Universidade do Estado do Rio de Janeiro
Centro de Tecnologia e Ciência
Faculdade de Engenharia

Ricardo Ferreira Vieira de Castro

Análise de desempenho dos algoritmos Apriori e *Fuzzy* Apriori na extração de regras de associação aplicados a um Sistema de Detecção de Intrusos

Rio de Janeiro
2014

Ricardo Ferreira Vieira de Castro

Análise de desempenho dos algoritmos Apriori e *Fuzzy* Apriori na extração de regras de associação aplicados a um Sistema de Detecção de Intrusos

Dissertação apresentada, como requisito parcial para a obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientadora: Prof[a]. Dr[a]. Maria Luiza Fernandes Velloso

Coorientador: Prof. Dr. Nival Nunes de Almeida

Rio de Janeiro

2014

CATALOGAÇÃO NA FONTE

UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

C355 Castro, Ricardo Ferreira Vieira de.
Análise de desempenho dos algoritmos Apriori e Fuzzy Apriori na extração de regras de associação aplicados a um Sistema de Detecção de Intrusos. Ricardo Ferreira Vieira de Castro. - 2014.
124 f.

Orientadora:. Maria Luiza Fernandes Velloso.
Coorientador: Nival Nunes de Almeida Mourelle.Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia Eletrônica. 2. Algorítmos - Dissertações. I. Velloso, Maria Luiza Fernandes. II. Almeida, Nival Nunes de. III. Universidade do Estado do Rio de Janeiro. IV. Título.

CDU 004.89:621.38

Assinatura

Data

Ricardo Ferreira Vieira de Castro

Análise de desempenho dos algoritmos Apriori e *Fuzzy* Apriori na extração de regras de associação aplicados a um Sistema de Detecção de Intrusos

Dissertação apresentada, como requisito parcial para a obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em ; 20 de fevereiro de 2014.

Banca Examinadora:

_____

Profª. Drª. Maria Luiza Fernandes Velloso (Orientadora)
Faculdade de Engenharia, UERJ

_____

Prof. Dr. Nival Nunes de Almeida (Coorientador)
Faculdade de Engenharia, UERJ

_____

Prof. Dr. Orlando Bernardo Filho
Faculdade de Engenharia, UERJ

_____

Profª. Drª. Karla Tereza Figueiredo Leite
Pontifícia Universidade Católica do Rio de Janeiro, PUC-RIO

Rio de Janeiro

2014

DEDICATÓRIA

A meus pais, saudades eternas, por todo amor e dedicação que me dispensaram ao longo de suas vidas, sempre me orientando a ter fé e nunca desistir dos meus sonhos, por mais distantes que estivessem, e a minha esposa, Rebecca Galera.

AGRADECIMENTOS

A todos aqueles que de alguma forma me incentivaram, ajudaram e compartilharam das minhas dificuldades, das minhas ausências, dos meus momentos mal-humorados, dos momentos de alegria por ter galgado mais um degrau no trabalho, dos meus sentimentos e das experiências por mim vividas. Entre todos, não poderia deixar de tecer agradecimentos especiais àqueles que diretamente contribuíram por mais esta etapa em minha vida.

A minha orientadora, professora Dra. Maria Luiza Fernandes Velloso, pelo apoio, paciência e conhecimentos transmitidos ao longo do curso.

Ao meu coorientador, professor Dr. Nival Nunes de Almeida, por toda ajuda, atenção e todo apoio dispensados.

À Universidade do Estado do Rio de Janeiro – UERJ, por ter me recebido e apoiado ao longo do curso.

À Dra. Maria Cristina Zamberland, do Instituto Nacional de Tecnologia, por ser uma fiel incentivadora dos meus estudos.

Ao amigo Me. Joaquim Augusto, da Divisão de Energia do Instituto Nacional de Tecnologia, que me trilhou e incentivou aos estudos na UERJ.

Ao Instituto Nacional de Tecnologia, através da Comissão de Pós-Graduação, pela concessão de participação no Programa de Pós-Graduação *Stricto-Sensu* da UERJ.

RESUMO

CASTRO, Ricardo Ferreira Vieira. **Análise de desempenho dos algoritmos Apriori e *Fuzzy* Apriori na extração de regras de associação aplicados a um Sistema de Detecção de Intrusos**. 2014. 124f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2014.

A extração de regras de associação (ARM - Association Rule Mining) de dados quantitativos tem sido pesquisa de grande interesse na área de mineração de dados. Com o crescente aumento das bases de dados, há um grande investimento na área de pesquisa na criação de algoritmos para melhorar o desempenho relacionado a quantidade de regras, sua relevância e a performance computacional. O algoritmo APRIORI, tradicionalmente usado na extração de regras de associação, foi criado originalmente para trabalhar com atributos categóricos. Geralmente, para usá-lo com atributos contínuos, ou quantitativos, é necessário transformar os atributos contínuos, discretizando-os e, portanto, criando categorias a partir dos intervalos discretos. Os métodos mais tradicionais de discretização produzem intervalos com fronteiras sharp, que podem subestimar ou superestimar elementos próximos dos limites das partições, e portanto levar a uma representação imprecisa de semântica. Uma maneira de tratar este problema é criar partições soft, com limites suavizados. Neste trabalho é utilizada uma partição fuzzy das variáveis contínuas, que baseia-se na teoria dos conjuntos fuzzy e transforma os atributos quantitativos em partições de termos linguísticos. Os algoritmos de mineração de regras de associação fuzzy (FARM - Fuzzy Association Rule Mining) trabalham com este princípio e, neste trabalho, o algoritmo FUZZYAPRIORI, que pertence a esta categoria, é utilizado. As regras extraídas são expressas em termos linguísticos, o que é mais natural e interpretável pelo raciocício humano. Os algoritmos APRIORI tradicional e FUZZYAPRIORI são comparado, através de classificadores associativos, baseados em regras extraídas por estes algoritmos. Estes classificadores foram aplicados em uma base de dados relativa a registros de conexões TCP/IP que destina-se à criação de um Sistema de Detecção de Intrusos.

Palavras-chave: Apriori. *Fuzzy* Apriori. Extração de regras de associação. Regras de classificação associativa. Detecção de intrusos.

ABSTRACT

CASTRO, Ricardo Ferreira Vieira. **Performance analysis of algorithms Apriori and Fuzzy Apriori in association rules mining applied to a System for Intrusion Detection**. 2014. 124f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2014.

The mining of association rules of quantitative data has been of great research interest in the area of data mining. With the increasing size of databases, there is a large investment in research in creating algorithms to improve performance related to the amount of rules, its relevance and computational performance. The APRIORI algorithm, traditionally used in the extraction of association rules, was originally created to work with categorical attributes. In order to use continuous attributes, it is necessary to transform the continuous attributes, through discretization, into categorical attributes, where each categorie corresponds to a discrete interval. The more traditional discretization methods produce intervals with sharp boundaries, which may underestimate or overestimate elements near the boundaries of the partitions, therefore inducing an inaccurate semantical representation. One way to address this problem is to create soft partitions with smoothed boundaries. In this work, a fuzzy partition of continuous variables, which is based on fuzzy set theory is used. The algorithms for mining fuzzy association rules (FARM - Fuzzy Association Rule Mining) work with this principle, and, in this work, the FUZZYAPRIORI algorithm is used. In this dissertation, we compare the traditional APRIORI and the FUZZYAPRIORI, through classification results of associative classifiers based on rules extracted by these algorithms. These classifiers were applied to a database of records relating to TCP / IP connections that aims to create an Intrusion Detection System.

Keywords: Apriori. Fuzzy Apriori. Fuzzy Association Rule Mining. Associative classification rule. Intruder Detection.

.

