

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
CURSO DE CIÊNCIA DA COMPUTAÇÃO

LUIZA DOS SANTOS EITELVEIN

**Implementação e Avaliação de um
Mecanismo de Detecção de Anomalias em
uma Ferramenta Smart Grid**

Monografia apresentada como requisito parcial para
a obtenção do grau de Bacharel em Ciência da
Computação

Orientador: Prof. Dr. Alberto Egon Schaeffer-Filho

Porto Alegre
2015

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitor de Graduação: Prof. Sérgio Roberto Kieling Franco

Diretor do Instituto de Informática: Prof. Luis da Cunha Lamb

Coordenador do Curso de Ciência de Computação: Prof. Carlos Arthur Lang Lisbôa

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

AGRADECIMENTOS

Meus mais sinceros agradecimentos ao Prof. Dr. Alberto Egon Schaeffer-Filho, por todo o auxílio e orientação ao longo deste projeto, por instigar o meu senso crítico e por nunca aceitar menos do que o meu melhor possível. Não é possível colocar em palavras tudo o que eu aprendi ao longo deste ano. Muito obrigada.

Meus profundos agradecimentos, também, aos colegas Alexandre Wermann e Marcelo Bortolozzo, pelo auxílio prestado com os aspectos técnicos do trabalho. Eu não teria conseguido sem a ajuda de vocês.

Agradeço também a todos os professores do Instituto de Informática da UFRGS. Este trabalho não seria possível sem tudo o que eu aprendi ao longo desses anos no INF. Foi uma experiência fantástica.

Por fim, muito obrigada a minha família por todo o suporte, e aos meus amigos e colegas futuros cientistas da computação, Eduardo Both e Ana Schwendler. Se é o meu nome que está escrito na capa, o crédito é todo de vocês.

RESUMO

Smart grids combinam redes de comunicação baseadas em ICT e redes elétricas com o objetivo de fornecer uma distribuição de energia mais eficiente e automatizada, além de permitir a introdução de fontes de produção de energia distribuídas, incluindo fontes renováveis. Sistemas SCADA, responsáveis pelo controle de dispositivos e coleta de informações ao longo de todo o smart grid, permitem o monitoramento em tempo real das informações de produção e consumo de energia. Todavia, esses sistemas estão vulneráveis a ataques cibernéticos, entre outras ameaças. Neste trabalho, apresentamos um Sistema de Detecção de Intrusão, baseado na detecção de anomalias no tráfego de rede, desenvolvido para a ferramenta ASTORIA, que permite a simulação de ambientes smart grid e a definição de ataques. A detecção de anomalias no tráfego é realizada através do algoritmo OCSVM, escolhido por permitir a classificação em classe única, com conhecimento apenas do tráfego normal da rede. Através dos experimentos realizados, com simulações de cenários de ataques DoS e anomalias no tamanho dos pacotes medidos, verificamos que o sistema proposto é capaz de identificar anomalias no tráfego da rede com uma acurácia superior a 97%, classificando corretamente todas as ocorrências de tráfego anômalo e apresentando uma taxa de até 3% de alarmes falsos.

Palavras-chave: Smart grid. SCADA. Segurança. Detecção de intrusão. Detecção de anomalias. OCSVM.

Implementation and Evaluation of an Anomaly Detection Mechanism in a Smart Grid Tool

ABSTRACT

Smart grids combine ICT based communication networks and electric grids with the goal of providing a more efficient and automatized energy distribution, besides allowing the introduction of distributed energy production sources, including renewable sources. SCADA systems, responsible for controlling devices and collecting information in the smart grid, allow real time monitoring of the energy production and consumption information. However, these systems are vulnerable to cyber attacks, among other threats. In this work, we present an Intrusion Detection System, based on network traffic anomaly detection, developed for the ASTORIA toolset, which allows the simulation of smart grid environments and the definition of attacks. The anomaly detection in the network traffic is performed by the OCSVM algorithm, which was chosen because it allows one class classification, only with knowledge of normal network traffic data. Through experiments we performed, using simulation scenarios containing DoS attacks and anomalies in the size of the measured packets, we verified that the proposed system is capable of identifying anomalies in the network traffic with an accuracy greater than 97%, correctly classifying all the occurrences of anomalous traffic and presenting a false alarm rate of up to 3%.

Keywords: Smart grid. SCADA. Security. Intrusion detection. Anomaly detection. OCSVM.

LISTA DE FIGURAS

Figura 2.1	Arquitetura de um smart grid.....	16
Figura 3.1	Estrutura da simulação com o framework ASTORIA.....	32
Figura 3.2	Arquitetura Conceitual do IDS Proposto.....	36
Figura 3.3	Componentes RTU e Analisador de Fluxos.....	37
Figura 3.4	Componente Classificador de Fluxos	38
Figura 4.1	Diagrama de Classes do IDS	40
Figura 4.2	Diagrama de Sequência do IDS.....	41
Figura 4.3	Topologia utilizada nos experimentos	43
Figura 4.4	Resultados dos experimentos com um ataque DoS de alta potência.....	46
Figura 4.5	Resultados dos experimentos com um ataque DoS de baixa potência	47
Figura 4.6	Resultados dos experimentos com inserção de anomalias no tamanho dos pacotes.....	48

LISTA DE TABELAS

Tabela 2.1 Comparação entre ferramentas de simulação	28
--	----

LISTA DE ABREVIATURAS E SIGLAS

ABD	Anomaly Based Detection
ADU	Application Data Unit
AMI	Advanced Monitoring Infrastructure
API	Advanced Programming Interface
DC	Dispositivo de Campo
DEI	Dispositivo Eletrônico Inteligente
HIDS	Host Based Intrusion Detection System
ICT	Information and Communication Technology
IDS	Intrusion Detection System
IHM	Interface Homem-Máquina
IP	Internet Protocol
JSON	JavaScript Object Notation
ML	Machine Learning
MTU	Master Terminal Unit
NIDS	Network Based Intrusion Detection System
OCSVM	One-Class Support Vectors Machine
PLC	Programmable Logic Controller
RTU	Remote Terminal Unit
SBD	Signature Based Detection
SCADA	Supervisory Control and Data Acquisition
SCI	Sistema de Controle Industrial
SVM	Support Vectors Machine
TCP	Transmission Control Protocol
UDP	User Datagram Protocol

SUMÁRIO

1 INTRODUÇÃO	10
1.1 Motivação	10
1.2 Objetivos	11
1.3 Contribuição	11
1.4 Estrutura do Trabalho	11
2 FUNDAMENTAÇÃO TEÓRICA	13
2.1 Smart Grids	13
2.1.1 Motivação.....	13
2.1.2 Arquitetura	14
2.1.2.1 Protocolos SCADA	15
2.1.3 Ameaças	17
2.2 Mecanismos de Detecção de Intrusão	18
2.2.1 Detecção de Intrusão.....	19
2.2.2 Classificação de Tráfego com Algoritmos de Aprendizado de Máquina.....	21
2.2.3 IDSs em sistemas SCADA.....	22
2.3 Ferramentas de Simulação	23
2.3.1 VirtuaPlant	23
2.3.2 mosaik	24
2.3.3 SCADASim.....	25
2.3.4 Modbus PLC Simulator	26
2.3.5 Comparação entre ferramentas de simulação	26
3 MODELAGEM E DESENVOLVIMENTO	29
3.1 Simulação da estrutura de smart grid com Framework ASTORIA	29
3.1.1 Integração entre as ferramentas	29
3.1.2 Simulação do ambiente smart grid.....	31
3.2 Mecanismo de Detecção de Intrusão	32
3.2.1 <i>One-Class Support Vectors Machine</i>	33
3.2.2 Sistema de Detecção de Intrusão para a ferramenta ASTORIA	35
4 IMPLEMENTAÇÃO E ANÁLISE DE RESULTADOS	39
4.1 Implementação do Protótipo	39
4.2 Execução dos Experimentos	42
4.2.1 Topologia e Configuração das Simulações	42
4.2.2 Introdução de Tráfego Anômalo	44
4.3 Análise dos Resultados	45
5 CONCLUSÃO E TRABALHOS FUTUROS	50
5.1 Resumo de Contribuições	50
5.2 Trabalhos Futuros	51
REFERÊNCIAS	52

1 INTRODUÇÃO

Smart grids são sistemas modernos de distribuição de energia, formados por redes elétricas tradicionais em conjunto com Sistemas de Controle de Supervisão e Aquisição de Dados – *Supervisory Control and Data Acquisition (SCADA)*, a fim de prover maior automação e segurança à rede, além de uma distribuição de energia mais eficiente e confiável (YAN et al., 2013). A agregação de capacidade computacional à rede elétrica, em conjunto com o fluxo bidirecional de energia e de informação, e com a instalação de infraestruturas avançadas de medição e controle, possibilitam diversos avanços em direção ao consumo e distribuição mais eficientes de energia elétrica. Smart grids podem receber energia de fontes distribuídas, incluindo fontes renováveis e pequenos produtores. Também é possível fornecer aos consumidores informações sobre como e quando seu consumo de energia é mais elevado, e oferecer opções de gerenciamento de consumo através do controle de dispositivos inteligentes presentes nas residências (BOU-HARB et al., 2013).

Na Seção 1.1, serão apresentadas as motivações para o desenvolvimento de mecanismos de segurança para smart grids. A Seção 1.2 apresenta os objetivos deste trabalho. As contribuições propostas são descritas na Seção 1.3. A Seção 1.4, por fim, descreve a estrutura na qual o trabalho está organizado.

1.1 Motivação

O acoplamento da rede elétrica à infraestrutura de comunicação e controle produz uma ampla variedade de benefícios ao sistema, como a integração de fontes de energia renováveis à rede, maior eficiência na distribuição de energia e maior automação do funcionamento da rede (YAN et al., 2013). No entanto, a utilização de uma rede de comunicação baseada em Tecnologia de Informação e Comunicação - *Information and Communication Technology (ICT)* na infraestrutura do smart grid introduz a vulnerabilidade à ataques cibernéticos (LI et al., 2012). É imprescindível que um smart grid seja seguro e robusto contra ataques, pois, sendo uma estrutura crítica, a interrupção do serviço pode cessar o fornecimento de energia elétrica à uma região inteira (AMIN; WOLLENBERG, 2005). Embora existam diversas tecnologias voltadas à segurança de redes baseadas em ICT, elas não são adequadas para garantir a segurança dos componentes de um smart grid (CARCANO et al., 2011). Dessa forma, é de grande importância desenvolver novos mecanismos de segurança projetados especificamente para sistemas SCADA e para os demais componentes de um smart grid.

1.2 Objetivos

Dado que a segurança e a confiabilidade são requisitos essenciais para a estrutura de comunicação de um smart grid, e que os mecanismos de segurança voltados para redes ICT tradicionais não são suficientes para garantir esses aspectos em um sistema SCADA, surge a necessidade de propor sistemas de segurança voltados especificamente para sistemas SCADA, a fim de tornar o smart grid mais seguro e robusto na presença de ataques cibernéticos.

O objetivo deste trabalho consiste em desenvolver um Sistema de Detecção de Intrusão - *Intrusion Detection System (IDS)* para uma ferramenta que simule o ambiente de execução de um smart grid utilizando um algoritmo de classificação do tráfego da rede de comunicação. A partir do uso de uma ferramenta para simular o tráfego de comunicação de um smart grid, o IDS deve ser capaz de acessar os fluxos de dados entre os componentes da rede e utilizar as informações obtidas para detectar a existência de ataques ao sistema.

1.3 Contribuição

O IDS proposto neste trabalho utiliza a ferramenta ASTORIA (WERMANN et al., 2016) para a simulação de um ambiente smart grid. As informações do tráfego da rede de comunicação são capturados pelo IDS e utilizadas para detectar anomalias no sistema, que podem indicar a ocorrência de um ataque. A detecção de anomalias é realizada através do *One-Class Support Vector Machine (OCSVM)*, um algoritmo de Aprendizado de Máquina voltado para a classificação de dados em uma única classe, utilizando atributos derivados do tamanho dos pacotes e da frequência dos pacotes entre os dispositivos da simulação.

A avaliação do IDS desenvolvido é feita através de experimentos com simulações de cenários com a ocorrência de ataques de Negação de Serviço - *Denial of Service (DoS)* e anomalias no tamanho dos pacotes de rede analisados.

1.4 Estrutura do Trabalho

No Capítulo 2, é apresentado o estado da arte dos smart grids, as motivações para o seu desenvolvimento, sua arquitetura e as ameaças que os afetam. Também são introduzidos os Sistemas de Detecção de Intrusão, suas principais classificações e alguns métodos utilizados para a detecção de ameaças em sistemas SCADA e smart grids. Além disso, são apresentadas

algumas ferramentas existentes para a simulação da estrutura de comunicação de um smart grid. O Capítulo 3 descreve as ferramentas utilizadas para a simulação do smart grid e propõe um IDS para o ambiente simulado baseado na classificação de tráfego através do algoritmo *One-Class Support Vector Machine*. A implementação de um protótipo do IDS proposto é descrita no Capítulo 4, juntamente com os experimentos realizados para a avaliação do IDS e a análise dos resultados obtidos. Finalmente, o Capítulo 5 apresenta as conclusões atingidas através do desenvolvimento do trabalho, com o resumo das contribuições e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, será estabelecida a fundamentação teórica dos tópicos abordados neste trabalho, afim de fornecer o entendimento dos conceitos e tecnologias que serão utilizados e apresentar o estado da arte em que se encontram. A seção 2.1 introduz os smart grids, seu propósito, sua arquitetura e as ameaças que os afetam. Na seção 2.2, são abordados os Sistemas de Detecção de Intrusão e seu uso em sistemas SCADA. Finalmente, a seção 2.3 apresenta as ferramentas existentes para simulação de ambientes smart grid e sistemas SCADA.

2.1 Smart Grids

Smart Grids combinam redes de energia elétrica com estruturas de comunicação, baseadas em Tecnologia de Informação e Comunicação - *Information and Communication Technology (ICT)*, que provêm um meio de troca de dados entre os componentes envolvidos no processo de produção, distribuição e consumo de energia. Como suas principais características, podem ser mencionados o fluxo bidirecional de energia elétrica entre produtores e consumidores e a incorporação de uma infraestrutura de comunicação, também bidirecional, que provê uma maior capacidade de automação à rede (YAN et al., 2013). Através de recursos e técnicas como monitoramento em tempo real, automação e controle de dispositivos, autoavaliação e autorecuperação, integração com de fontes de energia alternativas e mecanismos de segurança física e cibernética, Smart Grids imbuem a rede elétrica com maior confiabilidade, eficiência e segurança (LI et al., 2012).

A Seção 2.1.1 apresenta as motivações para o crescimento do uso de smart grids. Na Seção 2.1.2, é mostrada a arquitetura dos smart grids. A Seção 2.1.3 discute as ameaças às quais os smart grids são suscetíveis.

