o número de amostras classificadas corretamente pelo número total de amostras. O número de falsos positivos indica quantas amostras normais foram classificadas como ataque e o número de falsos negativos indica quantas amostras de ataque foram classificadas como uma amostra normal.

Cada classificador será treinado e testado utilizando inicialmente os 41 atributos da base de dados KDD'99, sem o uso do deep learning para redução do espaço das características, servindo assim como a base de comparação. Depois, será repetido o treino e classificação utilizando 5 atributos e depois com 13 atributos. Os resultados serão, então, comparados pelas métricas estabelecidas.

Os resultados apresentam uma maior acurácia para a classificação de ataques em cada uma das unidades de processamento de fluxos criada quando se utilizam 13 atributos. O uso de apenas 5 atributos teve sua acurácia reduzida devido aos ataques do tipo R2L e U2L, pois o modelo SAE requer quantidades maiores de dados para realizar o aprendizado corretamente. Infelizmente, devido ao pequeno número de dados de treinamento disponíveis para esses ataques, os resultados obtidos não foram satisfatórios. Entretanto, no geral, mesmo utilizando 5 atributos, obteve-se melhores resultados comparados a não utilização de deep learning. A Tabela I apresenta a comparação entre os distintos algoritmos de classificação em termos de acurácia para os casos de 41, 5 e 13 atributos. Pode-se observar que com a redução dos atributos obtêm-se uma maior acurácia, em geral, na classificação de ataques.

Algoritmo Classificador	41 Atrib.	5 Atrib.	13 Atrib.
Árvores de Decisão	96,4980	96,7387	98,2162
Naive Bayes	90,2766	90,9497	96,6401
Tabelas de Decisão	95,8408	96,1994	98,0171

TABELA I

Comparação de acurácia (%) entre os algoritmos de classificação, utilizado 41, 5 e 13 atributos.

Os falsos positivos e falsos negativos são mostrados na Tabela II, a qual compara os diversos algoritmos utilizados pelas unidades de processamento de fluxo considerando 41, 5 e 13 atributos. As colunas da tabela mostram o número de ataques classificados corretamente (amostras classificadas como ataque, porém de

tipo diferente não são consideradas), o número de falsos positivos (conexão normal classificada como um ataque) e o número de falsos negativos (ataque classificado como conexão normal). Observa-se que, para um mesmo fluxo de dados, o algoritmo Naive Bayes apresenta um número muito maior de falsos-positivos, embora sua acurácia seja próxima dos outros algoritmos de classificação. Ainda, a classificação utilizando-se 5 atributos sofre novamente com a falta de dados para o treinamento correto dos ataques R2L e U2L, aumentando assim o número de falsos-positivos e falso-negativos comparado ao uso de 13 atributos.

Classificador	Ataques Certos	FP	FN
Árvores: 41 atrib.	3.768.413	684	1.489
Árvores: 5 atrib.	3.901.872	598	1.249
Árvores: 13 atrib.	4.429.091	323	881
Bayes: 41 atrib.	3.710.219	460.861	1.676
Bayes: 5 atrib.	3.881.231	442.893	1.393
Bayes: 13 atrib.	4.399.182	329.122	901
Tabelas: 41 atrib.	3.763.595	782	2.439
Tabelas: 5 atrib.	3.891.125	633	2.219
Tabelas: 13 atrib.	4.511.297	391	1.128

TABELA II

Resultados obtidos pelos algoritmos de classificação, em um total de 4.898.431 entradas, para 41, 5 e 13 atributos selecionados.

Para testar o desempenho do sistema proposto em tempo real, criou-se um ambiente virtual em uma máquina com processador Intel Core i7-4770S e 8 GB de memória RAM, executando o sistema operacional Linux Ubuntu 16. A medida de desempenho foi realizada pela média de fluxos processados por minuto pelas três unidades de processamento. O sistema foi capaz de processar aproximadamente 630 mil fluxos por minuto, com incerteza de 25 mil, dentro de um intervalo de confiança de 95%. Assim, cada ataque teve um tempo de detecção aproximado de 95 microssegundos.

5 | CONCLUSÕES

Este trabalho propõe um sistema de detecção de intrusão distribuído em tempo real, através do processamento de fluxos, utilizando deep learning para redução do espaço de características. O sistema apresentado utiliza ferramentas de código aberto que permite o processamento paralelo de diversos algoritmos de aprendizado de máquina, permitindo analisar um grande volume de dados em tempo real. A avaliação do sistema proposto é sobre a base de dados KDD'99, vastamente utilizada na comunidade, que foi transformada em um fluxo rotulado. Para a classificação dos dados, foram utilizados três unidades de processamento de fluxos, cada um com um algoritmo distinto de aprendizado de máquina - árvore de decisão, Naive Bayes e tabelas de decisão. Os resultados obtidos por cada algoritmo são, então, encaminhados para um visualizador.