LISTA DE ILUSTRAÇÕES

LISTA DE GRÁFICOS

LISTA DE TABELAS

LISTA DE SIGLAS E ABREVIATURAS

AMD	Advanced Micro Devices
ARFF	Attribute-Relation File Format
ARM	Association Rule Mining
BN	Bayesian Networks
CBA	Classification Based on Association
CFA -R	Classifier Fuzzy Association Rule
CSV	Comma Separated Values
FARM	*Fuzzy* Association Rule Mining
FPR	False Positive Rate
GB	Giga Byte
GUI	Graphical User Interface
HIDS	Host Intrusion Detection System
IDS	Intruder Detection System
KDD	Knowledge Discovery in Databases
KEEL	Knowledge Extraction based on Evolutionary Learning
NIDS	Network Intrusion Detection System
RAM	Random Access Memory Random
SBP	Sharp Boundary Problem
UCI	University of California, Irvine
WEKA	Waikato Environment for Knowledge Analysis

SUMÁRIO

INTRODUÇÃO

"O saber a gente aprende com os mestres e com os livros.
A sabedoria se aprende é com a vida e com os humildes."
Cora Coralina

Este trabalho realiza uma análise de desempenho entre algoritmos para extração de regras de associação aplicados em base de dados que possuem atributos de valores quantitativos, através de uma avaliação da quantidade de regras de associação extraídas e pela respectiva acurácia de acerto dessas regras.

1 PROPOSTA DE TRABALHO

A extração de regras de associação de uma base de dados, conhecida como *Association Rule Mining* (ARM), é normalmente aplicada para o problema de descoberta de conjuntos de itens frequentes e posterior extração de regras de associação destes conjuntos. Entretanto, uma base de dados, em muitos dos casos, possui um conjunto de atributos que podem ser quantitativos[1] ou qualitativos[2]. Por exemplo, uma das técnicas aplicadas para extração de regras de associação que possuem atributos quantitativos utiliza o conceito *FUZZY*, mais conhecido como *Fuzzy Association Rule Mining* (FARM). A base de dados utilizada neste trabalho, denominada de *KDD Cup 1999 Data*, foi empregada na Terceira Competição Internacional de descoberta de conhecimento de mineração de dados. Essa base é composta por um padrão de dados a serem auditados que inclui uma grande variedade de intrusões simuladas em um ambiente de rede militar. Inicialmente, esses dados passaram por algumas etapas de pré-processamento até o seu resultado final, tais como: seleção de atributos relevantes e reamostragem dos dados.

---

[1] Variáveis quantitativas: são as características que podem ser medidas em uma escala quantitativa, ou seja, apresentam valores numéricos que fazem sentido. Podem ser contínuas ou discretas.
[2] Variáveis qualitativas (ou categóricas): são as características que não possuem valores quantitativos, mas, ao contrário, são definidas por várias categorias, ou seja, representam uma classificação dos indivíduos. Podem ser nominais ou ordinais.

A abordagem proposta neste trabalho é apresentar a comparação dos algoritmos Apriori e *Fuzzy* Apriori, aplicados a extração de regras de associação, no contexto de atributos que possuem valores quantitativos. Basicamente, no primeiro, os valores quantitativos são particionados em valores binários, e no segundo, utilizando conceitos fuzzy, particionados em termos de pertinência e suas respectivas funções de pertinência.

Essa abordagem ajudará a fazer uma análise dos algoritmos Apriori e *Fuzzy* Apriori, pela qual, através da classificação das regras de associação geradas, será possível avaliar em que condições qual o algoritmo apresenta melhor acurácia de acerto no reconhecimento de ataques de um sistema de detecção de intrusos.

1.1 Motivação

As últimas duas décadas vieram acompanhadas de um aumento exponencial na quantidade de informações que são armazenadas em Data Center. A Internet e seus serviços de e-commerce ampliaram o acúmulo de dados, que acontecem a uma taxa surpreendente. Bancos de Dados estão cada vez mais volumosos, mas, nossa capacidade de analisar e compreender essa massa de dados está bem aquém de nossa habilidade em coletar e armazenar dados. O valor destes dados armazenados está tipicamente ligado à capacidade de extrair informações de mais alto nível que se encontram subjacente a eles, ou seja, informação útil que sirvam para dar suporte a decisões e para explorar e melhor entender o fenômeno gerador dos dados. Podem existir padrões ou tendências úteis interessantes que, se descobertos, podem ser utilizados, por exemplo, para otimizar um processo de negócio em uma empresa, ajudar no entendimento dos resultados de um experimento científico, ajudar médicos a entender efeitos de um tratamento, entre outros benefícios. Neste contexto está situado o KDD *(Knowledge Discovery in Databases*) (FAYY, 1996), que busca extrair de grandes bases de dados as informações que não podem ser facilmente encontradas.

Inserida neste processo de descoberta, existe a etapa de *Data Mining* (Mineração de Dados), em que são aplicadas técnicas para descoberta de novos conhecimentos. Juntamente com as etapas de Seleção, Processamento,

Transformação e Interpretação, a Mineração de Dados completa as fases do processo de KDD. Diversas definições de Mineração de Dados podem ser encontradas na literatura. Entre elas podemos destacar que *mineração de dados, de forma simples, é o processo de extração ou mineração de conhecimento em grandes quantidades de dados* (HAN,KAMBER, 2001).

O processo de mineração pode ser utilizado em diversos tipos de banco de dados, e em função destes se pode definir que tipo de padrão ou relacionamento se deseja minerar. A aplicação ou funcionalidade da mineração de dados vai definir o tipo de relacionamento entre as instâncias e seus atributos utilizados na mineração. Dentro do processo de mineração, essa funcionalidade é conhecida por alguns autores, como resultados (*outcomes*) ou tarefas (*tasks*) (CORTEZ, PORCARO, LIFSCHITZ, 2002). Diversos autores tratam essas tarefas de diferentes formas, mas as mais regularmente utilizadas são Classificação, Regressão, Clusterização e Associação, que é a tarefa-tema desta dissertação.

Regras de associação são usadas para descobrir elementos que ocorrem em comum dentro de um determinado conjunto de dados (MENZIES, HU, 2003). Ou seja, buscar correlação entre atributos, cujo objetivo é encontrar itens que são mais frequentes e que impliquem na presença de outros na mesma transação. A identificação desses itens frequentes destina-se a identificar as regras fortes descobertas em bancos de dados usando diferentes medidas de interesse (suporte e confiança) (SHAPIRO, FRAWLEY, 1991) . Baseado no conceito de regras fortes, AGRAWAL et al. (1993) introduziu regras de associação para descobrir regularidades entre os produtos vendidos em transações de grande porte registradas por ponto de venda (POS) nos sistemas em supermercados. Uma regra de associação é uma expressão X → Y, em que X é um conjunto de itens e Y é um item único. Isto significa, num conjunto de transações, que, se todos os itens contidos em X existem em uma transação, então Y também ocorre na transação com alta probabilidade. Por exemplo, assume-se que consumidores que compraram pão e manteiga também compraram leite. Então a regra de associação "Pão e Manteiga → Leite" será minerada. Essa análise associativa ficou conhecida como *Market Basket Analisys*.

Prosseguindo com esse detalhamento do ambiente KDD, Mineração de Dados e Regras de Associação, encontramos vários estudos de algoritmos para a implementação desta tarefa de Associação no contexto da Mineração de Dados. Um

grande número de algoritmos para extração de regras de associação tem sido desenvolvido com diferentes eficiências. Qualquer algoritmo pode encontrar o mesmo grupo de regras, mas a eficiência computacional e o consumo de memória podem ser diferentes. Muitos dos esforços na pesquisa de regras de associação têm sido orientados para simplificar o conjunto de regras gerada e melhorar a performance do algoritmo. Mas esses não são apenas os únicos problemas que podem ser encontrados quando as regras são geradas e aplicadas em diferentes domínios. Outros problemas precisam ser levados em consideração na proposta de modelos de associação, e algumas das desvantagens de algoritmos de regras de associação são: i) grande número de regras, ii) regras não interessantes, iii) baixa performance do algoritmo (MORENO, et al., 2005). Alguns dos principais algoritmos utilizados na implementação da mineração de itens frequentes e extração de regras baseadas no limite de corte mínimo das medidas de suporte e confiança são: Apriori (AGRAWAL, SRIKANT, 1994), FP-Growth (HAN et al., 2004), ECLAT(ZAKI, 2000), dentre outros.