2.1.1 Motivação

A infraestrutura de comunicação dos Smart Grids incorpora uma grande diversidade de benefícios ao sistema de produção, distribuição e consumo de energia. Dados coletados pela Infraestrutura de Monitoramento Avançada - *Advanced Metering Infrastructure (AMI)* podem ser utilizados para melhorar a eficiência e o desempenho da distribuição de energia, identificando picos de consumo e pontos de desperdício na rede, além de fornecer aos usuários informações

detalhadas sobre seu consumo de energia, levando-os a um consumo mais eficiente. Uma maior automação da rede de distribuição leva à diminuição dos custos operacionais, pois seu funcionamento torna-se mais independente da mão de obra envolvida, que, por sua vez, pode executar suas tarefas com mais eficiência. A capacidade de comunicação entre diversas entidades e o fluxo bidirecional de energia possibilitam uma utilização cada vez maior de recursos de energia distribuídos, incentivando o surgimento de fontes de geração de energia renovável, como solar e eólica. Entidades consumidoras podem também ser produtoras de energia, permitindo que microprodutores forneçam energia à rede simultaneamente a grandes produtores (YAN et al., 2013).

A capacidade de autoavaliação e autoajuste em redes elétricas e outras infraestruturas críticas é de imensa importância. Devido à modernização das tecnologias utilizadas, essas infraestruturas têm seus sistemas cada vez mais interconectados, aumentando o risco de falhas em cascata de grandes proporções. A demanda crescente por uma distribuição de energia mais eficiente e confiável traz a necessidade de aperfeiçoar métodos e ferramentas que forneçam às redes elétricas a capacidade de se autoregular e sofrer o menor impacto possível na ocorrência de sobrecarga, mal funcionamento ou ataques maliciosos (AMIN; WOLLENBERG, 2005).

2.1.2 Arquitetura

Um smart grid é composto por duas estruturas principais: uma rede elétrica e uma rede de comunicação. A distribuição de energia é feita por redes elétricas tradicionais, operando nos dois sentidos. A rede de comunicação é formada por um Sistema de Controle de Supervisão e Aquisição de Dados – *Supervisory Control and Data Acquisition (SCADA)*. A produção de energia em um smart grid está distribuída em diversas fontes, que incluem usinas fixas e móveis e microprodutores. A energia elétrica é transportada das usinas de geração até as subestações de transmissão através de cabos de alta tensão, e então é transmitida, assim como a energia de outras fontes diversas, até as subestações de distribuição através de linhas de tensão variada. A partir das subestações de distribuição, finalmente, a energia é distribuída para consumo (BOUHARB et al., 2013).

O sistema SCADA realiza, de forma automatizada, o controle e monitoramento da rede. De maneira geral, os componentes básicos que constituem uma infraestrutura SCADA são Dispositivos de Campo (DCs), Unidades Terminais Remotas - *Remote Terminal Units (RTUs)* e Unidades Terminais Mestres - *Master Terminal Units (MTUs)*.

- DCs: Geralmente constituídos por RTUs ou Controladores Lógicos Programáveis - Programmable Logic Controllers (PLCs), DCs se conectam aos sensores e aos Dispositivos Eletrônicos Inteligentes (DEIs) para receber informações sobre produção e consumo de energia e enviar sinais de controle provenientes do sistema.
- RTUs: RTUs coletam dados de todos os DCs de uma determinada área e os encaminham para a MTU responsável pela região.
- MTUs: Os dados de todos os DCs de uma determinada região são enviados, através das RTUs, para uma MTU. A MTU, por sua vez, encaminha esses dados para um centro de controle regional, onde eles são monitorados e analisados.

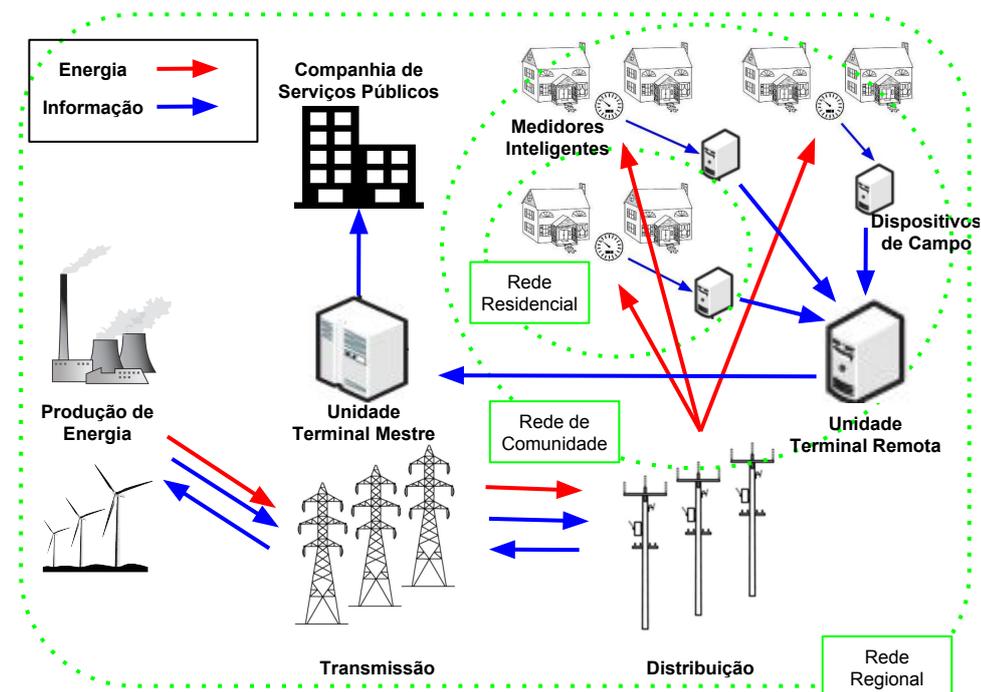
Sensores inteligentes instalados ao longo de toda a extensão da rede coletam, em tempo real, informações detalhadas sobre o consumo de energia, formando uma AMI (YAN et al., 2013). Um medidor inteligente em conjunto com um DC, DEIs e todos os consumidores que são atendidos por ele formam uma rede residencial. Redes residenciais e suas respectivas RTUs são agrupados em redes de comunidades que, por sua vez, são conectadas em uma área geográfica por uma rede regional. Os dados de todas as RTUs de uma rede regional são enviados para uma MTU no centro de controle, onde é realizado o controle e monitoramento da rede em cada região (LI et al., 2012). A figura 2.1 ilustra a arquitetura genérica da infraestrutura de um smart grid.

2.1.2.1 Protocolos SCADA

Os protocolos de comunicação utilizados em sistemas SCADA são projetados para garantir confiabilidade, operações em tempo real preciso e eficiência na comunicação entre componentes. Funções que prejudicam sua eficiência, incluindo funções de segurança, são desconsideradas na sua implementação, tornando-os menos seguros contra ameaças. Entre os diversos protocolos disponíveis para comunicação em sistemas SCADA, os mais amplamente utilizados são o Modbus e o DNP3 (DRIAS; SERHROUCHNI; VOGEL, 2015).

O Modbus é um protocolo do nível de aplicação, baseado no padrão requisição/resposta, desenvolvido para comunicação em tempo real entre controladores e dispositivos remotos. Apesar de inicialmente operar apenas sobre canais seriais, o protocolo foi estendido para funcionar em redes TCP/IP. Uma mensagem Modbus é composta por um cabeçalho de Protocolo de Aplicação Modbus, seguido por uma Unidade de Dados de Aplicação - *Application Data Unit (ADU)* do Modbus. O cabeçalho é formado pelos campos:

Figura 2.1 – Arquitetura de um smart grid



Fonte: Autor

- Identificador de transação: Permite o pareamento de requisições com suas respectivas respostas.
- Identificador de protocolo: Identifica o protocolo de aplicação encapsulado pelo cabeçalho. O protocolo Modbus é identificado pelo código 0.
- Comprimento: Tamanho, em bytes, da ADU.
- Identificador de unidade

A ADU é formada por um código de função, que indica o tipo de transação presente na mensagem, e uma área de dados. A mensagem Modbus é encapsulada no pacote TCP, e enviada pela porta 502 (DRIAS; SERHROUCHNI; VOGEL, 2015).

O DNP3 é um protocolo do nível de aplicação que implementa o modelo de comunicação mestre/escravo, desenvolvido para possibilitar uma comunicação confiável entre dispositivos SCADA geograficamente distribuídos. Surgiu como um protocolo serial, mas foi estendido para redes TCP/IP e UDP/IP. Para garantir a confiabilidade do protocolo, *Cyclic Redundancy Checks (CRCs)* são utilizados em todas as trocas de mensagens entre o terminal mestre SCADA e os dispositivos remotos, que são os escravos. O protocolo DNP3 suporta fluxos de comunicação bidirecionais, permitindo que dispositivos remotos iniciem comunicação com o mestre. Apesar do protocolo DNP3 atualmente suportar Autenticação por Chave Compartilhada e Au-

tentação Baseada em Certificado, a falta de tecnologias padronizadas de gerenciamento de chaves em sistemas SCADA faz com que sejam pouco utilizados (DRIAS; SERHROUCHNI; VOGEL, 2015).

Outros protocolos, utilizados em menor escala em sistemas SCADA, incluem o IEC 60870-5-101, publicado no padrão IEC TC57 para controle de telecomunicações (LIGUO et al., 2010), o IEC 60870-5-104, uma evolução do IEC 60870-5-101 que inclui a comunicação com redes TCP/IP (YANG et al., 2014b) e o PROFIBUS, definido pelo padrão europeu EN50170 para automação industrial, monitoramento e comunicação de dados e controle de dispositivos de campo (CHEN; SHI, 2011).

2.1.3 Ameaças

A introdução de uma estrutura de comunicação distribuída como parte essencial do funcionamento da rede elétrica tem como consequência submeter todo o sistema à possibilidade de ataques cibernéticos. A infraestrutura de comunicação, por ser desenvolvida sobre ICT, é vulnerável a diversos tipos de ataque, que podem ser utilizados para manipular dados ou obstruir o funcionamento do sistema (CHEN; CHENG; CHEN, 2012). Medidores inteligentes também têm riscos associados, estando vulneráveis a ataques de negação de serviço, roubo de informações de usuários e manipulação de dados (ASHFORD, 2011).

Uma taxonomia dos tipos de ataques cibernéticos em estruturas de comunicação de smart grids é apresentada em (LI et al., 2012). Os autores descrevem quatro tipos de ataques: ataques a dispositivos, ataques de dados, ataques de privacidade e ataques de disponibilidade de rede.

- Ataques a dispositivos: Ataques a dispositivos têm como finalidade obter controle sobre um elemento do smart grid e utilizá-lo para um objetivo malicioso. De modo geral, servem a dois propósitos: fornecer os meios para um ataque de dados ou de disponibilidade ou, caso o dispositivo afetado possua funções de controle críticas, causar danos físicos ao sistema.
- Ataques de dados: Ataques de dados configuram a tentativa de manipular os dados presentes na rede. Os dados manipulados podem ser informações de usuários ou sinais dos dispositivos de controle do smart grid. Seus usos variam de alterar dados de um usuário, para reduzir o valor da energia consumida, a eliminar sinais enviados por dispositivos de controle, para impedir o monitoramento e diagnóstico dos elementos da rede, o que pode

levar à interrupção do funcionamento do sistema.

- Ataques de privacidade: Ataques de privacidade têm o objetivo de obter informações privadas dos usuários. No caso dos smart grids, essas informações são os dados sobre o consumo de energia elétrica dos usuários, transmitidos pela rede de comunicação. Essas informações podem ser utilizadas para mapear dados privados sobre a rotina dos usuários, que podem ser utilizados para fins maliciosos.
- Ataques de disponibilidade: Ataques de disponibilidade de rede, ou ataques de negação de serviço, causam lentidão no tráfego de dados do smart grid através da sobrecarga da rede de comunicação e recursos computacionais. A velocidade da troca de dados é crítica para o funcionamento de um smart grid, e lentidão ou indisponibilidade do tráfego da rede podem causar prejuízos sérios aos seus usuários.

2.2 Mecanismos de Detecção de Intrusão

Garantir confiabilidade e segurança é um grande desafio no desenvolvimento dos smart grids. O desacoplamento das funcionalidades de controle e comunicação dos dispositivos elétricos e a modularização dos subsistemas leva a uma inevitável perda de confiabilidade. Componentes passam a ser originários de diferentes fabricantes, introduzindo margem à incompatibilidades e falhas de comunicação. A agregação de fontes de energia distribuída, incluindo usinas de geração instáveis, levam a fluxos de energia reversos e variações de voltagem. Ataques maliciosos podem ser direcionados tanto à rede elétrica física quanto à rede de comunicação (LI et al., 2012). Apesar da existência de uma vasta gama de tecnologias de segurança voltadas à ICT, essas medidas de segurança não são capazes de resguardar o sistema contra ataques desenvolvidos para atingir sistemas SCADA, medidores inteligentes e outros componentes do smart grid (CARCANO et al., 2011).

Sistemas de Detecção de Intrusão - *Intrusion Detection Systems (IDSs)* são aptos a detectar ataques lançados através de dispositivos internos do sistema que tenham sido comprometidos, reconhecendo o comportamento padrão de um sistema e identificando ataques a partir da premissa de que as ações de um atacante diferem do funcionamento convencional do sistema (LI et al., 2012). IDSs são caracterizados, de maneira geral, em dois tipos: Sistemas de Detecção de Intrusão baseados na Rede - *Network based Intrusion Detection Systems (NIDSs)* e Sistemas de Detecção de Intrusão baseados no Hospedeiro - *Host based Intrusion Detection Systems (HIDSs)*.

NIDSs são posicionados em pontos estratégicos ao longo da rede, afim de inspecionar o tráfego de dados entre todos os seus componentes. Os dados de tráfego podem ser, então, comparados a perfis de ataques maliciosos, para definir se os dados registrados se identificam com algum perfil de ataque conhecido, ou comparados a dados de tráfego normal da rede, com o objetivo de identificar tráfego anômalo, que pode indicar a ocorrência de um ataque. HIDSs são instalados em dispositivos individuais dentro da rede, e analisam o fluxo do tráfego que chega àquele componente. Assim como no NIDS, os dados de tráfego coletados são utilizados para identificar tráfego anômalo ou possíveis ataques.

Ao identificar tráfego anômalo ou possíveis ataques maliciosos, a principal tarefa do IDS consiste em registrar informações sobre os dados detectados e enviar um alerta para a central de controle do sistema. Sistemas de Detecção e Prevenção de Intrusões (SDPIs) são implementações de IDSs que utilizam técnicas para tentar suprimir ou bloquear ataques ao identificar tráfego suspeito. Entretanto, aplicar técnicas de prevenção de intrusão, que comumente consistem em desativar ou isolar o dispositivo sob ataque, pode ser complexo e arriscado em sistemas de infraestrutura crítica, que demandam alta disponibilidade.