Cada unidade de processamento de fluxos classificou 3 fluxos de dados diferentes. Inicialmente com 41 atributos (sem a utilização de deep learning, seguido por um fluxo de dados com 5 atributos e, por último, um fluxo de dados com 13 atributos. Utilizando-se deep learning para reduzir o espaço das características apresentou um melhor resultado em termos de acurácia e redução no número de falsos-positivos e falsos-negativos, embora ao utilizar-se apenas 5 atributos, notou-se uma falha na detecção de ameaças do tipo R2L e U2L devido a baixa representatividade desses ataques na base de dados, prejudicando o aprendizado. O sistema incorporando o método deep learning apresenta melhor acurácia em relação ao sistema sem redução de características, fornecendo uma solução para a detecção de ameaças em tempo real com maior desempenho.

Em trabalhos futuros, será proposta a comunicação entre as unidades de processamento de fluxos para troca de informações e a inclusão de diferentes fontes de fluxo de dados, sendo assim possível avisar os diferentes pontos da rede sobre um possível ataque à rede caso uma ameaça seja detectada por uma unidade. Será utilizado o deep learning não apenas para redução do espaço de características, mas também para a detecção de anomalias através da distribuição Gaussiana dos dados trafegados pela rede, permitindo a detecção de ataques desconhecidos.

REFERÊNCIAS

AGGARWAL, C. C. **Data Classification: Algorithms and Applications**. 1st ed. Chapman & Hall/CRC, 2014.

ALOM, M. Z.; TAHA, T. M. **Network intrusion detection for cyber security using unsupervised deep learning approaches**. 2017 IEEE National Aerospace and Electronics Conference (NAECON), Junho 2017, pp. 63–69.

BENGIO, Y. et al. **Learning deep architectures for ai**. Foundations and trends in Machine Learning, vol. 2, no. 1, pp. 1–127, 2009.

BHARGAVA, N. et al. **Decision tree analysis on j48 algorithm for data mining**. Proceedings of International Journal of Advanced Research in Computer Science and Software Engineering, vol. 3, no. 6, 2013.

HARBI, N.; BAHRI, E. **Real detection intrusion using supervised and unsupervised learning**. 2013 International Conference on Soft Computing and Pattern Recognition (SoCPaR), Dez. 2013, pp. 321–326.

JOHN, G. H.; LANGLEY, P. **Estimating continuous distributions in bayesian classifiers**. Proceedings of the Eleventh conference on Uncertainty in artificial intelligence. Morgan Kaufmann Publishers Inc., 1995, pp. 338–345.

KIM, K.; AMINANTO, M. E. **Deep learning in intrusion detection perspective: Overview and further challenges**. 2017 International Workshop on Big Data and Information Security (IWBIS), Set. 2017, pp. 5–10.

KOHAVI, R. **The power of decision tables**. Proceedings of the 8th European Conference on Machine Learning, ser. ECML '95. London, UK, UK: Springer-Verlag, 1995, pp. 174–189. [Online]. Disponível

em: <http://dl.acm.org/citation.cfm?id=645324.649649>.

LEE, W.; STOLFO, S. J.; MOK, K. W. **Mining in a data-flow environment: Experience in network intrusion detection**. Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 1999, pp. 114–124.

LEU, F. Y. et al. **An internal intrusion detection and protection system by using data mining and forensic techniques**. IEEE Systems Journal, vol. PP, no. 99, pp. 1–12, 2015.

LOPEZ, M. A. et al. **An evaluation of a virtual network function for real-time threat detection using stream processing**. 2018 Fourth International Conference on Mobile and Secure Services (MobiSecServ), Fev. 2018, pp. 1–5.

QUINLAN, J. R. **C4. 5: programs for machine learning**. Elsevier, 2014.

SCHUARTZ, F. C.; FONSECA, M. S. P.; MUNARETTO, A. **Sistema distribuído para detecção de ameaças em tempo real utilizando big data**. XXXV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBrT 2017, Set. 2017, pp. 472–476.

SHONE, N. et al. **A deep learning approach to network intrusion detection**. IEEE Transactions on Emerging Topics in Computational Intelligence, vol. 2, no. 1, pp. 41–50, Fev. 2018.

TAN, Z. et al. **Enhancing big data security with collaborative intrusion detection**. IEEE Cloud Computing, vol. 1, no. 3, pp. 27–33, Set. 2014.

VAN, N. T.; THINH, T. N.; SACH, L. T. **An anomaly-based network intrusion detection system using deep learning**. 2017 International Conference on System Science and Engineering (ICSSE), Julho 2017, pp. 210–214.

SOBRE O ORGANIZADOR

Henrique Ajuz Holzmann - Professor da Universidade Tecnológica Federal do Paraná (UTFPR). Graduação em Tecnologia em Fabricação Mecânica e Engenharia Mecânica pela Universidade Tecnológica Federal do Paraná. Mestre em Engenharia de Produção pela Universidade Tecnológica Federal do Paraná Doutorando em Engenharia e Ciência do Materiais pela Universidade Estadual de Ponta Grossa. Trabalha com os temas: Revestimentos resistentes a corrosão, Soldagem e Caracterização de revestimentos soldados.

Agência Brasileira do ISBN
ISBN 978-85-7247-449-8



9 788572 474498