Os primeiros estudos de algoritmos na extração de regras de associação identificava a relação entre transações de um mesmo conjunto de dados usando valores binários, no entanto, transações com valores quantitativos são comumente vistas nas aplicações do mundo real. AGRAWAL et al. (1996), dando continuidade a suas pesquisas, propôs um método para extração de regras de associação de atributos com valores quantitativos. Seu método proposto transforma os itens quantitativos em itens binários através da partição dos atributos com domínio quantitativo. Por exemplo, se o item Idade numa base de dados D possui valores de (0, 100], então ele pode ser particionado em três novos itens como Idade (0,30], Idade (30,60] e Idade (60,100] respectivamente. No entanto, esse método proposto não resolve o problema conhecido como *sharp boundaries* que consiste em poder subestimar ou superestimar elementos próximos dos limites da partição, e portanto levar a uma representação imprecisa de semântica.

Para tratar o problema de *sharp boundaries*, uma nova técnica utilizando *fuzzy sets* e *fuzzy* itens, normalmente em forma de rótulos ou termos linguísticos, é usada e definida no domínio. KUOK et al. (1998) assim descreve *fuzzy association rules mining* (FARM): "*Extração de regras de associação fuzzy é o descobrimento das regras de associação usando conceito fuzzy set de tal modo que atributos quantitativos podem ser manipulados*". Por exemplo, o atributo Idade pode parecer

tal como F_{idade} = {criança, jovem, adulto, idoso}. O conceito de conjuntos *fuzzy* tem se mostrado melhor que o método de partição em itens binários porque conjuntos *fuzzy* proporcionam uma transição suave entre os membros e não membros de um conjunto, consequentemente, tratam melhor o problema de *sharp boundaries*. As regras extraídas são expressas em termos linguísticos, mais naturais e interprestáveis para os seres humanos.

Tradicionalmente, a análise de regras de associação tem sido considerada como uma técnica não supervisionada, por isso tem sido aplicada para tarefas de descoberta de conhecimento. Estudos têm mostrado que os algoritmos de descoberta de conhecimento, como a mineração de regras de associação, podem ser aplicados com sucesso para a previsão de problemas de classificação. Nesses casos, os algoritmos usados para a geração de regras de associação devem ser adaptados às peculiaridades de previsões, a fim de construir classificadores eficazes. Alguns trabalhos foram realizados em que algoritmos de mineração de associação foram modificados de modo que possam ser utilizados para a classificação / previsão. A proposta desta categoria de classificadores denominada de *class association rules* (CARs) é o algoritmo de classificação baseada em associação *CBA (Classification Based on Association)*. O algoritmo consiste de duas partes: um gerador de regra que é baseado no algoritmo Apriori para encontrar regras de associação em AGRAWAL, SRIKANT (1994), e um construtor de classificador com base nestas regras (LIU et al., 1998).

1.2 Objetivos

Visando a estabelecer parâmetros para comparação de desempenho entre técnicas aplicadas na tarefa de extração de regras de associação da etapa de mineração de dados com atributos compostos de valores quantitativos, os objetivos estão assim definidos:

- analisar o desempenho dos algoritmos para extração de regras de associação Apriori e *Fuzzy* Apriori.
- preparar a base de dados, extraída de um sistema de detecção de intruso, para os experimentos.

- estabelecer métricas para medir o desempenho: i) quantitativo de regras de associação extraídas e ii) acurácia das regras de associação extraídas.
- utilizar ferramentas GUI (*Graphical User Interface*) para os experimentos:
    - WEKA (*Waikato Environment for Knowledge Analysis*) (HALL et al., 2009) para o algoritmo Apriori e classificador.
    - KEEL (*Knowledge Extraction based on Evolutionary Learning***)** (ALCALA et al., 2011) para o algoritmo *FUZZY* APRIORI e classificador.

1.3 Estrutura da dissertação

A dissertação está estruturada em quatro capítulos. O capítulo 1 introduz a proposta de trabalho com a motivação, objetivo e estrutura da dissertação. O capítulo 2 aborda a Fundamentação Teórica, levando em consideração toda a teoria aplicada no trabalho. O capítulo 3 apresenta uma breve abordagem de Sistema de Detecção de Intruso. O capítulo 4 o Experimento com as ferramentas utilizadas, a descrição dos dados e toda a metodologia desenvolvida. O capítulo 5 traduz todos os resultados e realiza a análise dos experimentos.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo trata da fundamentação teórica necessária para a evolução do trabalho: a base teórica de temas relacionados ao estado da arte, Descoberta de Conhecimento em Base de Dados, mineração de regras de associação CRISP e *FUZZY*, a abordagem simplificada de sistema de detecção de intruso e as ferramentas de mineração de dados utilizadas.

2.1 Antecedentes e Estado da arte

Várias técnicas de mineração de dados tem sido aplicadas na detecção de intrusão, pois têm a vantagem de descobrir conhecimento útil que descreve o comportamento do usuário a partir de grandes conjuntos de dados. Indução de regras de associação é uma das abordagens mais conhecidas em técnicas de mineração de dados. A grande maioria dos trabalhos relacionados utiliza o conjunto de dados KDD99[3]. No entanto, diferentes *frameworks*[4], categorias de ataques escolhidos, métodos de avaliação, algoritmos etc. se diferenciam entre os estudos deste tema.

WU et al. (2011), propôs um *framework* onde o sistema de classificação, que é o centro do Sistema de Detecção de Intruso, utiliza regras de associação fuzzy para construir o classificador. O experimento foi realizado em duas etapas: treinamento e detecção. O conjunto de amostra é estabelecido pela extração de regras de associação fuzzy. Na fase de classificação, o conjunto de amostra que corresponde ao conjunto de regras será rotulado pelo classificador onde o atributo de saída classe tem todos os possíveis tipos de ataques. O conjunto de dados KDD99 é usado nos experimentos. Ou seja, as regras de associação fuzzy são usadas para construir o classificador. O classificador foi implementado na linguagem

---

[3] Conjunto de dados usado em *The Third International Knowledge Discovery and Data Mining Tools Competition* - http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html

[4] *Framework* é um conjunto de classes que colaboram para realizar uma responsabilidade para um domínio de um subsistema da aplicação (FAYAD e SCHMIDT).

standard C e, para as regras de associação Booleana, foi utilizada a implementação segundo Borgelt´s [5]. Os resultados apontam taxa de detecção de 96.0% para ataques conhecidos, 13% para ataques não conhecidos e 92.5% para todos os tipos de ataques. E a taxa de falso positivo de 3.22% para os ataques conhecidos, não conhecidos e todos os tipos de ataques.

EL-SEMARY et al. (2006) usando um sistema de mineração de dados que integra o algoritmo Apriori e Fuzzy Apriori (Kuok) para gerar regras fuzzy, capta as características de interesse do tráfego de rede. Usando um motor de inferência, implementado usando *FuzzyJess,* o sistema de detecção de intrusos avalia essas regras e sinaliza para o administrador da rede indicações para se disparar o conjunto de regras. A arquitetura utilizada pelo Sistema de Detecção de Intruso possui dois modos de operação: gerador de regras e detecção. Quando operando no modo de geração de regras o sistema processa os dados da rede e usa algoritmo de mineração de dados fuzzy para gerar as regras. Um subconjunto de regras gerado pelo algoritmo é usado como modelo para os dados de entrada. O modo de detecção usa este subconjunto de regras para detecção de intruso. Um módulo de mineração de dados integra os algoritmos Apriori e KuoK para gerar as regras fuzzy. O motor de inferência utilizado utiliza FuzzyJess para avaliar as regras fuzzy. *FuzzyJess* é um sistema especialista que integra componentes da lógica fuzzy do *FuzzyJ Toolkit* com *Jess*[6]. A base de dados utilizada no experimento foi 1999 DARPA e no experimento foi utilizado apenas o tipo de ataque *ipsweep* para detecção. A métrica utilizada no sistema de detecção de intruso foi baseada em anomalia e em assinatura. Como resultado, foi revelado presença de ataque para um mesmo conjunto de dados e dois conjuntos de regras totalmente diferentes.

Em IDRIS et al. (2009) foi proposta a criação de um sistema baseado em lógica *fuzzy* para identificar de forma eficaz as atividades de detecção de intruso na rede. Seu modelo híbrido, incorporando técnicas melhoradas da lógica *fuzzy* e de mineração de dados, tinha como objetivo detectar ataques do tipo *uso indevido* e do tipo *anomalia*. Neste trabalho, focado também na acurácia, foi extraído os atributos relevantes para distinguir as atividades normais dos ataques. Para seleção de atributos foi usado o algoritmo tradicional que utiliza ganho de informação para

---

[5] Christian Borgelt em http://www.borgelt.net/index.html.