A seguir, são discutidas as técnicas de detecção utilizadas em IDSs. A Seção 2.2.1 descreve a taxonomia dos métodos de detecção de instrusão. Na Seção 2.2.2, é discutido o uso de algoritmos de aprendizado de máquina para a classificação de tráfego, e é introduzido o algoritmo SVM, utilizado na implementação do IDS proposto neste trabalho. Por fim, a Seção 2.2.3 aborda técnicas utilizadas para a detecção de intrusão em sistemas SCADA.

2.2.1 Detecção de Intrusão

Em (AXELSSON, 2000), os mecanismos de detecção utilizados em IDSs são classificados em Detecção Baseada em Assinaturas - *Signature Based Detection (SBD)* e Detecção Baseada em Anomalias - *Anomaly Based Detection (ABD)*. Técnicas de SBD consistem em armazenar perfis de ataques maliciosos conhecidos, sem conhecimento do comportamento normal do sistema. Ao realizar a análise do tráfego, as informações são comparadas com os perfis de ataques existentes, a fim de identificar ameaças conhecidas. Métodos utilizados em SBD incluem:

- Detecção baseada em regras - *Rule-based detection*: Utiliza regras simples para descrever o comportamento do sistema sob um ataque. Quando os dados detectados se enquadram nas regras descritas, a intrusão é detectada.

- Modelagem de estados - *State-modeling*: Modela o comportamento do sistema através de uma máquina de estados, onde determinadas sequências de transições entre os estados identificam a intrusão.
- Reconhecimento de texto - *String matching*: Reconhece sequências de caracteres pré-definidas como comportamento intrusivo nos dados enviados e recebidos pelo sistema, ou em dados resultantes de processamentos do sistema.
- Sistema especialista - *Expert system*: É uma forma mais avançada da detecção baseada em regras. Utiliza uma série de regras e critérios, que descrevem uma situação de intrusão, para ponderar sobre o estado atual do sistema. São mais flexíveis que os métodos mais simples, porém com maior complexidade e menor performance.

Mecanismos de ABD se baseiam em reconhecer o comportamento normal esperado do sistema. Ao monitorar o tráfego da rede, os dados analisados são classificados em tráfego normal, se são condizentes com o comportamento esperado do sistema, ou anormal, se diferem do comportamento esperado. Em geral, os métodos utilizados para ABD são:

- Detecção programada - *Programmed detection*: Informações são inseridas no detector para que ele reconheça o comportamento normal do sistema, e modelar, através de regras ou de máquinas de estados, os critérios para que o comportamento seja considerado anormal.
- Sistemas de auto-aprendizado - *Self-learning systems*: O detector aprende através de exemplos a reconhecer o comportamento normal do sistema, observando o sistema em funcionamento por um período de tempo e construindo um modelo a partir dos dados coletados. Esta técnica utiliza modelos de detecção mais complexos, gerados por algoritmos de aprendizado de máquina.

Mecanismos de SBD são capazes de identificar de forma mais eficiente ameaças conhecidas ao sistema do que mecanismos de ABD, que visam apenas identificar tráfego de dados anômalo, de forma geral. Entretanto, a implementação de SBD necessita de dados específicos e precisos sobre cada ataque que terá um perfil incluído para identificação. Esses dados podem ser difíceis de obter para alguns sistemas, pois suas informações podem não estar disponíveis. Além disso, não é possível listar exaustivamente todos os ataques que podem ser lançados à um sistema, já que ataques existentes podem ser modificados e novos ataques podem surgir a qualquer momento. Dessa forma, mecanismos de SBD geralmente são utilizados como complemento para mecanismos de ABD, que podem ser implementados com conhecimento apenas sobre o tráfego normal do sistema.

2.2.2 Classificação de Tráfego com Algoritmos de Aprendizado de Máquina

A implementação de um IDS baseado em Detecção de Anomalias requer a realização da classificação, durante a execução, do tráfego de dados do sistema. Algoritmos de Aprendizado de Máquina - *Machine Learning (ML)* têm sido utilizados para a classificação de tráfego de dados por possuírem diversas características vantajosas para a tarefa. Enquanto técnicas de classificação de tráfego tradicionais dependem da inspeção do conteúdo de pacotes, mecanismos baseados em ML classificam os dados através de atributos que podem ser observados externamente, como tamanho dos pacotes e tempo entre a chegada de pacotes, criando padrões estatísticos. Há benefícios consideráveis nessa abordagem: o campo de dados do pacote deixa de ser obrigatoriamente visível (os dados podem estar criptografados, por exemplo), e o classificador não precisa conhecer a sintaxe dos dados nos pacotes de cada aplicação (NGUYEN; ARMITAGE, 2008). Os algoritmos de ML podem ser classificados em duas categorias:

- **Aprendizado supervisionado:** No aprendizado supervisionado, o algoritmo é treinado utilizando um conjunto de instâncias já classificadas, rotuladas com classes pré-definidas. O modelo gerado no treinamento é utilizado para classificar um conjunto de instâncias desconhecidas. Um algoritmo de aprendizado supervisionado é composto por duas fases principais. Na fase de treinamento, o algoritmo analisa o conjunto de instâncias de treinamento, já classificadas, e identifica relações entre os atributos e as classes, a fim de gerar um modelo de regras para a classificação. Na fase de teste, o modelo gerado durante a fase de treinamento é utilizado para identificar a classe de novas instâncias, ainda não classificadas. Existe uma vasta gama de algoritmos de aprendizado supervisionado, um exemplo sendo o algoritmo de classificação *Naive Bayes* (RISH, 2001).
- **Aprendizado não supervisionado:** Algoritmos de aprendizado não supervisionado não possuem uma fase de treinamento com classes já definidas. Em vez disso, implementam heurísticas para descobrir padrões entre os dados das instâncias e agrupá-las em *clusters* com características similares. Os grupos podem ser exclusivos, quando uma instância não pode pertencer a mais de um grupo, ou sobrepostos, quando as instâncias podem pertencer a diversos grupos. Os principais métodos de aprendizado não supervisionado são os algoritmos *k-means* (WAGSTAFF et al., 2001), clusterização incremental (ESTER et al., 1998) e clusterização baseada em probabilidade (FRALEY; RAFTERY, 2002).

Segundo (NGUYEN; ARMITAGE, 2008), a tarefa de classificação de tráfego utilizando ML requer, primeiramente, que atributos sejam definidos. Atributos são características dos

fluxos de pacotes entre os dispositivos da rede, como tamanho máximo e mínimo de pacote e tempo médio entre chegada de pacotes, que serão utilizados para selecionar instâncias de dados de tráfego. É necessário, então, treinar o algoritmo classificador, associando conjuntos de atributos com classes de tráfego definidas. Através da etapa de treinamento, o algoritmo gera o conjunto de regras que será utilizado para determinar a qual classe pertence uma determinada entrada. Finalmente, utilizando o modelo gerado no treinamento, o classificador pode receber dados de tráfego desconhecidos e identificar a que classe pertencem.

Support Vectors Machine (SVM) é um algoritmo de ML, definido em (CORTES; VAPNIK, 1995), baseado em aprendizado supervisionado e amplamente utilizado para a tarefa de classificação de dados. O algoritmo utiliza um conjunto de dados previamente classificados, chamado conjunto de treinamento, para definir um modelo de classificação, que utiliza regras geradas durante o treinamento para prever a que classe pertencem instâncias de dados desconhecidas. O SVM considera cada instância de dados como um vetor de n dimensões, e o modelo de classificação é construído de forma a separar as instâncias em suas respectivas classes com um único hiperplano de $n-1$ dimensões. A solução clássica do SVM encontra o hiperplano linear com a maior margem possível entre as classes. Entretanto, o SVM permite a utilização de funções de kernel não lineares, possibilitando gerar modelos com hiperplanos não lineares, que ampliam a distância máxima da margem entre as classes.

2.2.3 IDSs em sistemas SCADA

Existe uma ampla variedade de IDSs voltados para redes de comunicação tradicionais. Todavia, IDSs desenvolvidos para ICT falham em suprir os requisitos de segurança de sistemas SCADA, e mecanismos voltados para satisfazer as necessidades desses sistemas ainda não estão suficientemente amadurecidos. Portanto, novos mecanismos para detecção de ameaças devem ser desenvolvidos especificamente para a rede de sistemas SCADA.

Em (COUTINHO et al., 2009), os autores apresentam uma técnica de detecção de anomalias para centros de controle de infraestruturas críticas, utilizando o Algoritmo de Classificação de Conjuntos Irregulares - *Rough Sets Classification Algorithm*. O algoritmo foi capaz de identificar dados corrompidos introduzidos em um sistema de energia elétrica de seis barramentos. Uma abordagem à detecção de intrusão em sistemas SCADA baseada em Análise de Estado Crítico e Proximidade de Estados é analisada em (CARCANO et al., 2011). Um IDS multiagente é introduzido em (TSANG; KWONG, 2005), baseado no Modelo de Clusterização da Colônia de Formigas - *Ant Colony Clustering Model*, para detecção descentralizada de

anomalias em redes distribuídas. Os resultados obtidos apresentam alta acurácia na detecção e baixa taxa de falsos positivos. Em (YANG et al., 2013), os autores propõem e avaliam um IDS baseado em SBD para sistemas SCADA que utilizam o protocolo IEC 60870-5-104, utilizando um conjunto de regras para a identificação de ameaças conhecidas, e obtém resultados positivos nos testes com identificação de ameaças. Um framework para a detecção de intrusões é apresentado em (YANG et al., 2014a), que utiliza um sistema hierárquico para incluir IDSs distribuídos ao longo da estrutura do sistema SCADA. O framework utiliza regras e perfis para analisar o comportamento da rede, e os testes realizados obtiveram sucesso na detecção de ataques cibernéticos inseridos no sistema SCADA. Em (SAYEGH et al., 2014), um IDS específico para sistemas SCADA é proposto baseado na identificação de relações de tempo entre os pacotes da rede. O IDS foi testado utilizando dados reais do sistema SCADA de uma usina de energia, e os resultados obtiveram uma taxa alta de identificação de ameaças com poucos falsos positivos. Já em (ALI; AL-SHAER, 2013), os autores propõem um IDS para AMIs, coletando dados do AMI e modelando seu comportamento para comparação com especificações de configuração dos dispositivos. Os resultados são validados utilizando dados reais obtidos de medidores de uma AMI, obtendo uma alta taxa de detecção. Por fim, o framework AMIDS é apresentado em (MCLAUGHLIN et al., 2012) para a detecção de intrusão em AMIs, combinando registros de medição com dados de consumo para modelar o comportamento do AMI. Nos testes realizados, o framework identificou com sucesso tentativas de roubo de energia.

2.3 Ferramentas de Simulação

A fim de realizar a implementação e a avaliação do IDS proposto neste trabalho, é necessário utilizar uma ferramenta que permita a simulação da estrutura de comunicação de um smart grid. São apresentadas, a seguir, algumas ferramentas que possibilitam a simulação de tráfego de dados entre componentes SCADA. Algumas ferramentas suportam apenas simulações do fluxo de dados em componentes específicos, como o PLC, enquanto outras permitem a simulação de estruturas mais completas, com tráfego de dados entre diversos componentes.

2.3.1 VirtuaPlant

VirtuaPlant (VirtuaPlant, 2015) é um simulador de Sistemas de Controle Industriais (SCI). Possui uma interface gráfica chamada World View que simula o efeito das ações do

sistema de controle sobre um recurso virtual utilizando protocolo Modbus. O recurso é representado por uma fábrica que enche garrafas.

Um PLC é implementado sobre a biblioteca pymodbus, que roda em uma thread separada no componente World View e compartilha seu contexto, que contém registradores, entradas e valores, com as funções do World View para simular recursos sendo conectados ao controlador. A Interface Homem-Máquina (IHM) utiliza GTK3 e executa o cliente pymodbus em uma thread separada, que conecta com o servidor através de TCP/IP, obtendo leituras constantes dos valores do servidor, isto é, do PLC.

A ferramenta VirtuaPlant fornece uma variedade de scripts de ataque ao PLC. Entretanto, não permite a definição de novos dispositivos, não sendo possível a definição de novas topologias. Também não possibilita a modelagem de elementos da infraestrutura de comunicação, já que a simulação engloba apenas a leitura e escrita dos valores do controlador PLC.

2.3.2 mosaik

O mosaik (mosaik, 2015) permite usar diversos simuladores existentes em um contexto comum para realizar uma simulação coordenada de um cenário, que representa um conjunto de componentes de smart grid. Oferece uma API para os simuladores se comunicarem com ele e possui handlers para cada tipo de processo dos simuladores.

A ferramenta permite a modelagem de diferentes cenários envolvendo esses simuladores, possibilitando a criação de novos objetos e definição de novas topologias. A biblioteca SimPy é utilizada para a simulação coordenada de cenários, e a execução da simulação é feita executando passos em cada simulador ao longo do tempo. Cada simulador executa o seu próprio processo e laço de eventos, enquanto o Mosaik sincroniza esses processos e gerencia a troca de dados entre eles. Através da combinação com outros simuladores, é possível simular uma estrutura ICT.

O protocolo de comunicação entre o mosaik e os simuladores é definido por uma API. Existem duas versões da API: alto nível e baixo nível. A API baixo nível utiliza sockets TCP para estabelecer a comunicação entre o mosaik e os simuladores através da troca de mensagens JSON. A API alto nível, atualmente disponível nas linguagens Python e Java, fornece o encapsulamento dessa comunicação em uma classe abstrata, onde as mensagens trocadas entre os simuladores e o mosaik são implementadas como métodos.

A criação de cenários de simulação é feita por uma API que permite iniciar simuladores e instanciar modelos a partir deles, criando um conjunto de entidades. É possível conectar as

entidades entre si para estabelecer a troca de dados entre elas.

O gerenciador de simuladores é responsável por iniciar e gerenciar os processos dos simuladores e a comunicação entre eles. Permite iniciar novos processos de simuladores, conectar a processos que já estão em execução e, no caso de simuladores desenvolvidos em Python, também permite importar módulos de simuladores e executá-los durante a execução do processo.

Em (WERMANN et al., 2016), os autores apresentam o framework ASTORIA, desenvolvido a partir da integração do mosaik com um simulador de redes, que permite a especificação e execução de simulações customizadas de ambientes smart grids. Além disso, permite definir ataques, como Negação de Serviço - *Denial of Service (DoS)*, ao ambiente simulado e avaliar seu impacto na estrutura do smart grid.