[6] *Java Expert System Shell.*

seleção de cada atributo, e para mineração de dados uma variação do algoritmo KUOK (1998) é aplicado. O algoritmo extrai os *itemsets* mais utilizados e constrói as regras baseadas nesses *itemsets*. As regras com grau de confiança maior ou igual ao valor mínimo de confiança previamente definido são armazenados num banco de regras. Uma máquina de inferência determina que regras são relevantes para os dados. Um protótipo utiliza a ferramenta *FuzzyJess* para avaliar as regras, e são considerados três variáveis de entrada: os dados capturados, atributos relevantes e regras extraídas. A saída da máquina de inferência consiste em um atributo classe nomeado de alerta com duas classes de saída: atividade normal ou ataque. A base de dados utilizada no experimento foi 1999 DARPA e no experimento foi utilizado apenas o tipo de ataque *smurf* para detecção. As regras inseridas num motor de inferência tiveram um percentual de detecção de 90% para o método de *uso indevido* e 85% para *anomalias*.

No estudo realizado por CHAPKE et at. (2012), foi utilizada a mesma proposta de IDRIS et al. (2009) com a mesma base de dados 1999 DARPA. No entanto, o trabalho sugere que foram considerados todos os tipos de ataque para detecção no sistema de inferência com duas opções de saída: atividade normal ou ataque. Como resultado o trabalho indica apenas a redução de atributos para uma rápida detecção de ataques e a redução de ataques falso positivos, mas não indica os valores dos resultados.

2.2 Descoberta de Conhecimento em Banco de Dados

No mundo dos negócios das organizações, a informação é o ativo de maior valor, tornando-se essencial na competitividade de qualquer empresa, independente de seu porte. O valor de uma tomada de decisão estratégica depende das informações disponíveis aos executivos das organizações, da capacidade de interpretá-las e da experiência para associá-las de maneira que conduzam à melhor decisão. A gerência e a condução das informações são partes integrantes do estudo sobre Gestão do Conhecimento (GC). Segundo DAVENPORT e PRUSAK (1998), a GC pode ser vista como um conjunto de ações gerenciais contínuas e sistemáticas

que auxiliam os processos de criação, registro e compartilhamento do conhecimento nas organizações.

Estudos na área de Inteligência Computacional têm auxiliado a obtenção dessas informações através do processo de *Knowledge Discovery in Databases (KDD).* O termo KDD (Descoberta de Conhecimento em Banco de Dados) foi formalizado em 1989, em referência ao amplo conceito de se procurar conhecimento útil em base de dados. Segundo FAYYAD, PIATETSKY-SHAPIRO e SMYTH (1996), "*KDD é um processo, de várias etapas, não trivial, interativo e iterativo, para identificação de padrões compreensíveis, válidos, novos e potencialmente úteis a partir de grandes conjuntos de dados*". Porém, a extração de conhecimento de uma grande base de dados através da aplicação de um processo de KDD exige a melhor compreensão das diferenças entre dado, informação e conhecimento.

2.2.1 As etapas do processo de KDD

O processo de KDD é composto por três fases operacionais (Figura 1):

1ª fase: pré-processamento que compreende as funções que se relacionam à captação, à organização e ao tratamento de dados, cujo objetivo é preparar os dados para os algoritmos da etapa seguinte;

2ª fase: mineração de dados, que realiza a busca efetiva de conhecimentos úteis no contexto proposto para a aplicação do KDD;

3ª fase: pós-processamento, que abrange o tratamento do conhecimento obtido na etapa anterior (GOLDSCHIMIDT e PASSOS, 2005).

Figura 1 - Fases operacionais do processo de KDD

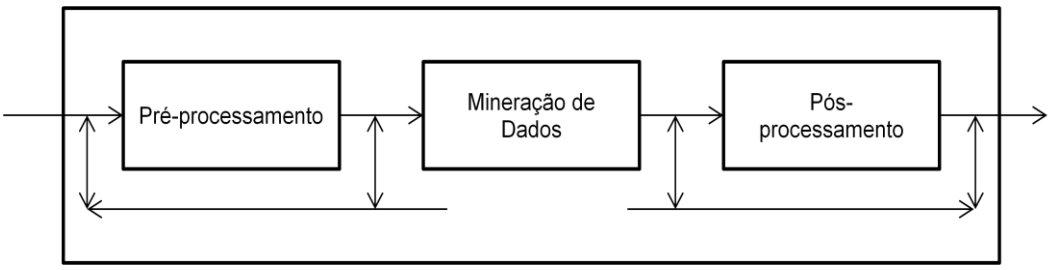

Fonte: GOLDSCHIMIDT e PASSOS, 2005.

De acordo com MAIMON e ROKACH (2005), as etapas da KDD possuem quatro etapas adicionais ao modelo de FAYYAD (1996), sendo duas delas conceituais (uma no início e outra no final do processo), e a etapa de Mineração de Dados é desdobrada em duas outras etapas internas (Figura 2).

Figura 2 – Etapas do processo de KDD

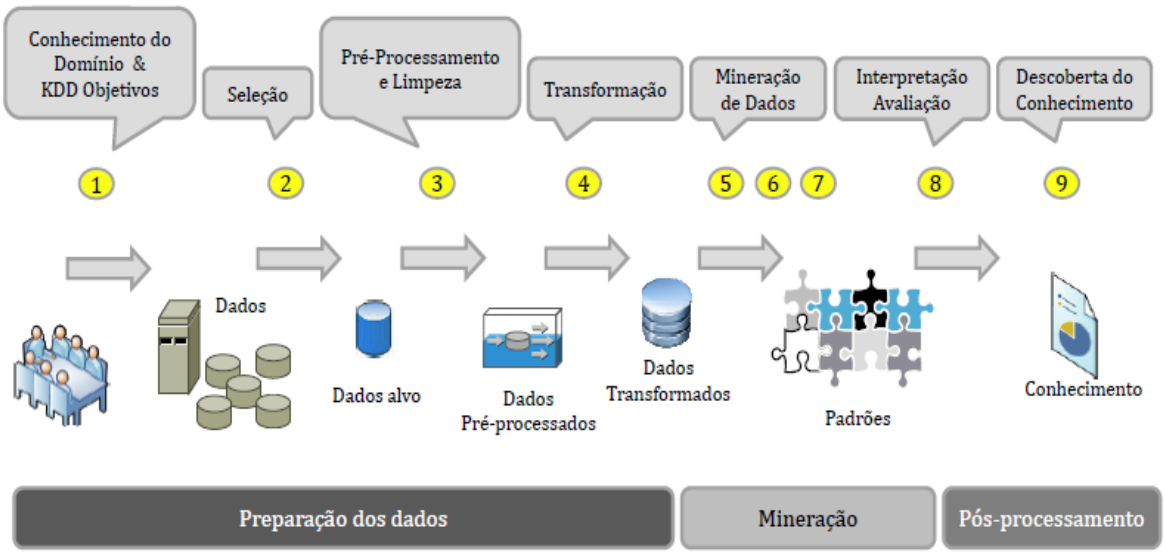

Fonte: O autor, 2013. Modificado - MAIMON e ROKACH (2005).

A seguir, tem-se uma breve descrição das nove etapas do processo de KDD, demonstrado na Figura 2, começando pela etapa de conhecimento do domínio e definição dos objetivos do KDD.

i. **O desenvolvimento de uma compreensão do domínio da aplicação:** Essa é a etapa inicial. Ela prepara o cenário para entender o que deve ser feito com as muitas decisões que deverão de ser tomadas. As pessoas que estão na gerência de um projeto de KDD precisam entender e definir os objetivos do usuário final e do ambiente em que o processo de descoberta de conhecimento terá lugar. Conforme o processo de KDD avança, pode haver até mesmo uma revisão desta etapa.

ii. **Selecionando e criando um conjunto de dados sobre o qual vai ser realizada a descoberta de conhecimento: u**ma vez definidos os objetivos, os dados que vão ser utilizados para a descoberta de conhecimento devem ser determinados. Isso inclui descobrir que dado está disponível, obtendo dados adicionais se necessário, e, em seguida, integrando todos os dados

para a descoberta de conhecimento em um conjunto de dados, incluindo os atributos que serão considerados para o processo.

iii. **Pré-processamento e limpeza:** nessa etapa, a confiabilidade dos dados é melhorada. Isso inclui limpeza de dados, como manipulação de valores faltosos e remoção de ruído ou discrepantes.

iv. **Transformação de dado**. nessa fase, a geração de melhores dados para a próxima etapa de extração de dados (*Data Mining*), é preparada e desenvolvida. Alguns métodos aqui incluem redução de dimensão e transformação de atributo (como discretização de atributos numéricos e transformação funcional). Tal etapa pode ser crucial para o sucesso de todo o projeto KDD, e é geralmente muito específica. Tendo completado as quatro etapas acima, as quatro etapas seguintes estão relacionados com a parte de *Data Mining*, cujo foco é sobre os aspectos algorítmicos empregados para cada projeto.

v. **Escolhendo a tarefa apropriada de Mineração de Dados (*Data Mining*)**: nessa etapa é preciso definir que tipo de Mineração de Dados será usado, por exemplo, classificação, regressão, ou *clustering*. Isso depende principalmente dos objetivos de KDD, e também das etapas anteriores. Há dois objetivos principais em *Data Mining*: predição e descrição. Predição é muitas vezes referida como *Data Mining* supervisionado, enquanto *Data Mining* descritivo inclui os aspectos não supervisionados e a visualização de *Data Mining*.

vi. **Escolhendo o algoritmo de Mineração de Dados *(Data Mining)***: definindo-se a estratégia agora é decidir sobre as táticas. Esta etapa inclui selecionar o método específico a ser utilizado para a busca de padrões.

vii. **Empregando o algoritmo de Mineração de Dados (Data Mining):** finalmente, a execução do algoritmo de mineração de dados é alcançada. Nesta etapa pode ser preciso aplicar o algoritmo várias vezes até que um resultado satisfeito seja obtido, por exemplo, por meio do ajuste de parâmetros de controle do algoritmo.

viii. **Avaliação**: nessa etapa, são avaliados e interpretados os padrões extraídos (regras, confiabilidade etc), com relação às metas definidas na primeira etapa, centrando-se na compreensão e utilidade do modelo induzido. A última etapa é o uso e *feedback* geral sobre os padrões e os resultados descobertos e obtidos durante a etapa de *Data Mining*.

ix. **Usando o conhecimento descoberto**: nessa última etapa, o conhecimento torna-se ativo no sentido de que podemos fazer alterações no sistema e medir os efeitos. Na verdade, o sucesso deste passo determina a eficácia global do processo de KDD.

2.2.2 Mineração de Dados (Data Mining)

A etapa de mineração de dados localizada entre o Pré-processamento e o Pós-processamento torna-se muito importante de todo no processo KDD, pois é nela que são aplicadas as técnicas (algoritmos) de busca de conhecimentos a serem utilizados no problema em questão, que podem ser feitas através de Redes Neurais, Algoritmos Genéticos, Lógica Difusa, modelos estatísticos e probabilísticos (GOLDSCHIMIDT e PASSOS, 2005). Neste caso, têm-se os seguintes passos:

a. Seleção da tarefa de mineração de dados: uma ou outra combinação de tarefas deve ser selecionada dentre os diversos tipos de tarefas possíveis, dentre as mais utilizadas: classificação, regressão, agrupamento e associação.
b. Escolha da técnica de mineração de dados: em função da tarefa selecionada, uma técnica específica, também denominada de algoritmo, será aplicada nos dados.
c. Aplicação de mineração de dados: busca por padrões de interesse em uma forma representacional particular ou em um conjunto de aplicações.

A maioria dos autores considera as principais tarefas da etapa de mineração de dados como sendo classificação, regressão, agrupamento e associação, as quais são descritas a seguir, segundo BERRY e LINOFF (1997).

- *Classificação* consiste em analisar previamente as característica dos objetos e atribuir a cada um deles um conjunto predefinido de classes. Os objetos a serem classificados são geralmente representados por registros em banco de dados, e o ato de classificação consiste em adicionar uma nova coluna com algum tipo de código de classe.
- *Regressão* é similar à classificação, porém a principal diferença é quanto à natureza do atributo a ser predito, que é quantitativo em vez de ser

qualitativo (discreto) (TAN et al., 2006). Assim, é possível estimar o valor de uma determinada variável, analisando-se os valores das demais.

- *Agrupamento* ou *Clustering* visa a segmentar um conjunto de dados heterogêneos num número de subgrupos mais homogêneos. Seu objetivo é formar grupos de registros o mais homogêneos em si, porém o mais heterogêneo dos outros grupos de dados. A diferença fundamental entre a formação de agrupamento e a classificação é que no agrupamento não existem classes predefinidas (aprendizado não supervisionado) para classificar os registros. Os registros são agrupados em função de suas similaridades básicas, ou seja, quando se deseja formar agrupamentos.
    - *Associação,* também conhecida na área de marketing como grupos de afinidade ou *basket market analysis*, determina que "coisas" estão relacionadas, ou seja, descobre as regras de associação condicionadas a valores de atributos que ocorrem juntos em um conjunto de dados. Aplica-se casos em que se deseja estudar preferências, afinidades entre itens, visando principalmente criar agrupamento de produtos, formando pacotes de oportunidades para consumidores.

2.2.3 Regras de associação na Mineração de Dados

Segundo LAROSE (2005), regras de associação ou análise de afinidades é o estudo dos atributos ou categorias de itens que estão relacionados, ou seja, aqueles que possuem alguma associação entre si. A representação do problema de extração de regras de associação foi proposto inicialmente por AGRAWAL et al. (1993), que introduziu regras de associação para descobrir regularidades entre os produtos vendidos em transações de grande porte registradas por ponto de venda (POS) nos sistemas em supermercados.

Métodos de regras de associação, tal como *market basket analysis*, procuram descobrir associações entre os atributos de forma a quantificar a relação entre dois ou mais atributos. Para transmitir a ideia de análise da cesta de mercado, observa-se a figura do carrinho de compras na Figura 3 contendo vários produtos adquiridos por um consumidor em um determinado supermercado.

Figura 3 – Análise de cesta de mercado ajuda a entender consumidores.

Fonte: BERRY e LINOFF (1997).

Um carrinho de compras nos informa sobre o que um cliente comprou em uma ida ao supermercado. Logo, podemos concluir que uma lista completa de compras feitas por todos os clientes em um determinado período fornece muito mais informações importantes, tais como que produtos e quando. Cada cliente compra produtos diferenciados uns dos outros, em quantidades diferentes e em épocas diferentes. A análise de cesta de mercado sugere informações relevantes sobre os produtos, como, por exemplo, que produtos tendem a ser adquiridos em conjunto e que são mais favoráveis à promoção. Isso também impacta em revisão do layout das lojas, fazendo com que os clientes sejam induzidos a adquirir produtos que normalmente não seriam adquiridos se estivem em outra posição A tarefa de mineração de dados afinada com a análise de cesta de mercado remete à geração de regras de associação que representam padrões nos dados e padrões de comportamento sem um alvo específico (BERRY e LINOFF,1997).

Regras de associação têm a forma "SE" (antecedente), "ENTÃO" (consequente), juntamente com medidas de suporte e confiança associadas à regra.

A medida de suporte *s* para uma regra de associação em particular $A => B$, em que A é o *antecedente* e B o *consequente*, é a proporção de transações no conjunto de dados *D* que contem ambos, *A* e *B*, definido por:

$$suporte = P(A \cap B) = \frac{número\ de\ transações\ que\ contêm\ ambos\ A\ e\ B}{total\ do\ número\ de\ transações} \quad (1)$$

A medida de confiança *c* para uma associação de regra $A => B$ é a medida de acurácia da regra, como determinado pelo percentual de transações em *D* contendo *A* que também contem *B*, definido por:

$$confiança = P(B|A) = \frac{P(A \cap B)}{P(A)} = \frac{número\ de\ transações\ que\ contêm\ ambos\ A\ e\ B}{número\ de\ transações\ que\ contêm\ A} \quad (2)$$

Por exemplo, um supermercado tem registrado em um dia da semana que, de 1000 consumidores, 200 compraram leite, e desses 200 que compraram leite, 50 compraram manteiga. Então, a associação de regra será: *Se* comprou leite (antecedente), *então* comprou manteiga (consequente), com medida de *suporte* de 50/100 = 5% e a medida de *confiança* de 50/200 = 25%.