2.3.3 SCADASim

A ferramenta SCADAsim (QUEIROZ; MAHMOOD; TARI, 2011) é um framework para construção de simulações SCADA. Possui um conjunto de módulos que representam os componentes SCADA, como RTUs, PLCs e MTUs, e implementa os protocolos Modbus TCP e DNP3. Permite a integração de componentes externos e componentes internos simultaneamente através do conceito de Gates, que são objetos que conectam um ambiente externo com o ambiente da simulação.

É baseado em 3 componentes principais: SSScheduler, SSGate e SSProxy. SSScheduler é um escalonador em tempo real que permite controlar e sincronizar mensagens recebidas. Gerencia uma lista de instâncias do componente SSGate, que são responsáveis por enviar e receber mensagens de um ambiente externo, garantindo a sincronização das mensagens entre dois ambientes. SSGate fornece conexão com o ambiente externo através de um protocolo, que é utilizado para se comunicar com os componentes SCADA externos. Atualmente os protocolos disponíveis são: ModbusGate, DNP3Gate e HTTPGate. SSProxy representa um dispositivo real ou aplicação externa que interage com os objetos simulados e com um SSGate, que direciona suas mensagens para componentes externos.

Os protocolos são gerenciados de dois modos. Os protocolos utilizados dentro do ambiente do simulador para comunicação entre componentes da simulação são chamados de protocolos simulados. Os protocolos utilizados para comunicação entre dispositivos e aplicações externas e os SSGates são chamados de protocolos originais. No ambiente interno da simulação, toda a comunicação entre os componentes utiliza versões simuladas dos protocolos SCADA. O framework possui uma biblioteca de protocolos SCADA originais e simulados, contendo: Mod-

bus TCP, DNP3 TCP e HTTP.

O simulador SCADASim permite, através dos módulos integrados de componentes SCADA, criar componentes e definir topologias, além de possibilitar a integração com componentes reais através da API. Possui, também, uma biblioteca com alguns tipos de ataques comuns à estruturas SCADA, como worm e DDoS. Não suporta, todavia, a modelagem de elementos de geração de energia, presentes em um smart grid.

2.3.4 Modbus PLC Simulator

O Modbus PLC Simulator (MODBUS..., 2009) é um simulador de PLC baseado na ferramenta Modbus Slaves. O Modbus Slaves é uma ferramenta que permite simular até 32 dispositivos simultaneamente. Os dados contidos nos dispositivos escravos (slaves) são acessíveis à aplicação mestre. Permite monitoramento de tráfego serial. Cada instância de escravo pode ser configurada para representar dados de um mesmo nodo ou de nodos diferentes.

A ferramenta suporta os protocolos Modbus TCP/IP, Modbus RTU (serial) e AB-DF1. Funciona criando uma thread de comunicação com interface para a API de comunicação e controla um bloco de RAM que funciona como a memória do PLC.

O Modbus PLC Simulator possibilita a simulação da troca de dados entre um dispositivo PLC, representado pela aplicação mestre, e outros dispositivos, não fornecendo suporte, entretanto, para os demais aspectos da comunicação ICT, como modelagem de topologias e de dispositivos da infraestrutura de rede.

2.3.5 Comparação entre ferramentas de simulação

O IDS visa realizar a detecção de anomalias em uma rede SCADA através da classificação dos dados de tráfego em tempo real. Para que esta solução seja possível, o único requisito estritamente necessário à escolha da ferramenta a ser utilizada é que ela deve ser capaz de simular o tráfego de dados entre componentes de uma estrutura SCADA. Caso contrário, não será possível realizar a classificação do tráfego entre componentes. Dito isso, outras características são interessantes para realizar uma simulação mais completa, que gere cenários mais próximos a um smart grid real, como a modelagem de componentes, a definição de topologias e a possibilidade de definir ataques para a simulação. A Tabela 2.1 apresenta uma comparação entre as ferramentas de simulação previamente abordadas utilizando os seguintes critérios:

- Simulação da infraestrutura ICT: A ferramenta permite a simulação de uma estrutura ICT. É um requisito obrigatório da ferramenta a ser escolhida, pois é necessário simular o tráfego de dados entre componentes SCADA.
- Simulação de produção e consumo de energia: A simulação de valores de produção e consumo de energia permite que o ambiente simulado seja mais próximo ao ambiente real de um smart grid.
- Elementos modeláveis: Quais elementos da simulação podem ser modelados. Quanto maior a flexibilidade para modelar elementos, mais próxima à estrutura de um smart grid podemos tornar a simulação.
- Protocolos de rede: A utilização de um dos protocolos comumente utilizados em redes de comunicação SCADA torna possível classificar os dados de tráfego de forma similar a um smart grid real.
- Modelagem de troca de pacotes de rede e informações de energia: Como é realizada a modelagem do tráfego de dados e do fluxo de energia elétrica na simulação. Idealmente, a modelagem deve ter um grau de abstração que torne o uso da ferramenta simples.
- Definição de novas topologias: A possibilidade de definir novas topologias possibilita a simulação de cenários com configuração semelhante à de um smart grid.
- Criação e simulação de ataques: Definir e executar ataques sobre a estrutura simulada é uma maneira eficiente de avaliar o IDS a ser implementado.

A partir da comparação entre as ferramentas, é possível analisar qual é mais adequada para o propósito deste trabalho. Apesar de permitirem a leitura e escrita de dados em componentes SCADA, os simuladores VirtuaPlant e Modbus PLC Simulator não possibilitam a simulação da infraestrutura ICT presente em um smart grid. Ambos os simuladores mosaik e SCADASim permitem a simulação da infraestrutura ICT do sistema SCADA, a definição de novas topologias e a modelagem de seus componentes de forma suficientemente simples. O mosaik, no entanto, permite a simulação da rede de energia elétrica presente em um smart grid, enquanto o SCADASim simula apenas a rede de comunicação. Apesar de a simulação de um ambiente smart grid através do mosaik requisitar a integração com um simulador de redes, o framework ASTORIA implementa essa integração e permite a simulação tanto da rede elétrica quanto da rede de comunicação presentes em um smart grid, além de fornecer ataques que podem ser executados sobre a simulação. Deste modo, o framework ASTORIA foi escolhido como ferramenta para simulação do ambiente smart grid neste trabalho.

Tabela 2.1 – Comparação entre ferramentas de simulação

	<i>VirtuaPlant</i>	<i>mosaik</i>	<i>SCADASim</i>	<i>Modbus PLC Simulator</i>
Simulação da infraestrutura ICT	N/D	API permite integração com simuladores de rede	Componente SSGate simula estrutura de comunicação	N/D
Simulação de produção e consumo de energia	N/D	Modelado pelo simulador PYPOWER	N/D	N/D
Elementos modeláveis	Leitura e escrita de valores do PLC	Infraestrutura SCADA, topologia da rede, consumo e geração de energia	Infraestrutura SCADA	Apenas tráfego de dados entre componentes e PLC
Protocolos de rede	Modbus	API para integração com simuladores de rede	Modbus e DNP3	Modbus
Modelagem de troca de pacotes de rede e informações de energia	N/D	Através dos simuladores de rede integrados	Modelagem realizada pelo componente SSGate	N/D
Definição de novas topologias	N/D	Permite definição de componentes e topologias	Permite definição de componentes e topologias	N/D
Criação e simulação de ataques	Inclui ataques que atingem os dados do PLC	Framework ASTORIA inclui definição e simulação de ataques à estrutura SCADA	Inclui biblioteca de ataques a componentes da estrutura SCADA	Possível desenvolver ataques para o componente PLC

Fonte: Autor

3 MODELAGEM E DESENVOLVIMENTO

O problema proposto por este trabalho consiste em implementar um mecanismo de detecção de intrusão e avaliá-lo utilizando uma ferramenta que simule a infraestrutura de um smart grid. Para isso, é necessário desenvolver um IDS e integrá-lo à ferramenta de simulação, de modo que o IDS possa receber os dados da simulação do smart grid e operar sobre eles.

Neste capítulo, serão apresentadas a modelagem e as ferramentas utilizadas para o desenvolvimento de uma solução para o problema proposto. A Seção 3.1 contém mais informações sobre o framework ASTORIA, utilizado para configurar as simulações do ambiente smart grid. A Seção 3.2 apresenta a modelagem do IDS proposto e descreve seu funcionamento.

3.1 Simulação da estrutura de smart grid com Framework ASTORIA

O Framework ASTORIA, descrito pelos autores em (WERMANN et al., 2016), permite modelar simulações de ambientes smart grid, definir e executar ataques nesses ambientes e avaliar seus resultados e o comportamento do sistema. O ASTORIA utiliza o mosaik para agregar os simuladores em um contexto comum, para que sua execução sincronizada possa criar um ambiente de smart grid. Para isso, é necessário conectar as ferramentas que farão a simulação dos componentes dos smart grid. A simulação da rede elétrica é realizada pelo PYPOWER, uma ferramenta nativamente integrada ao mosaik. Para realizar a simulação do componente de comunicação do smart grid, o ASTORIA implementa a integração do mosaik com o simulador de redes ns-3.

A seguir, é apresentado o framework ASTORIA, seu funcionamento e as simulações produzidas por ele. A Seção 3.1.1 descreve a integração entre as ferramentas que compõem o framework, os simuladores mosaik, ns-3 e PYPOWER. Na Seção 3.1.2, são mostradas a estrutura das simulações produzidas pelo framework.

3.1.1 Integração entre as ferramentas

A simulação de um smart grid utilizando o ASTORIA acontece através da integração das funcionalidades de três ferramentas: PYPOWER, que realiza a simulação da rede de energia elétrica, ns-3, que simula a rede de comunicação da estrutura SCADA, e mosaik, que sincroniza a execução das demais ferramentas.

O PYPOWER (PYPOWER, 2011), é uma ferramenta que implementa as funcionalidades do MATPOWER (ZIMMERMAN; MURILLO-SANCHEZ; THOMAS, 2011) na linguagem Python e permite simular cenários de fluxo de energia elétrica, fornecendo os dados de produtores e consumidores de energia. O PYPOWER permite a simulação de uma estrutura de rede elétrica e gera dados de produção e consumo em tempo real. Esses dados são fornecidos, através do mosaik, para a rede de comunicação. O fluxo de energia simulado pelo PYPOWER para cada nodo da rede elétrica é gerado a partir de perfis de produção e consumo de energia, já incluídos na ferramenta. Como o PYPOWER já é originalmente integrado ao mosaik, os dois já estão conectados e não há necessidade de implementar a troca de dados entre eles.

O ns-3 (ns-3, 2011), utilizado para compor o elemento de comunicação da simulação do smart grid, é um simulador de redes que funciona mantendo uma lista de eventos que devem ser executados, sequencialmente, em determinados tempos da simulação. Desenvolvido para fins de estudo e pesquisa, está disponível publicamente para uso, e sua estrutura suporta simulações tanto de redes baseadas em IP quanto de redes não baseadas em IP. Também permite a interação entre simulações e dispositivos reais, possibilitando o envio de pacotes gerados pelo simulador para dispositivos de uma rede real.

A integração do mosaik com o simulador ns-3, descrita em (WERMANN et al., 2016), foi feita através da mosaik Sim API, que possibilita a sincronização com outros simuladores. A comunicação entre as ferramentas é realizada através de sockets TCP e mensagens no formato JSON. As mensagens seguem o padrão requisição-resposta e são compostas por um cabeçalho, que carrega o número de bytes do corpo, e pelo corpo da mensagem, que contém o tipo, o identificador e o conteúdo da mensagem. O ns-3 inicia a conexão com o mosaik através de um socket TCP e, por meio dessa conexão, é realizado o envio das mensagens, através das quais o mosaik sincroniza a execução dos dois simuladores, PYPOWER e ns-3, e fornece os dados da rede elétrica para a rede de comunicação.

A execução do mosaik é baseada em passos. Após a fase de configuração, em que é feita a inicialização dos simuladores e a criação das instâncias de simulação, é enviada para o ns-3 uma mensagem a cada passo de execução, contendo os dados referentes à produção e ao consumo de energia, gerados pelo PYPOWER. Ao receber a mensagem contendo esses dados, o ns-3 executa a etapa atual da simulação, responde a mensagem com o instante em que a próxima etapa de simulação deve ser executada e entra em espera até receber a próxima mensagem.

3.1.2 Simulação do ambiente smart grid

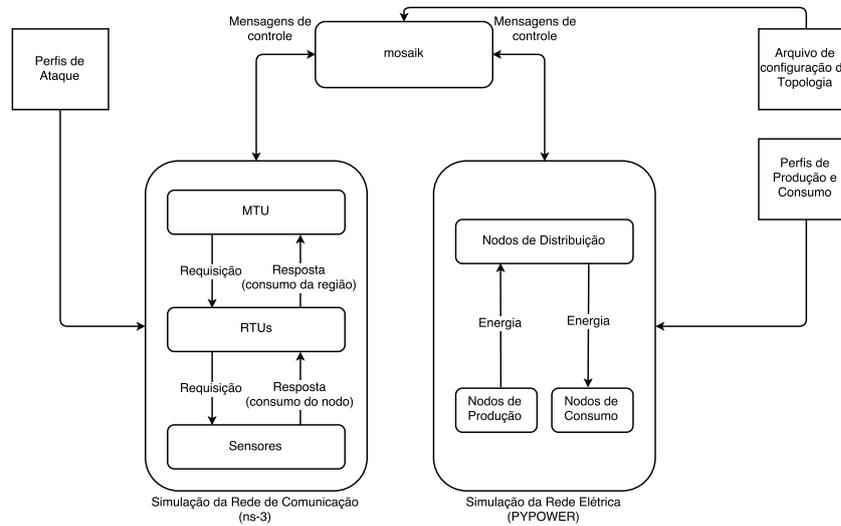
A rede de energia elétrica é composta por nodos de geração, consumo e distribuição de energia. Os dados de consumo de cada nodo são gerados pelo PYPOWER, que gera o fluxo de cada componente a partir de perfis de produção e consumo de energia presentes no simulador. A estrutura SCADA formada pela rede de comunicação é composta por sensores, RTUs e MTUs. Cada nodo de produção, distribuição e consumo presente na rede elétrica possui um nodo correspondente na rede de comunicação SCADA. Cada nodo de produção ou consumo está pareado com um sensor SCADA, enquanto os nodos de distribuição de energia estão pareados com as RTUs. As MTUs não possuem nenhum componente respectivo na rede elétrica, por serem um componente exclusivo da estrutura SCADA.

A Figura 3.1 mostra a estrutura dos componentes na simulação do ambiente smart grid com o framework ASTORIA. A comunicação entre os componentes SCADA acontece através do protocolo modbus. O mosaik fornece a cada sensor SCADA as informações sobre o consumo de energia do nodo da rede elétrica associado a ele. A cada passo de execução, as RTUs enviam requisições para todos os sensores conectados a elas, e os sensores respondem enviando os dados de consumo obtidos. A MTU envia requisições para todas as RTUs, que enviam respostas contendo as informações recolhidas de toda a sua região. A topologia da simulação é definida por um arquivo de configuração em que são instanciados os componentes MTU, RTUs e sensores, e as conexões entre os componentes. Todas as RTUs são conectadas à MTU, e cada RTU possui um conjunto de sensores conectados a ela.

O framework ASTORIA também oferece uma biblioteca de ataques, que podem ser executados sobre a simulação do smart grid. Os ataques podem ser instanciados através de perfis, que permitem a configuração de diferentes tipos de ataques. Os perfis de ataques são compostos pelos parâmetros:

- Tipo de Ataque: Tipo do ataque definido no perfil, como Negação de Serviço - *Denial of Service (DoS)*, que será executado na simulação.
- Nodo de Origem: Nodo da simulação do qual se origina o ataque.
- Nodo Alvo: Nodo da simulação que será atingido pelo ataque.
- Passo de Execução: Define a frequência e a intensidade do ataque. Em um ataque DoS, por exemplo, o passo de execução pode ser definido como 4 milissegundos, indicando que o nodo atacado receberá 250 pacotes por segundo.
- Tempo de Início: Horário de início do ataque na simulação.

Figura 3.1 – Estrutura da simulação com o framework ASTORIA



Fonte: Autor

- **Parâmetros Específicos:** Uma lista de parâmetros opcionais, específicos para determinados tipos de ataques, como o tamanho dos pacotes enviados pelo atacante, por exemplo.

O framework contém dois tipos de ataques definidos. O ataque DoS visa parar o funcionamento dos nodos atingidos através do envio de um grande volume de pacotes, e é implementado através de uma aplicação maliciosa que é instanciada nos nodos de origem, que recebe os parâmetros do perfil de ataque DoS. O ataque de Injeção de Software Malicioso é implementado por uma aplicação maliciosa que infecta uma RTU, também recebendo parâmetros do perfil de ataque correspondente. Quando dados da RTU infectada são requisitados pela MTU, a aplicação maliciosa responde informando dados de consumo incorretos para toda uma região. Entretanto, o framework e a biblioteca de ataques são extensíveis, e novos perfis de ataques podem ser definidos e implementados sobre a simulação do smart grid.

3.2 Mecanismo de Detecção de Intrusão

A incorporação de um IDS no sistema SCADA de um smart grid permite a rápida identificação de situações de risco, como ataques cibernéticos, que podem comprometer o funcionamento correto do sistema. Ao detectar rapidamente anomalias no comportamento do sistema, é possível se beneficiar de medidas responsivas de segurança, minimizando os danos causados pelo ataque ao sistema.

A seguir, são abordadas as técnicas utilizadas para o desenvolvimento do IDS implementado na ferramenta ASTORIA. Na Seção 3.2.1, é descrito o algoritmo Máquina de Vetores de Suporte de Uma Classe, utilizado neste trabalho, e a Seção 3.2.2 apresenta a modelagem do IDS desenvolvido para a ferramenta ASTORIA.

3.2.1 *One-Class Support Vectors Machine*

O algoritmo *One-Class Support Vectors Machine (OCSVM)*, proposto em (SCHOLKOPF; SMOLA, 2001), é um caso específico do algoritmo SVM para Classificação em Classe Única. Algoritmos de Classificação em Classe Única são treinados para reconhecer apenas uma classe de dados. Todas as instâncias do conjunto de treinamento pertencem a uma única classe e os dados analisados pelo algoritmo são classificados como pertencentes à classe (normais) ou não pertencentes à classe (anômalos).

A tarefa de classificação de dados utilizando o OCSVM consiste nos seguintes passos:

- **Obtenção do conjunto de treinamento:** Inicialmente é necessário definir um conjunto de instâncias de treinamento para gerar o modelo de classificação. O conjunto de treinamento é composto por uma lista de instâncias de dados, cada instância contendo uma lista de atributos predefinidos e os seus respectivos valores. Como o OCSVM realiza a classificação em uma única classe, todas as instâncias do conjunto de treinamento pertencem a mesma classe.
- **Treinamento do algoritmo:** A partir do conjunto de treinamento, o algoritmo gera um modelo de classificação. O modelo de classificação é composto por diversas regras, que permitem identificar se uma determinada instância pertence ou não à classe definida pelo conjunto de treinamento.
- **Classificação:** Após o treinamento, o algoritmo é capaz de classificar instâncias desconhecidas, ou seja, que não fazem parte do conjunto de treinamento. As instâncias de classificação possuem o mesmo formato que as instâncias de treinamento e contém os mesmos atributos, mas sua classe é desconhecida. O algoritmo utiliza o modelo de classificação, gerado na etapa de treinamento, para identificar as novas instâncias como pertencentes ou não à classe de dados representada.

Para a classificação do tráfego de rede, as instâncias representam informações sobre os fluxos da rede. Os fluxos caracterizam cada par de dispositivos presentes na rede que trocam pacotes entre si. Assim, os atributos utilizados nas instâncias consistem em métricas que des-

crevem o comportamento dos fluxos da rede. Não existe um consenso sobre a quantidade de atributos utilizados na classificação com o OCSVM, pois os resultados obtidos com diferentes conjuntos de atributos têm grande dependência do tipo de informações sendo representadas. Neste trabalho, serão considerados cinco atributos para treinamento e classificação de tráfego com o OCSVM:

- *Número de pacotes*: Quantidade total de pacotes registrados para cada fluxo entre dois dispositivos em uma rede.
- *Tempo médio entre chegada de pacotes*: Tempo médio entre a chegada de dois pacotes de um mesmo fluxo a cada dispositivo da rede.
- *Tamanho médio de pacotes*: Tamanho médio dos pacotes pertencentes a cada fluxo na rede.
- *Tamanho mínimo de pacote*: Menor tamanho de pacote registrado em cada fluxo de uma rede.
- *Tamanho máximo de pacote*: Maior tamanho de pacote registrado em cada fluxo de uma rede.

Os atributos listados acima foram escolhidos por poderem ser derivados de maneira simples dos dados que podem ser obtidos dos pacotes da simulação do smart grid. O número de pacotes de cada fluxo pode ser registrado através da identificação do dispositivo de origem e do dispositivo de destino dos pacotes que são analisados. Tempo médio entre a chegada de dois pacotes do mesmo fluxo pode ser obtido através do *timestamp* de chegada de cada pacote ao destino. Tamanho médio, tamanho mínimo e tamanho máximo de pacotes podem ser extraídos do tamanho dos pacotes analisados para cada fluxo. No entanto, a lista de atributos é extensível, e outros atributos podem ser utilizados na a classificação. Para adicionar novos atributos ao modelo de classificação, basta inseri-los nas instâncias de treinamento e de classificação. Cada instância é representada por uma lista de pares de índice e valor, onde cada índice representa um atributo, e o valor associado a cada índice é o valor do atributo respectivo naquela instância.

O algoritmo OCSVM é particularmente interessante para a classificação do tráfego em um sistema SCADA, pois o classificador pode ser treinado com um conjunto de dados proveniente do tráfego normal da rede. Isso elimina alguns dos problemas de classificar o tráfego utilizando um algoritmo multiclasse: dados de tráfego característicos de ataques cibernéticos à sistemas SCADA podem ser difíceis de obter, além de não ser possível classificar exaustivamente todos os tipos de ataques possíveis à rede com instâncias de treinamento. Utilizando o OCSVM, podemos classificar o tráfego em normal ou anormal, o que é suficiente para detectar

uma anomalia na rede.

3.2.2 Sistema de Detecção de Intrusão para a ferramenta ASTORIA

O objetivo da implementação de um IDS para a ferramenta ASTORIA é que ele funcione como um mecanismo de segurança do sistema, identificando comportamentos anômalos no tráfego de rede e realizando o registro dos dados do fluxo de rede onde as anomalias foram percebidas. Para tanto, os seguintes requisitos devem ser cumpridos:

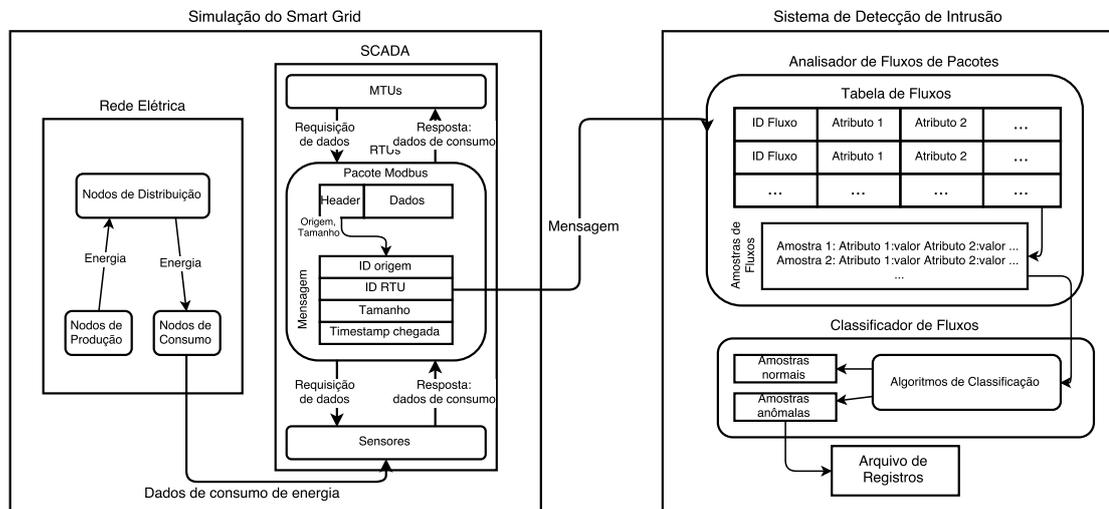
- A fim de realizar a análise do tráfego, o IDS deve ter acesso às informações de dispositivo de origem, dispositivo de destino e tamanho do pacote dos pacotes da rede durante a simulação, para que os atributos dos fluxos de rede possam ser identificados.
- O IDS deve utilizar os dados capturados para realizar a classificação do tráfego em normal ou anômalo durante a simulação, registrando ocorrências de tráfego anômalo.
- O IDS deve ser independente da topologia da simulação e dos dados sobre o fluxo de energia trocados pelos componentes.

A Figura 3.2 ilustra a arquitetura conceitual do IDS proposto. Os dados de cada pacote modbus enviado pelos sensores que chegam às RTUs, contendo informações de consumo de energia, são enviados para o módulo do IDS. Inicialmente, as informações extraídas dos pacotes são utilizadas para calcular os atributos dos fluxos presentes na rede. Cada fluxo é composto pelos pacotes trocados por cada par de dispositivos que se comunica pela rede. Os pacotes de requisição que as RTUs enviam para os sensores solicitando dados não são considerados na análise. Apenas os pacotes de resposta, que são enviados dos sensores para as RTUs, são utilizados para o cálculo dos atributos de cada fluxo. Depois, os atributos obtidos podem ser utilizados para treinar o classificador ou podem ser classificados, uma vez que o classificador já esteja treinado. Quando o classificador identifica os atributos recebidos como não pertencentes ao tráfego normal, o IDS registra a ocorrência e os dados do fluxo que foi identificado como anômalo em um arquivo de registros.

Inicialmente, o IDS obtém os dados do tráfego da simulação. Todos os pacotes de dados que são enviados pelos sensores às RTUs são analisados, e as seguintes informações são recuperadas do pacote:

- Origem: Identificador do sensor que enviou o pacote para a RTU.
- Destino: Identificador da RTU que recebeu o pacote.

Figura 3.2 – Arquitetura Conceitual do IDS Proposto



Fonte: Autor

- **Tamanho:** Tamanho do pacote.
- **Timestamp:** Horário da chegada do pacote ao destino.

As informações são enviadas por um socket de rede para um servidor que implementa o Analisador de Fluxos e o Classificador de Fluxos.

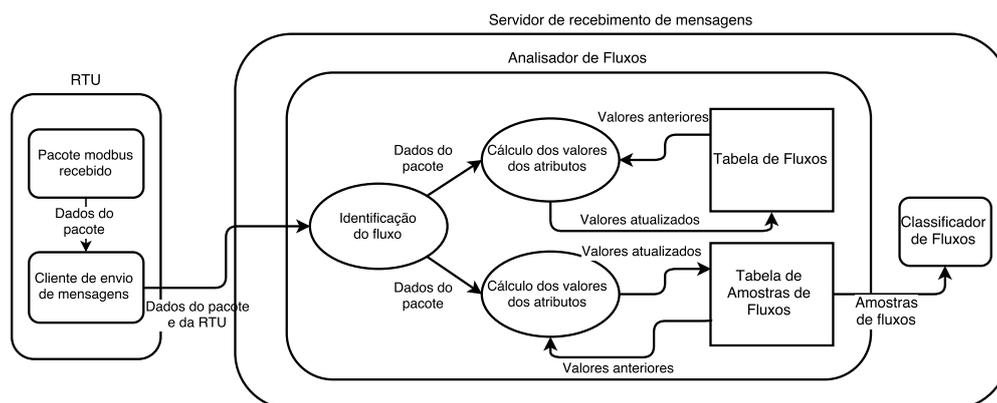
O servidor, que recebe as mensagens enviadas através do socket de rede, implementa os módulos que realizam a análise e a classificação dos dados. As mensagens recebidas pelo servidor, contendo informações sobre os pacotes, inicialmente são analisadas pelo Analisador de Fluxos, que fará a síntese dos dados que serão utilizados na classificação. O analisador recebe cada mensagem com informações de um pacote que chega ao módulo, e o insere em duas tabelas, uma tabela de fluxos e uma tabela de amostras. Enquanto a tabela de fluxos armazena os valores computados dos atributos dos fluxos até o fim da execução, a tabela de amostras armazena amostras dos atributos dos fluxos durante um determinado período de tempo, que serão utilizadas na classificação, e depois tem seus registros deletados para o armazenamento de novas amostras.

Cada par de sensor de origem com RTU de destino representa um fluxo da aplicação SCADA, e os identificadores de origem e destino do pacote são utilizados para rotular cada fluxo e armazená-lo nas tabelas. Para cada fluxo identificado, os seguintes atributos são armazenados:

- *Quantidade de Pacotes*: Quantidade de pacotes registrados para um determinado fluxo durante toda a execução.
- *Tamanho Médio dos Pacotes*: Tamanho médio dos pacotes de um fluxo.
- *Tempo Médio de Chegada Entre Pacotes*: Tempo médio entre a chegada ao destino de dois pacotes consecutivos em um mesmo fluxo.
- *Tamanho Mínimo de Pacote*: Tamanho do menor pacote registrado em um fluxo.
- *Tamanho Máximo de Pacote*: Tamanho do maior pacote registrado em um fluxo.
- *Timestamp*: Horário de chegada ao destino do último pacote registrado no fluxo.