2.3 Sistemas Baseados em Regras *Fuzzy*

A lógica nebulosa, difusa ou *fuzzy*, foi desenvolvida nos anos 60 por Lofti A. Zadeh, professor no departamento de engenharia elétrica e ciências da computação da Universidade da Califórnia, em *Berkeley* nos Estados Unidos, com o objetivo de fornecer um ferramental matemático para o tratamento de informações de caráter impreciso ou vago e auxiliar no controle e tomada de decisão.

A Teoria de Conjuntos *Fuzzy* e os Conceitos de Lógica *Fuzzy* têm vasta aplicação em diversos setores, e basicamente sua utilização é aplicada para traduzir em termos matemáticos a informação imprecisa expressa por um conjunto de regras linguísticas. Se um operador de um equipamento qualquer tiver a capacidade de traduzir sua forma de operar este equipamento em um conjunto de regras da forma

SE / ENTÃO, será possível desenvolver um algoritmo passível de ser implementado em computador. O resultado é um sistema de inferência baseado em regras, no qual a Teoria de Conjuntos *Fuzzy* e Lógica *Fuzzy* fornecem o ferramental matemático para se lidar com as tais regras linguísticas (TANSCHEIT, 2007).

Lógica *Fuzzy* pode ser definida como sendo os princípios formais de raciocínio aproximado, com raciocínio preciso visto como um caso específico (ZADEH, 1988). Em geral a lógica *Fuzzy* é descrita como uma lógica booleana convencional sem a restrição de que todas as variáveis devem ser 0 ou 1.

Segundo ROSS (1995), a linguagem natural é talvez a forma mais poderosa de transmitir informação que os seres humanos possuem para qualquer tipo de situação que exija uma solução ou raciocínio. Por essas razões é que a Lógica *Fuzzy* é implementada na liguagem natural.

Segundo JANG et al. (1995), a lógica *fuzzy* é uma forma conveniente para mapear um espaço de entrada para um espaço de saída. Semelhante a uma caixa preta que faz 'algo' para calcular a solução, ou seja, a saída. Este é o ponto de partida de tudo que será abordado nesta seção. Para representar o que seria dizer em mapear o espaço de entrada para o espaço de saída, temos o seguinte exemplo: Um cliente de um restaurante diz quão bom foi o serviço de atendimento, e será sugerido a ele um valor para a gorjeta (Figura 4).

Figura 4 - Exemplo de mapeamento de espaço de entrada e saída.

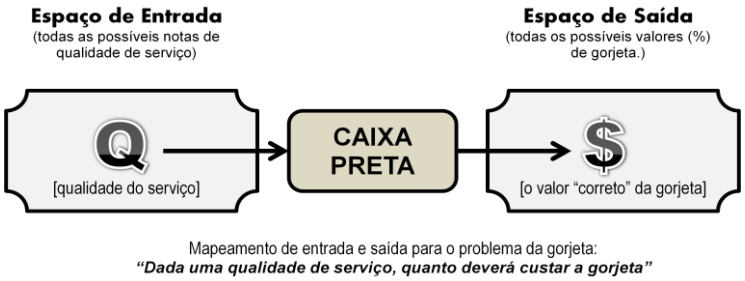

Fonte: Autor, 2014. Modificado - JANG et al., 1995.

Entre o espaço de entrada e o de saída existe uma caixa preta que vai executar "algo" para fazer este trabalho. Uma lista extensa poderia ser mencionada, tal como: sistemas *fuzzy*, sistemas lineares, sistemas especialista, redes neurais, equações diferenciais e tantas outras mais recentes quando da publicação deste

trabalho, tais como redes neuro-*fuzzy*, sistemas evolucionários agregados a outras soluções etc. Então por que usar a lógica *fuzzy*? Segundo ZADEH (1965), a resposta é porque normalmente é mais interpretável, rápido e mais barato que as outras soluções (JANG et al., 1995).

O principal mecanismo para se fazer essa interligação entre o espaço de entrada e o de saída, através da caixa preta, é uma lista de instruções da forma SE - ENTÃO, chamadas de regras. A construção de um interpretador de regras implica em definir todos os termos que se planeja usar e as características que os descrevem. No exemplo da gorjeta é preciso definir as faixas de qualidade de atendimento para se dizer o quão foi bom o atendimento.

O diagrama da Figura 5 é um roteiro básico do processo de inferência *fuzzy*, ao lado esquerdo do qual se tem uma visão genérica de um sistema difuso, e ao lado direito, um sistema *Fuzzy* específico (exemplo da gorjeta). Em resumo, o conceito de inferência *fuzzy* representado nesta figura é um método que interpreta os valores do vetor de entrada e, baseado em um conjunto de regras, atribui valores ao vetor de saída.

Figura 5 - Roteiro básico de inferência *fuzzy*.

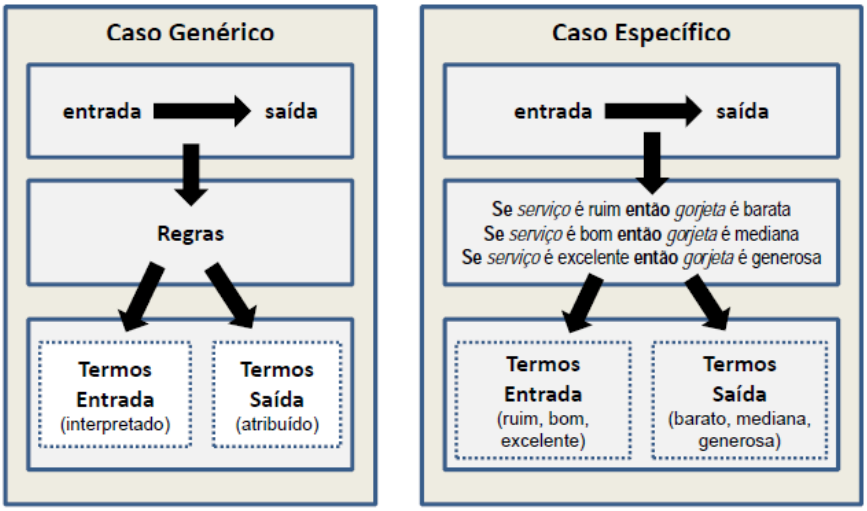

Fonte: Autor, 2014. Modificado - JANG et al., 1995.

2.3.1 Conjuntos *Fuzzy*

A principal limitação para a eficácia para a classe de sistemas especialistas[7] é o problema conhecido como *sharp boundary* (SBP), que leva à subestimação ou superestimação de elementos próximos dos limites da partição, como resultado da estratégia de particionamento de atributos quantitativos, o que, consequentemente, afeta a acurácia do sistema especialista (VERLINDE, COOK, e BOUTE, 2006).

Na teoria clássica, a pertinência de elementos em relação a um conjunto é assumida como termos binários de acordo com a sua condição *crisp*. Um elemento pode pertencer ou não a um conjunto: os limites desse conjunto são *crisp*. Ou seja, o conceito de pertinência de um elemento a um conjunto fica bem definido. Dado um conjunto *A* em um universo *X*, os elementos deste universo simplesmente pertencem ou não pertencem àquele conjunto. A função característica $f_A(x)$ expressa esse conceito.

$$f_A(x) = \begin{cases} 1 \; se \; e \; somente \; se \; x \in A \\ 0 \; se \; e \; somente \; se \; x \notin A \end{cases} \quad (3)$$

ZADEH (1965) propôs uma abordagem mais ampla, de tal forma que a função característica pudesse assumir um valor infinito de valores no intervalo [0,1]. Um conjunto *fuzzy A* em um universo *X* é definido por uma função de pertinência $\mu_A(x): X \rightarrow [0,1]$ e representado por um conjunto de pares ordenados

$$A = \left\{ \frac{\mu_A(x)}{x} \right\} \; x \in X \quad (4)$$

onde $\mu_A(x)$ indica o quanto x é compatível com o conjunto *A*. Dessa forma, um determinado elemento pode vir a pertencer a mais de um conjunto *fuzzy,* com diferentes graus de pertinência (TANSCHEIT, 2007).