A cada pacote que chega, os valores de origem e destino são concatenados e utilizados como chave do registro na tabela. Caso o fluxo já exista na tabela, as informações sobre o pacote são computadas ao fluxo existente. Caso o fluxo não exista na tabela, uma nova entrada é inserida, contendo as informações sobre o primeiro pacote registrado para aquele fluxo. As amostras armazenadas na tabela de amostras representam o comportamento de cada um dos fluxos durante um intervalo de tempo. A cada intervalo de tempo determinado, os atributos de todas as amostras são armazenados em um arquivo, e então a tabela é esvaziada de todos os dados para que as amostras do próximo intervalo de tempo sejam armazenadas. O funcionamento da RTU e do Analisador de Fluxos são ilustrados na Figura 3.3.

Figura 3.3 – Componentes RTU e Analisador de Fluxos



Fonte: Autor

A cada intervalo de tempo de amostragem, as amostras de fluxos são obtidas pelo Classificador de Fluxos, que utiliza algoritmos de classificação de dados para identificar amostras de tráfego normal e amostras de tráfego anômalo. Se o classificador ainda não foi treinado,

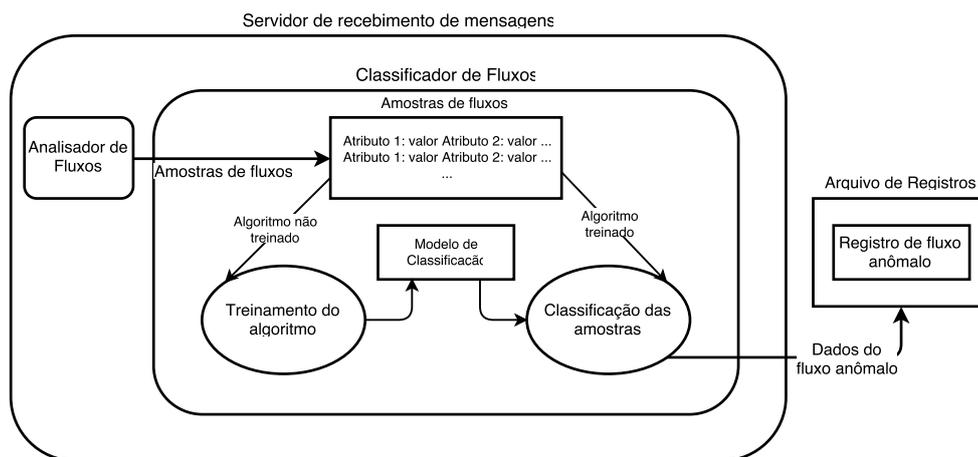
as amostras que chegam ao classificador são utilizadas para o treinamento dos algoritmos, que geram modelos de regras para a classificação dos dados. Quando o treinamento é encerrado, as amostras recebidas passam a ser classificadas de acordo com os modelos gerados no treinamento, identificando se os valores dos atributos de cada amostra pertencem ou não à classe de tráfego normal.

Quando uma amostra de fluxo é identificada como anômala, ela é armazenada em um arquivo de registros, que documenta todas as incidências de tráfego anormal com as seguintes informações:

- Origem: Dispositivo do qual se origina o fluxo de rede caracterizado como tráfego anômalo.
- Destino: Dispositivo que recebe os pacotes do fluxo de rede identificado como anômalo.
- *Timestamp*: Horário em que foi identificada a anomalia na amostra do fluxo de rede.
- Dados: Valores dos atributos da amostra que foi identificada como tráfego anômalo.

O arquivo de registros pode ser enviado à empresa de serviços públicos responsável pela manutenção do sistema SCADA, para que sejam tomadas medidas preventivas em relação à identificação de tráfego anômalo na rede ou para a condução de estudos e pesquisas sobre o tráfego do sistema. O funcionamento do componente Classificador de Fluxos é ilustrado na Figura 3.4.

Figura 3.4 – Componente Classificador de Fluxos



Fonte: Autor

4 IMPLEMENTAÇÃO E ANÁLISE DE RESULTADOS

O IDS proposto no capítulo anterior visa utilizar dados do tráfego normal de uma simulação de smart grid, obtidos a partir das RTUs, para gerar um modelo de classificação capaz de identificar tráfego anômalo. A fim de realizar a análise e avaliação desse IDS, foi implementado um protótipo para a classificação do tráfego da ferramenta ASTORIA utilizando o algoritmo OCSVM. Neste capítulo, será descrita a implementação e a avaliação do protótipo, com o objetivo de definir se o algoritmo utilizado e o modelo proposto são adequados para a identificação de anomalias em uma simulação de smart grid.

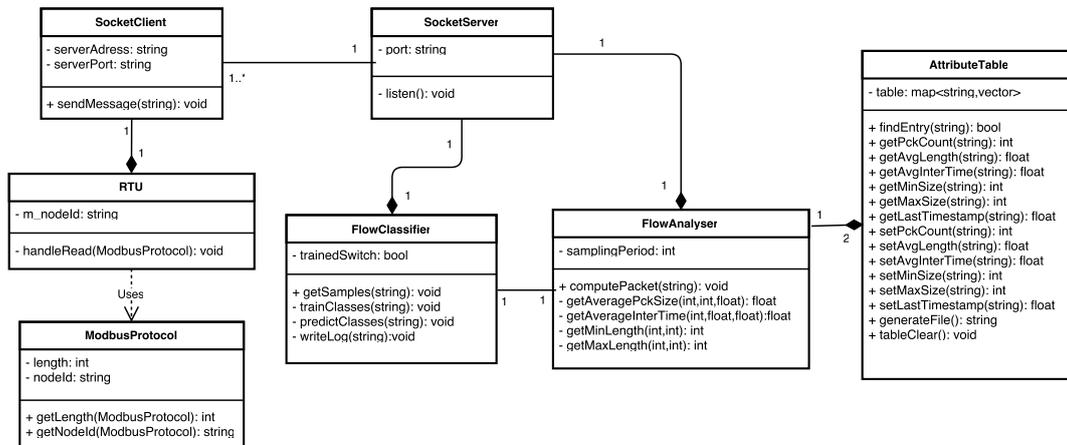
A Seção 4.1 apresenta a implementação do protótipo e as ferramentas utilizadas. Na Seção 4.2, são descritos os experimentos executados para a avaliação do protótipo. Por fim, a Seção 4.3 analisa os resultados obtidos nos experimentos.

4.1 Implementação do Protótipo

Para avaliar o IDS apresentado neste trabalho, foi realizada a implementação de um protótipo do sistema. O objetivo da implementação do protótipo é utilizá-lo na execução de experimentos, utilizando dados gerados a partir da simulação de um ambiente smart grid, e avaliar sua capacidade de diferenciar cenários de tráfego normal de cenários com ocorrência de ataques.

O framework ASTORIA foi utilizado para a simulação do ambiente smart grid e para a geração de cenários de ataques cibernéticos. No ASTORIA, as RTUs são implementadas pela classe *RTU*, que gerencia os pacotes de rede recebidos dos sensores através do método *handleRead*. Os métodos *getNodeId()* e *getLength()*, da classe *ModbusProtocol*, são utilizados para obter os atributos desejados do pacote, que então são concatenados em uma mensagem, juntamente com o atributo *m_NodeId* na RTU. O envio das mensagens foi implementado utilizando um *socket* de rede UDP através da biblioteca *sys/socket.h*. Cada RTU utiliza um cliente, definido pela classe *SocketClient*, para enviar as mensagens utilizando o método *sendMessage()*. As mensagens enviadas de todas as RTUs são recebidas por um servidor, definido pela classe *SocketServer*, que executa o método *listen()* em um laço para receber mensagens. A cada mensagem que chega no módulo de detecção, o método *computePacket()*, da classe *FlowAnalyser*, é executado para extrair as informações do pacote. A Figura 4.1 apresenta o diagrama de classes do IDS. A linguagem C++ foi utilizada na implementação de todos os módulos do IDS.

Figura 4.1 – Diagrama de Classes do IDS



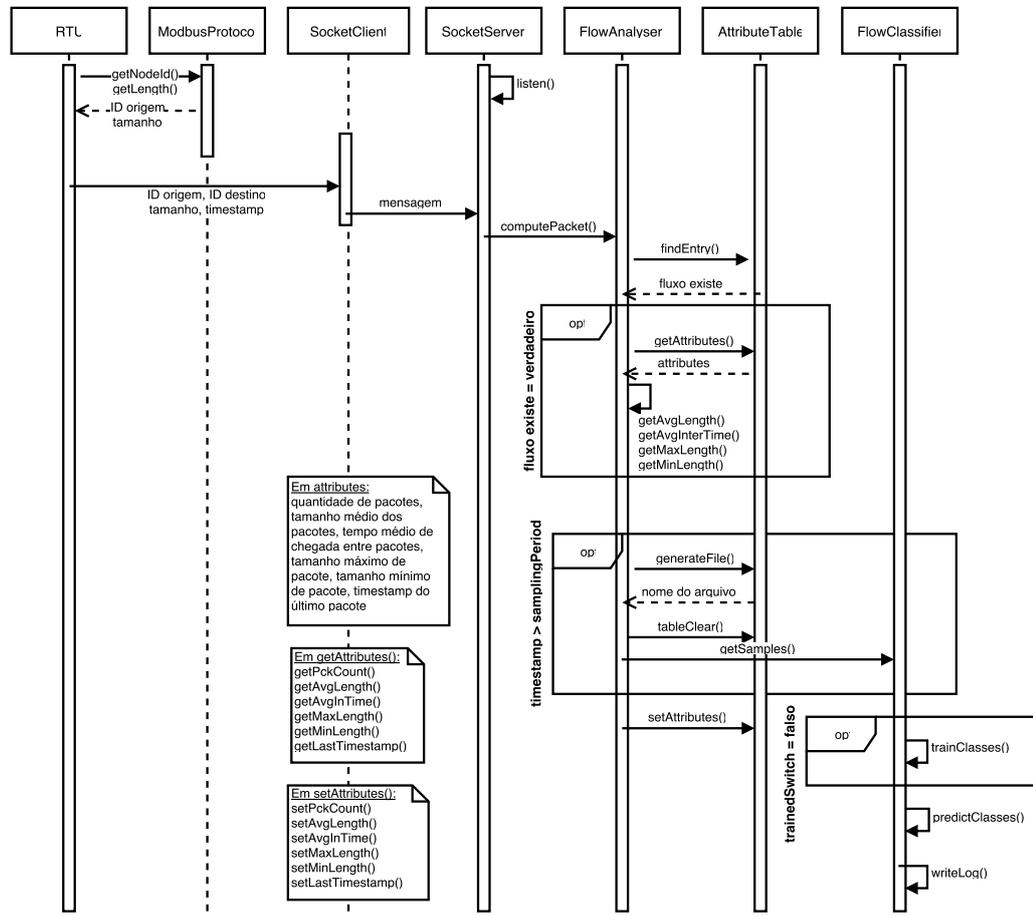
Fonte: Autor

Na classe *FlowAnalyser*, o atributo *Tamanho Médio dos Pacotes* de um fluxo é calculado pelo método *getAveragePckSize*, utilizando a média aritmética dos tamanhos de todos os pacotes computados para aquele fluxo. O atributo *Tempo Médio de Chegada Entre Pacotes* é calculado pelo método *getAverageInterTime*, através da média aritmética do intervalo de tempo entre a chegada de cada par de pacotes consecutivos registrados no fluxo. Os atributos *Tamanho Máximo de Pacote* e *Tamanho Mínimo de Pacote* são obtidos pelos métodos *getMaxLength* e *getMinLength*, respectivamente. O atributo *samplingPeriod* é utilizado para definir o intervalo de tempo em que as amostras de fluxos são armazenadas, antes de serem enviadas para classificação. A Figura 4.2 ilustra as interações entre os componentes em um diagrama de sequência.

As tabelas que armazenam os valores dos atributos são definidas pela classe *AttributeTable*, que implementa métodos para determinar se um fluxo já existe, obter os valores dos atributos de um fluxo e inserir valores nos atributos de um fluxo. Os métodos *generateFile()* e *tableClear()* são utilizados para escrever os valores armazenados em um arquivo e para excluir os valores armazenados na tabela. Os valores são armazenados em um mapeamento, utilizando a biblioteca *map.h*, de uma chave do tipo *string*, caracterizada pelos identificadores dos nodos pertencentes a cada fluxo, com um vetor contendo os valores de cada atributo. A cada período de amostragem definido em *samplingPeriod*, as amostras da tabela são escritas em um arquivo de texto e a tabela é esvaziada. O método *getSamples*, da classe *FlowClassifier*, obtém o arquivo de amostras gerado para classificação.

O algoritmo OCSVM é utilizado na classificação das amostras. Para a implementação do OCSVM, foi utilizada a biblioteca LIBSVM (CHANG; LIN, 2011). A LIBSVM contém

Figura 4.2 – Diagrama de Sequência do IDS



Fonte: Autor

implementações do algoritmo SVM e suas variações, incluindo o OCSVM, e fornece três scripts para a realização da tarefa de classificação. O *script svm-scale* é utilizado para normalizar os valores dos atributos das amostras para o intervalo $[-1, 1]$. O *script svm-train* recebe como entrada o conjunto de treinamento, e gera o modelo de classificação, que contém as regras para a classificação das amostras. O *script svm-predict* recebe um conjunto de amostras e utiliza o modelo de classificação para identificar se elas pertencem ou não à classe definida.

A classe *FlowClassifier* utiliza os *scripts* da LIBSVM para implementar o método *trainClasses()*, para treinar o algoritmo OCSVM, e o método *predictClasses*, para classificar as amostras utilizando o algoritmo treinado. O atributo *trainedSwitch* indica se o algoritmo já está treinado ou não. O método *writeLog()* é utilizado para escrever o registro dos fluxos classificados como anômalos em um arquivo. Quando uma amostra é classificada como não pertencente à classe de tráfego normal, ela é armazenada em um arquivo de registros, contendo as seguintes

informações: Identificador do dispositivo de origem, identificador do dispositivo de destino, atributos do fluxo e *timestamp* da amostra.

4.2 Execução dos Experimentos

Os experimentos para avaliação do funcionamento do IDS previamente definido foram realizados através de simulações, utilizando a ferramenta ASTORIA, de diferentes cenários de um ambiente smart grid. Os dados de tráfego, gerados durante as simulações, são obtidos pelo protótipo implementado do IDS, e então utilizados como entrada para os processos de análise e classificação. Os experimentos utilizaram cenários de tráfego anômalo na simulação para testar a capacidade do IDS de identificar fluxos anormais.