Segundo KUOK et. al, 1998, o conceito de conjuntos *fuzzy* é melhor do que métodos de partição binária, porque conjuntos *fuzzy* permitem uma suave transação entre membro e não membro em relação ao seu conjunto. Consequentemente o tratamento do problema de SBP é contornado minimizando a exclusão do número de elementos próximo ao limite (*boundary*) (Figura 6). Para representar a diferença

[7] São Sistemas que têm como objetivo simular o raciocínio de um profissional especialista em alguma área de conhecimento bem específica.

entre lógica convencional da lógica *fuzzy*, o conjunto de altura das pessoas será usado como exemplo (Figura 7).

Figura 6 - Representação básica de conjunto *crisp* e *fuzzy*.

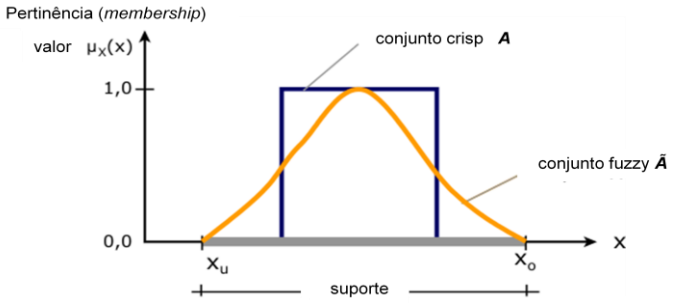

Figura 7 – Conjunto de altura das pessoas.

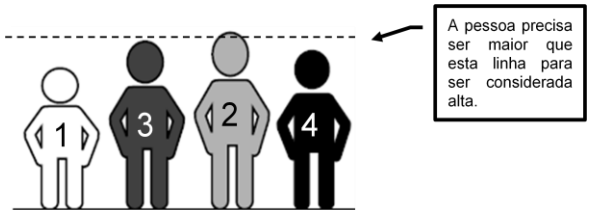

Fonte: Autor, 2014. Modificado - JANG et al., 1995.

A lógica convencional (*sharp boundary*) vai considerar a pessoa como "alta", por exemplo, com 180 cm ou mais, e como "baixa" se for menor que 180 cm (Figura 8). No entanto, se temos 2 pessoas, uma com 179.9 cm de altura e outra com 180.1 cm de altura, será considerada a primeira como sendo uma pessoa baixa, e a segunda como uma pessoa alta. Porém, não há sentido em se considerar uma pessoa baixa e outra alta se a diferença entre elas é de somente 0.2 cm.

Figura 8 – Conjunto *crisp* de altura das pessoas.

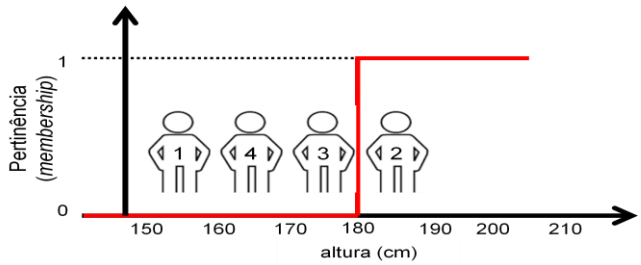

Fonte: Autor, 2014. Modificado - JANG et al., 1995.

O pensamento humano não trabalha dessa forma. Não faz sentido dizer que a pessoa número 2 é alta, e a número 3, baixa. Neste caso também temos graduação entre alto e baixo. Também não podemos considerar o número 1 baixo e o número 4 também baixo, porque o número 4 realmente não é considerado alto, mas também não baixo como o número 1.

No contexto da lógica *fuzzy*, temos duas pessoas com certo grau de pertinência aos dois conjuntos, variando entre 0 e 1, ou seja, para dizer se uma pessoa é alta ou baixa temos fatores do raciocínio humano que vão ajudar nessa decisão. Dessa forma, pode-se concluir que os conjuntos *fuzzy* que classificam os elementos de um dado universo de discurso são menos rígidos do que aqueles utilizados na lógica convencional, pois eles admitem graus parciais de pertinência (entre 0 e 1). A Figura 9 mostra uma representação do conjunto *fuzzy* de altura das pessoas em termos de função de pertinência. Observa-se que não existe o problema de *sharp boundary* em 180 cm, mas uma transação suave.

Figura 9 – Conjunto *fuzzy* de altura das pessoas.

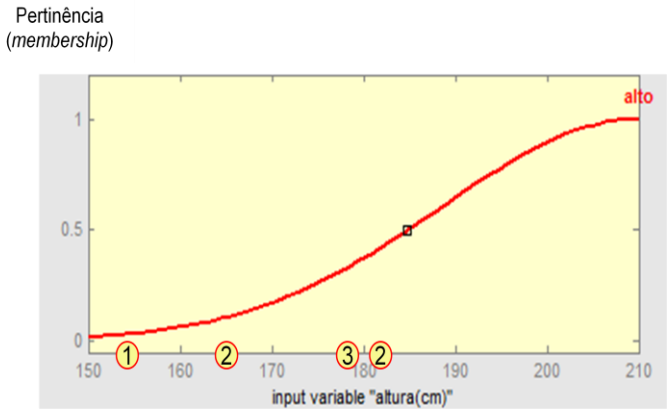

Fonte: Autor, 2014.

2.3.2 Variável linguística

Uma variável linguística é aquela cujos valores são palavras em lugar de números (TANSCHEIT, 2007). Esses nomes são geralmente relacionados a conceitos do cotidiano da linguagem humana, tais como: quente, morno, perto, muito perto e, no exemplo que está sendo abordado do conjunto de altura das pessoas,

são as palavras "baixa", "mediana" e "alta". Essas variáveis linguísticas são descritas tanto por intermédio de conjuntos *crisp* como *fuzzy,* representados por funções de pertinência. No mundo crisp, os valores de grau de pertinência podem ser 0 e 1, e no mundo *fuzzy* esses valores podem variar entre 0 e 1.

No exemplo do conjunto das alturas, a faixa de alturas (universo de discurso) que vai de 150 a 210 cm foi dividida em três classes: baixa, mediana e alta. A representação Booleana[8], referente aos conjuntos crisp, pode ser representada conforme a Figura 10 (a). A Figura 10 (b) é representação *fuzzy* do conjuntos *fuzzy*.

Figura 10 - Variáveis linguísticas dos conjuntos de altura das pessoas.

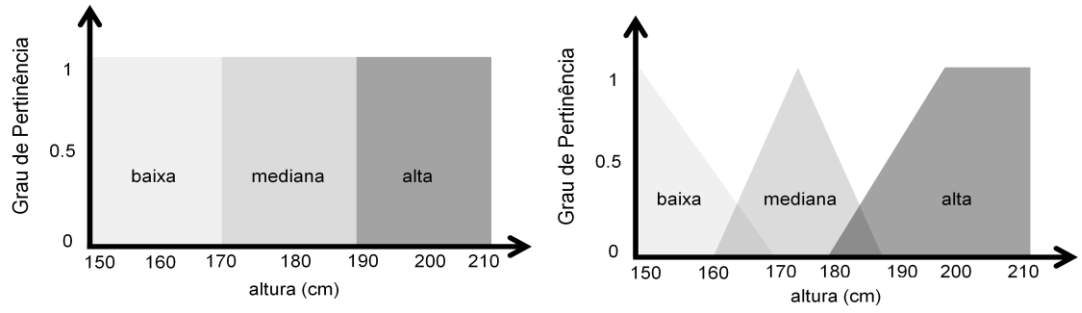

(a) (b)

Fonte: Autor, 2014. Modificado - JANG et al., 1995.

Essa representação das variáveis linguísticas é um ponto muito importante para esta dissertação, pois basicamente o trabalho se resume em fazer uma análise do modelo de particionamento de valores quantitativos, que podem ser crisp através da discretização, ou *fuzzy,* através das variáveis linguísticas, em ambos os valores quantitativos.