Para a realização dos experimentos, foi definida uma topologia para a simulação, que representa a interação entre os componentes da rede no cenário sendo simulado. Outras características da simulação, como o intervalo de tempo entre as requisições de dados das RTUs e MTUs e a duração da simulação, também foram definidos. Em seguida, foram definidos os cenários que originam tráfego anômalo na simulação.

Na Seção 4.2.1, são descritas a topologia e as configurações utilizadas na ferramenta ASTORIA para a simulação do cenário do smart grid. A Seção 4.2.2 descreve os recursos utilizados para gerar os cenários de tráfego anômalo, utilizados para testar o funcionamento do IDS.

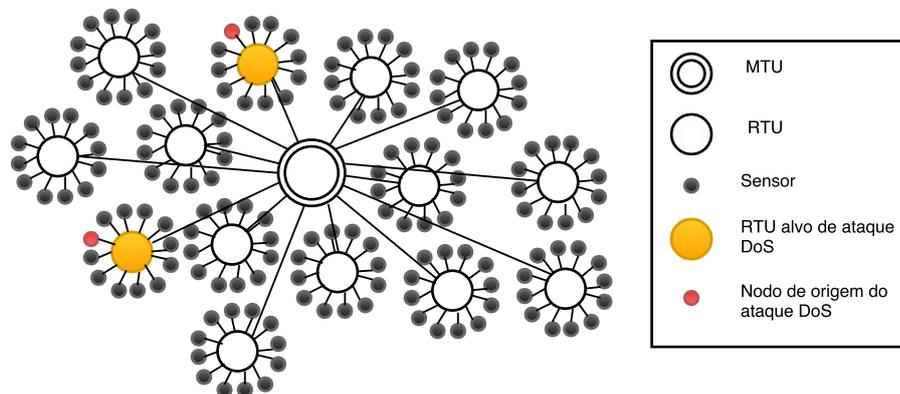
4.2.1 Topologia e Configuração das Simulações

A topologia utilizada nas simulações do smart grid com o ASTORIA, ilustrada na Figura 4.3, é similar à topologia descrita pelos autores em (WERMANN et al., 2016), porém com uma quantidade menor de nodos de produção e consumo, sendo composta por 1 MTU, 14 RTUs e 168 sensores.

- MTU: A MTU envia requisições às RTUs, que enviam respostas contendo dados sobre os valores de energia medidos pelos sensores naquela região. Todas as RTUs da simulação estão conectadas à MTU. Como a MTU é o único componente do sistema SCADA na simulação que não tem um correspondente na rede de energia, ela existe apenas na rede de comunicação.

- RTUs: As RTUs enviam requisições aos sensores, que respondem enviando os dados sobre consumo de energia coletados por eles. Cada RTU possui 12 sensores conectados a ela e está conectada à MTU. Para toda RTU na simulação, existe um nodo de distribuição de energia na rede elétrica associado a ela.
- Sensores: Cada um dos sensores na simulação está conectado à uma RTU, e possui um nodo de consumo de energia associado a ele na rede elétrica. Quando uma requisição da RTU chega ao sensor, ele responde enviando os dados medidos de consumo de energia no seu respectivo nodo.

Figura 4.3 – Topologia utilizada nos experimentos



Fonte: Autor

Na configuração das simulações, o tempo total de execução foi definido em 1800 segundos e o passo de execução foi definido em 2 segundos. O passo de execução define que, a cada 2 segundos, todas as RTUs enviarão requisições de dados para todos os seus respectivos sensores, e a MTU enviará requisições de dados para todas as RTUs. Para a realização dos experimentos, foram utilizados dois modelos de simulação. O primeiro modelo de simulação utiliza o tráfego puro gerado pela configuração que foi definida. Nesse modelo, as requisições são enviadas a cada intervalo de 2 segundos, sem variações, e as amostras de tráfego obtidas tem valores constantes. Ao calcular os atributos dos fluxos do tráfego desse modelo de simulação, os valores obtidos tendem a convergir, gerando amostras uniformes, com variações muito pequenas. No segundo modelo de simulação, atrasos aleatórios são introduzidos ao intervalo de tempo entre as requisições enviadas por algumas RTUs, causando variações nos intervalos de envio das requisições. Cada requisição enviada por uma RTU tem uma chance de 25% de

sofrer um atraso aleatório de 100, 200, 300 ou 400 milissegundos. Esse modelo gera amostras de tráfego com maior variedade, e os valores calculados para os atributos dos fluxos apresentam resultados com maior diversidade de valores.

As informações de tráfego gerado por cada um dos modelos de simulação foram utilizadas nos experimentos para o treinamento do IDS, a fim de gerar um modelo de classificação capaz de reconhecer o tráfego normal da simulação. Após o treinamento utilizando tráfego normal da simulação, os dados de tráfego gerados pelas simulações com anomalias inseridas foram analisados e classificados pelo IDS, para testar a capacidade da ferramenta de reconhecer os fluxos de tráfego anômalos.

4.2.2 Introdução de Tráfego Anômalo

O primeiro recurso utilizado para a geração de anomalias no cenário da simulação foi o ataque DoS fornecido pelo framework ASTORIA. Dois perfis de ataque foram utilizados no experimento, ambos os ataques com as RTUs 4 e 9 sendo atacadas por um de seus respectivos sensores. O primeiro perfil define um ataque de alta potência, com o intervalo de envio de pacotes variando entre 2 e 50 milissegundos, o que gera entre 20 e 500 pacotes por segundo sendo enviados a cada uma das RTUs sob ataque, em contraste à média de 0,5 pacote por segundo, característica do tráfego normal da simulação. No segundo perfil, o ataque realizado é de baixa potência, e o intervalo de envio dos pacotes varia entre 200 e 500 milissegundos, enviando entre 2 e 5 pacotes por segundo para as RTUs sob ataque.

O tamanho dos pacotes enviados pelos componentes não pode ser manipulado de maneira simples em uma simulação, pois ele é definido pela carga de dados enviada pelos sensores. Dessa forma, afim de obter dados de tráfego com anomalias no tamanho dos pacotes para os experimentos, foram geradas cargas de dados com alteração nos tamanhos dos pacotes obtidos. Os conjuntos de dados gerados são semelhantes aos dados obtidos de uma simulação normal, mas com variações inseridas nos valores obtidos para o tamanho dos pacotes em alguns fluxos. Os valores anômalos inseridos incluíram pacotes com 80%, 120%, 200% e 400% do tamanho original.

As anomalias geradas foram utilizadas em experimentos nos dois modelos de simulação, o modelo de tráfego uniforme e o modelo de tráfego com variações. Assim, os seguintes experimentos foram executados, com 30 repetições e 95% de confiança:

- Simulação com modelo de tráfego uniforme com o perfil de ataque DoS de alta potência

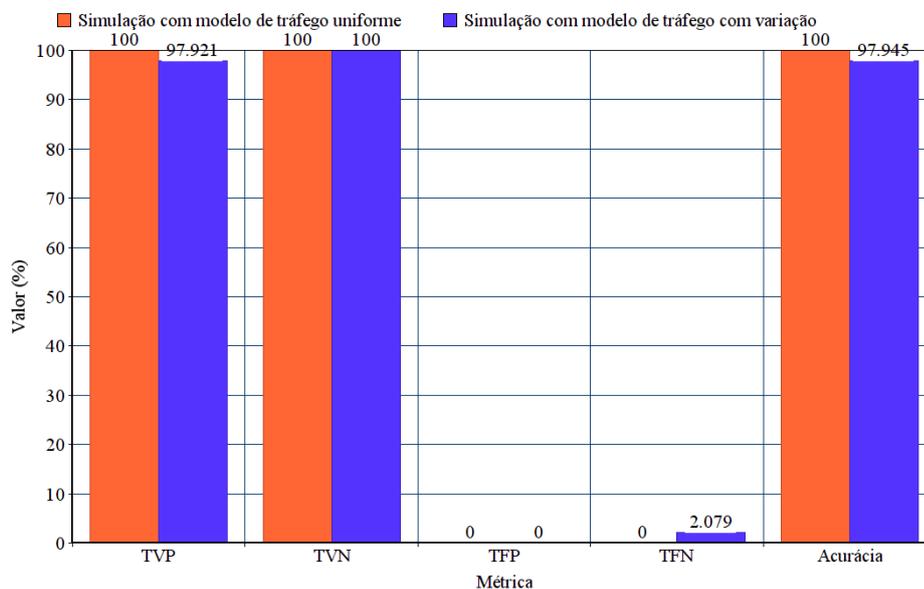
- Simulação com modelo de tráfego com variações com o perfil de ataque DoS de alta potência
- Simulação com modelo de tráfego uniforme com o perfil de ataque DoS de baixa potência
- Simulação com modelo de tráfego com variações com o perfil de ataque DoS de baixa potência
- Simulação com modelo de tráfego uniforme com a carga de dados contendo anomalias no tamanho dos pacotes
- Simulação com modelo de tráfego com variações com a carga de dados contendo anomalias no tamanho dos pacotes

4.3 Análise dos Resultados

Para a avaliação dos resultados obtidos nos experimentos, foram utilizadas as métricas Taxa de Verdadeiros Positivos (TVP), Taxa de Falsos Positivos (TFP), Taxa de Verdadeiros Negativos (TVN) e Taxa de Falsos Negativos (TFN), amplamente utilizados na avaliação de sistemas de classificação (NGUYEN; ARMITAGE, 2008).

- Taxa de Verdadeiros Positivos: Porcentagem de amostras de tráfego normal, classificadas corretamente como pertencentes à classe de tráfego normal, dada por $TVP = VP / (VP + FN)$.
- Taxa de Verdadeiros Negativos: Porcentagem de amostras de tráfego anômalo, classificadas corretamente como não pertencentes à classe de tráfego normal, calculada a partir de $TVN = VN / (VN + FP)$.
- Taxa de Falsos Positivos: Porcentagem de amostras de tráfego anômalo, classificadas incorretamente como pertencentes à classe de tráfego normal, calculada por $TFP = 1 - TVN$.
- Taxa de Falsos Negativos: Porcentagem de amostras de tráfego normal classificadas incorretamente como não pertencentes à classe de tráfego normal, obtida com $TFN = 1 - TVP$.
- Acurácia: medida que representa a porcentagem de amostras classificadas corretamente em relação à quantidade total de amostras, calculada pela expressão $ACC = (VP + VN) / (VP + VN + FP + FN)$.

Figura 4.4 – Resultados dos experimentos com um ataque DoS de alta potência

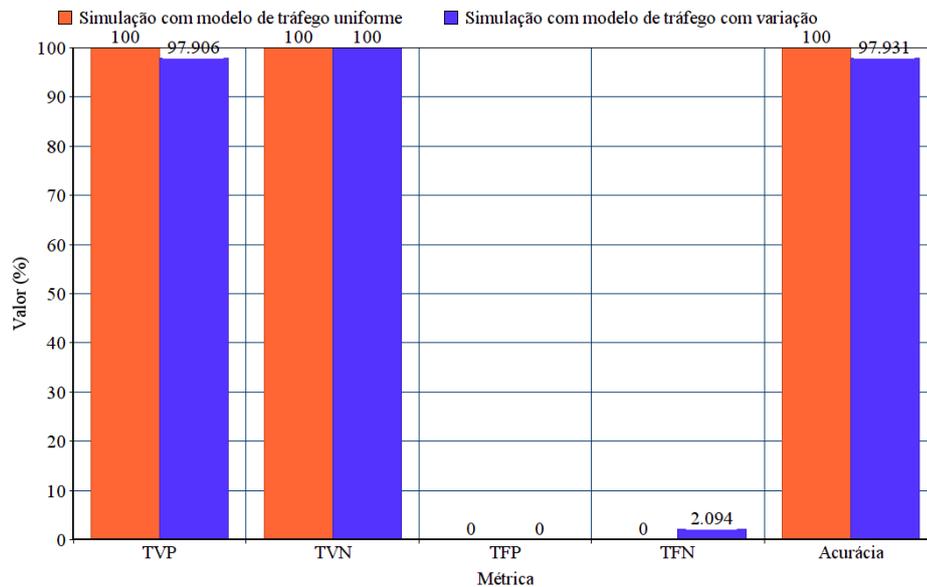


Fonte: Autor

A Figura 4.4 apresenta os resultados obtidos na classificação do tráfego da simulação durante a ocorrência de um ataque DoS de alta potência. Primeiramente, é possível observar que, nos experimentos que utilizaram a simulação com modelo de tráfego uniforme, o IDS foi capaz de classificar corretamente todas as amostras, atingindo uma acurácia de 100%. Já nos experimentos que utilizaram a simulação com modelo de tráfego com variações, apesar do IDS ter identificado corretamente todas as amostras de tráfego anômalo, uma parcela das amostras de fluxos normais foram classificadas como anômalas, gerando uma TFN de 2,079%. Podemos atribuir esses resultados ao modelo de classificação que é gerado pelo IDS. Quando utilizamos o modelo de tráfego uniforme, o tráfego se mantém constante ao longo da execução, gerando amostras de tráfego que possuem valores de atributos iguais ou com variações muito pequenas. Quando essas amostras são utilizadas no treinamento do algoritmo, o modelo gerado para solucionar a classificação é muito simples, pois amostras de tráfego normal sempre serão iguais às amostras utilizadas no treinamento, e qualquer amostra com uma pequena variação é caracterizada como anômala. Quando o modelo de tráfego com variações é utilizado, as amostras de tráfego utilizadas para o treinamento do algoritmo sofrem variações aleatórias, o que torna o problema da classificação mais complexo. O classificador de classe única não é capaz de incorporar toda a diversidade de dados do conjunto de treinamento ao modelo de classificação. Assim, algumas amostras com variações, provenientes de tráfego normal, são

consideradas fora da classe descrita pelo modelo, e classificadas como anômalas. Ainda assim, o classificador obteve acurácia de 97,945% na classificação do tráfego nesse cenário.

Figura 4.5 – Resultados dos experimentos com um ataque DoS de baixa potência

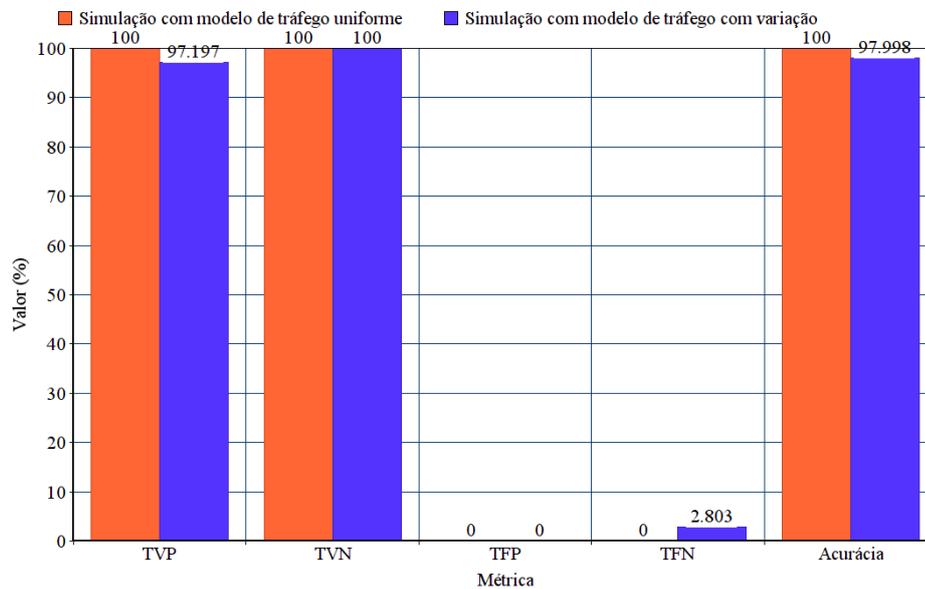


Fonte: Autor

Os resultados obtidos para a classificação do tráfego durante um ataque DoS de baixa potência são mostrados na Figura 4.5. Os resultados obtidos para esse cenário são semelhantes aos resultados obtidos nos cenários com o ataque DoS de alta potência. Nas execuções com a simulação de modelo uniforme de tráfego, o IDS também classificou corretamente todas as amostras, com 100% de acurácia. Nas execuções com a simulação de modelo de tráfego com variações, as amostras de fluxos provenientes dos ataques também foram 100% classificadas como anômalas, mas com uma TFN de 2,094%, obtendo 97,931% de acurácia. Da mesma forma que nos experimentos com o ataque de alta potência, o modelo de classificação gerado a partir da simulação de tráfego com variações não compreendeu toda a diversidade de dados descrita pelas amostras de tráfego. Desse modo, apesar das anomalias geradas serem mais próximas do tráfego normal, o classificador excluiu as amostras anômalas da classe normal da mesma forma que excluiu parte das amostras normais que possuíam variações.

Por fim, a Figura 4.6 apresenta os resultados obtidos para a classificação do tráfego utilizando cargas de dados com anomalias no tamanho dos pacotes. Os resultados seguiram o

Figura 4.6 – Resultados dos experimentos com inserção de anomalias no tamanho dos pacotes



Fonte: Autor

mesmo comportamento dos experimentos com os cenários de ataques DoS. As execuções utilizando a simulação com o modelo de tráfego uniforme obtiveram acurácia de 100% na classificação. As execuções utilizando a simulação com modelo de tráfego com variação identificaram todas as amostras anômalas corretamente, porém com uma TFN de 2,803%, atingindo 97,998% de acurácia.

A primeira consideração que pode ser feita sobre os resultados obtidos é que o classificador obtém resultados mais precisos para a classificação de tráfegos mais estáveis, com maior uniformidade nos dados e poucas variações. Quando pequenas variações são inseridas no tráfego, o modelo de classificação gerado passa a não assimilar toda a diversidade de dados presente no conjunto de treinamento, e falsos negativos passam a ocorrer na classificação. Todavia, a TFP foi zero em todos os experimentos, indicando que todas as ocorrências de tráfego anômalo foram identificadas, e a acurácia superou 97% em todas as execuções. Esses resultados apontam que IDSs baseados no algoritmo OCSVM são viáveis em estruturas de comunicação de smart grids.

Para aumentar a precisão do IDS, seria possível complementar o algoritmo de detecção de anomalias com técnicas de *Signature Based Detection* utilizando perfis de ataques para a detecção, como utilizado em (YANG et al., 2013). Dessa forma, todas as amostras de fluxo identificadas como anômalas pelo classificador poderiam ser comparadas aos perfis de ataques

registrados. Esse processo poderia identificar os verdadeiros negativos através da similaridade com os perfis de ataque, e eliminar os falsos negativos. Para isso, seria necessário ter acesso a dados sobre ataques conhecidos a smart grids, e sobre o comportamento do tráfego da rede durante a ocorrência de ataques. Outra possibilidade seria utilizar na classificação um algoritmo de classificação em duas classes, como o SVM tradicional. Nesse caso, o conjunto de treinamento seria composto por uma classe positiva, representada por amostras de tráfego normal, e uma classe negativa, representada por amostras de tráfego em cenários de ataques ou anomalias. Dessa forma, pequenas variações de tráfego estariam muito mais próximas da classe positiva do que da classe negativa, diminuindo a ocorrência de falsos negativos.

5 CONCLUSÃO E TRABALHOS FUTUROS

O desenvolvimento dos smart grids possibilita o consumo e distribuição mais eficientes da energia elétrica, a utilização de fontes renováveis de energia e abre diversas possibilidades para a utilização de novas tecnologias, a fim de tornar o sistema de distribuição mais seguro e confiável. No entanto, smart grids são suscetíveis a diversos ataques, tanto aos componentes da rede elétrica quanto aos componentes da rede de comunicação. O desenvolvimento de mecanismos e técnicas para garantir a segurança dos smart grids é de grande importância, pois são estruturas críticas que fornecem energia a uma larga extensão de regiões, que podem sofrer prejuízos graves na ocorrência de uma interrupção no serviço.

Na Seção 5.1, são apresentadas as contribuições deste trabalho. As propostas para trabalhos futuros são descritas na Seção 5.2.

5.1 Resumo de Contribuições

Neste trabalho, propusemos um IDS para a detecção de ataques em uma ferramenta de simulação de smart grid, baseada no reconhecimento do tráfego normal da rede. A ferramenta de simulação utilizada foi o framework ASTORIA, capaz de definir e executar ataques cibernéticos sobre a simulação de um smart grid. O IDS desenvolvido utiliza as informações do tráfego das RTUs da simulação para identificar anomalias através da classificação dos dados. Os pacotes recebidos pelas RTUs contendo informações dos sensores são analisados e os atributos de cada fluxo de rede são calculados. Amostras dos atributos dos fluxos da rede são enviados para classificação a cada período de amostragem, e a classificação foi realizada utilizando o algoritmo *One-Class Support Vector Machine*, de classificação em classe única. O algoritmo foi treinado utilizando amostras de tráfego normal da simulação, a fim de diferenciar tráfego normal de tráfego anômalo apenas com o conhecimento do tráfego normal da rede.

O IDS foi avaliado através de experimentos que utilizaram cenários de simulação com tráfego uniforme e cenários com atrasos aleatórios introduzidos no envio dos pacotes. Foram utilizados cenários com ataques DoS de maior intensidade e de menor intensidade, além de cenários com anomalias no tamanho medido para os pacotes. Os resultados dos experimentos demonstraram que o IDS desenvolvido é capaz de identificar corretamente a ocorrência de ataques e anomalias de intensidades variadas à rede, apesar de apresentar uma pequena taxa de ocorrência alarmes falsos quando o tráfego sendo analisado apresenta uma quantidade maior de variações.

5.2 Trabalhos Futuros

Como trabalhos futuros, propomos avaliar o desempenho do IDS utilizando outros algoritmos de classificação em classe única, como o *Support Vector Data Description* (TAX; DUIN, 2004) e o *Kernel Principal Component Analysis* (HOFFMANN, 2007). Também propomos melhorar a acurácia do IDS combinando o algoritmo de classificação em classe única com técnicas de detecção baseadas em assinatura, como as utilizadas em (YANG et al., 2013), utilizando perfis que descrevam ataques comuns a sistemas SCADA, a fim de diminuir a quantidade de alarmes falsos e aumentar a precisão da detecção.

REFERÊNCIAS

- ALI, M.; AL-SHAER, E. Probabilistic model checking for ami intrusion detection. In: **Smart Grid Communications (SmartGridComm), 2013 IEEE International Conference on**. [S.l.: s.n.], 2013. p. 468–473.
- AMIN, S.; WOLLENBERG, B. Toward a smart grid: power delivery for the 21st century. **Power and Energy Magazine, IEEE**, v. 3, n. 5, p. 34–41, Sep 2005. ISSN 1540-7977.
- ASHFORD, W. **Smart meter and smart grids: security risk or opportunity?** 2011. Available from Internet: <<http://www.computerweekly.com/news/1280097292/Smart-meter-and-smart-grids-security-risk-or-opportunity>>.
- AXELSSON, S. **Intrusion detection systems: A survey and taxonomy**. [S.l.], 2000.
- BOU-HARB, E. et al. Communication security for smart grid distribution networks. **Communications Magazine, IEEE**, v. 51, n. 1, p. 42–49, Jan 2013. ISSN 0163-6804.
- CARCANO, A. et al. A multidimensional critical state analysis for detecting intrusions in SCADA systems. **Industrial Informatics, IEEE Transactions on**, v. 7, n. 2, p. 179–186, May 2011. ISSN 1551-3203.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, p. 1 – 27, 2011. Software available at <<http://www.csie.ntu.edu.tw/~cjlin/libsvm>>.
- CHEN, P.-Y.; CHENG, S.-M.; CHEN, K.-C. Smart attacks in smart grid communication networks. **Communications Magazine, IEEE**, v. 50, n. 8, p. 24–29, Aug 2012. ISSN 0163-6804.
- CHEN, Y.; SHI, X. A real-time communication solution based on PROFIBUS. In: **Advanced Intelligence and Awareness Internet (AIAI 2011), 2011 International Conference on**. [S.l.: s.n.], 2011. p. 288–292.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine learning**, Springer, v. 20, n. 3, p. 273–297, 1995.
- COUTINHO, M. et al. Anomaly detection in power system control center critical infrastructures using rough classification algorithm. In: **Digital Ecosystems and Technologies, 2009. DEST 09. 3rd IEEE International Conference on**. [S.l.: s.n.], 2009. p. 733–738.
- DRIAS, Z.; SERHROUCHNI, A.; VOGEL, O. Taxonomy of attacks on industrial control protocols. In: **Protocol Engineering (ICPE) and International Conference on New Technologies of Distributed Systems (NTDS), 2015 International Conference on**. [S.l.: s.n.], 2015. p. 1–6.
- ESTER, M. et al. Incremental clustering for mining in a data warehousing environment. In: **CITeseer. 24th VLDB Conference**. [S.l.], 1998. v. 98, p. 323–333.
- FRALEY, C.; RAFTERY, A. E. Model-based clustering, discriminant analysis, and density estimation. **Journal of the American statistical Association**, Taylor & Francis, v. 97, n. 458, p. 611–631, 2002.

HOFFMANN, H. Kernel PCA for novelty detection. **Pattern Recognition**, Elsevier, v. 40, n. 3, p. 863–874, 2007.

LI, X. et al. Securing smart grid: cyber attacks, countermeasures, and challenges. **Communications Magazine, IEEE**, v. 50, n. 8, p. 38–45, Aug 2012. ISSN 0163-6804.

LIGUO, Z. et al. IEC 60870-5-101 protocol based voltage detector data communication. In: **Measuring Technology and Mechatronics Automation (ICMTMA), 2010 International Conference on**. [S.l.: s.n.], 2010. v. 2, p. 410–413.

MCLAUGHLIN, S. et al. Amids: A multi-sensor energy theft detection framework for advanced metering infrastructures. In: **Smart Grid Communications (SmartGridComm), 2012 IEEE Third International Conference on**. [S.l.: s.n.], 2012. p. 354–359.

MODBUS PLC Simulator. 2009. Available from Internet: <<http://www.plcsimulator.org/>>.

mosaik. 2015. Available from Internet: <<https://mosaik.offis.de/>>.

NGUYEN, T.; ARMITAGE, G. A survey of techniques for internet traffic classification using machine learning. **Communications Surveys and Tutorials, IEEE**, v. 10, n. 4, p. 56–76, Fourth Quarter 2008.

ns-3. 2011. Available from Internet: <<https://www.nsnam.org/>>.

PYPOWER. 2011. Available from Internet: <<https://pypi.python.org/pypi/PYPOWER>>.

QUEIROZ, C.; MAHMOOD, A.; TARI, Z. SCADASim - a framework for building SCADA simulations. **Smart Grid, IEEE Transactions on**, v. 2, n. 4, p. 589–597, Dec 2011. ISSN 1949-3053.

RISH, I. An empirical study of the naive bayes classifier. In: IBM NEW YORK. **IJCAI 2001 workshop on empirical methods in artificial intelligence**. [S.l.], 2001. v. 3, n. 22, p. 41–46.

SAYEGH, N. et al. Scada intrusion detection system based on temporal behavior of frequent patterns. In: **Mediterranean Electrotechnical Conference (MELECON), 2014 17th IEEE**. [S.l.: s.n.], 2014. p. 432–438.

SCHOLKOPF, B.; SMOLA, A. J. **Learning with kernels: support vector machines, regularization, optimization, and beyond**. [S.l.]: MIT press, 2001.

TAX, D. M.; DUIN, R. P. Support vector data description. **Machine learning**, Springer, v. 54, n. 1, p. 45–66, 2004.

TSANG, C.-H.; KWONG, S. Multi-agent intrusion detection system in industrial network using ant colony clustering approach and unsupervised feature extraction. In: **Industrial Technology, 2005. ICIT 2005. IEEE International Conference on**. [S.l.: s.n.], 2005. p. 51–56.

VirtuaPlant. 2015. Available from Internet: <<http://wroot.org/projects/virtuaplant/>>.

WAGSTAFF, K. et al. Constrained k-means clustering with background knowledge. In: **Eighteenth International Conference on Machine Learning**. [S.l.: s.n.], 2001. v. 1, p. 577–584.

WERMANN, A. G. et al. Astoria: A framework for attack simulation and evaluation in smart grids. In: **Proceedings of the 15th IEEE/IFIP Network Operations and Management Symposium (NOMS 2016)**. Istanbul, Turkey: [s.n.], 2016.

YAN, Y. et al. A survey on smart grid communication infrastructures: Motivations, requirements and challenges. **Communications Surveys and Tutorials, IEEE**, v. 15, n. 1, p. 5–20, First 2013. ISSN 1553-877X.

YANG, Y. et al. Intrusion detection system for iec 60870-5-104 based scada networks. **Power and Energy Society General Meeting (PES), 2013 IEEE**, p. 1–5, July 2013. ISSN 1944-9925.

YANG, Y. et al. Multiattribute scada-specific intrusion detection system for power networks. **Power Delivery, IEEE Transactions on**, v. 29, n. 3, p. 1092–1102, June 2014. ISSN 0885-8977.

YANG, Y. et al. Stateful intrusion detection for IEC 60870-5-104 SCADA security. In: **PES General Meeting | Conference Exposition, 2014 IEEE**. [S.l.: s.n.], 2014. p. 1–5.

ZIMMERMAN, R. D.; MURILLO-SANCHEZ, C. E.; THOMAS, R. J. MATPOWER: Steady state operations, planning and analysis tools for power systems research and education. **Power Systems, IEEE Transactions on**, v. 26, n. 1, p. 12–19, Feb 2011.