2.3.3 Regras *Fuzzy* SE - ENTÃO

[8] São estruturas algébricas que "captam as propriedades essenciais" dos operadores lógicos e de conjuntos, ou ainda oferece um estrutura para se lidar com "afirmações" (SCHEINERMAN, 2003),

As regras *fuzzy* são regras normais utilizadas para operar, da maneira correta, conjuntos *fuzzy*, com o objetivo de obter consequentes. Para criar tais regras é preciso de um raciocínio coerente com o que se deseja e obter. Para isso, este raciocínio pode ser dividido em duas etapas: (1) avaliar o antecedente da regra e (2) aplicar o resultado no consequente OU, SENÃO, E e uma combinação delas.

Regras *Fuzzy* SE/ENTÃO, OU, SENÃO, E e uma combinação delas são regras cujos antecedentes, consequentes ou ambos são *fuzzy* ao invés de *crisp*, e o consequente (resultado de saída) pode ser numérico ou linguístico. A interpretação mais comum e amplamente utilizada considera uma regra *fuzzy* do tipo "se *x* é A então *y* é B", como um ponto *fuzzy* A x B, e uma coleção de regras *fuzzy* "se *x* é A_i então *y* é B_i " i = 1, ..., n. (ZADEH, 1992, 1994). Nessa estrutura de regra se/então, temos que:

i) A e B são termos linguísticos de um conjunto *fuzzy* (por exemplo "alta" do exemplo anterior);

ii) x é o valor de pertinência de uma entrada ($\mu ALTA(x)$);

iii) 'x é A' é chamado de antecedente e descreve uma condição;

iv) 'y é B' é chamado de consequente e descreve uma conclusão;

Referindo-se ao exemplo da gorjeta é possível ter uma regra do tipo: **se** (*serviço* é bom) **então** (*gorjeta* é média). Onde "bom" é representado como um número entre 0 e 1, e então, o antecedente é uma interpretação que retorna um número único entre 0 e 1. Por outro lado, "média" é representado como um conjunto *fuzzy*, e então o consequente é uma atribuição que assume o conjunto *fuzzy* B inteiro para a variável de saída *y* (JANG et al, 1995).

Podemos citar outro exemplo de uma possível regra *fuzzy* de um sistema de detecção de intruso, e que poderia ocorrer neste trabalho: **se** (*service* é private) **e** (*count* é count_low) **e** (*serv_count* é serv_count_low) **então** (*atack_type* é DoS). No caso tem-se o antecedente *service* como valor qualitativo e os antecedentes *count* e *serv_count* como valores quantitativos e o consequente *atack_type* como valor qualitativo.

2.3.4 Sistema de Inferência *Fuzzy*

O Sistema de Inferência *Fuzzy* é uma estrutura computacional popular baseada nos conceitos de teoria de conjuntos *fuzzy,* regras *fuzzy* SE... ENTÃO e raciocínio *fuzzy* (JANG, 1995). Como também, através de um processo de avaliação do espaço de entrada com o objetivo de, através das regras previamente definidas e das entradas, obter resultados para uma tomada de decisão, utilizando-se de todos os elementos que foram vistos neste tópico de Sistema *Fuzzy*: conjuntos *fuzzy*, variável linguística, função de pertinência, operadores de lógica *fuzzy* e regras se/então.

Existem dois tipos de sistemas de inferência que variam conforme o tipo de saída determinado: Mamdani e Sugeno. O método de Mamdani foi um dos primeiros sistemas de controle construídos usando a teoria dos conjuntos *fuzzy*. De um modo geral, o método Sugeno pode ser utilizado para modelar qualquer sistema de inferência em que a funções de pertinência saída são lineares ou constantes.

Um Sistema de Inferência *Fuzzy* é mostrado na Figura 11, onde estão identificadas as funções de cada bloco.

Figura 11 - Sistema de Inferência *Fuzzy*

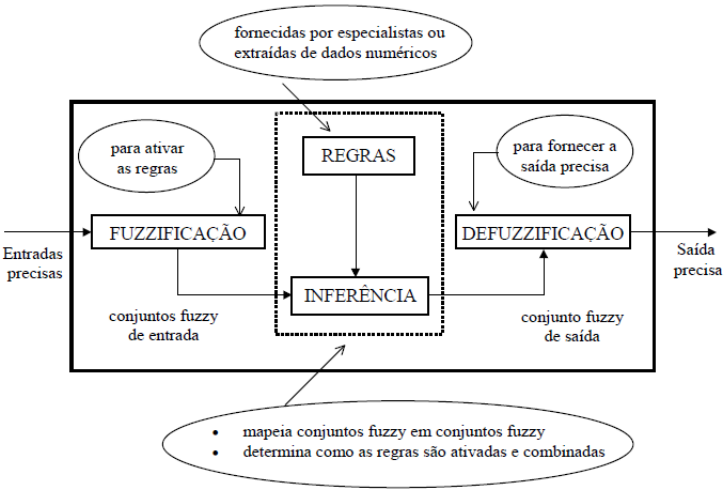

Fonte: Tanscheit (1995)

Segundo JANG et al. (1995), podemos fazer uma breve descrição dos módulos, sendo:

Fuzzificação: nessa etapa para cada entrada, através das funções de pertinência, obtém-se o grau de pertinência com que cada entrada pertence a cada conjunto *fuzzy*. Cada uma dessas entradas foi previamente definida no seu

respectivo no universo de discurso e associada a um grau de pertinência em cada conjunto *fuzzy* através do conhecimento do especialista. A entrada é um valor numérico e a saída um valor entre 0 e 1.

Inferência: uma vez que as entradas foram *fuzzyficadas*, é sabido que o grau em cada parte do antecedente foi satisfeita para cada regra. Nessa etapa ocorrem as operações com conjuntos *fuzzy* propriamente ditas. Ou seja, combinação dos *antecedentes* das regras, *implicação* e *modus ponens generalizado*[9]. Os conjuntos *fuzzy* de entrada, relativos aos antecedentes das regras, e o de saída, referente ao consequente, podem ser definidos previamente ou, alternativamente, gerados automaticamente a partir dos dados. Dois operadores são os principais na construção de funções de pertinência: E e OU. E são bons o bastante para construir sistemas bem definidos.

Regras: podem ser fornecidas por especialistas, em forma de sentenças linguísticas, e são fundamentais no desempenho de um sistema de inferência *fuzzy*. Tomando como exemplo um sistema de detecção de intruso, este só terá uma taxa de acurácia de acerto dos tipos de ataque se as regras que definem a estratégia de avaliação dos ataques forem consistentes. Extrair regras de especialistas na forma de sentenças do tipo SE/ENTÃO não é uma tarefa tão fácil, por mais conhecedores que eles sejam do problema em questão. Um método em substituição ao uso de especialistas para a definição da base de regras. Existem métodos de extração de regras de dados numéricos que são os métodos que serão abordados neste trabalho.

Desfuzzificação: para se obter um valor de saída é necessário *defuzzyficar* o conjunto *fuzzy* de saída obtido no processo de inferência. Nessa etapa é feita uma interpretação dessas informações. Existem vários métodos de defuzzificação, mas dois dos mais comuns são o *centro de gravidade* (*centroid*) e a *média dos máximos* (*mom*). Dos dois , talvez o mais popular método seja o *centro de gravidade, que retorna o centro de uma área de uma curva.* Existem ainda outros três métodos: bisector, maior dos máximos (*largest of maximum*) e o menor dos máximos (*smallest of maximum*).

---

[9] Modus ponens ou MP é uma forma de argumento válido em lógica. Ex: Se o bolo é feito com açúcar, então o bolo é doce.

2.4 Extração de Regras de Associação (Qualitativo)

O objetivo da mineração de dados é descobrir associações importantes entre os itens de tal forma que a presença de alguns itens em uma transação implicará a presença de alguns outros itens. Para atingir esse objetivo , AGRAWL et al. (1994) propôs o conhecido algoritmo Apriori, que se baseia no conceito de grandes conjuntos de itens para encontrar regras de associação entre os dados de uma transação (AGRAWL et al., 1995) (MANNILA, H., 1997) . O processo de mineração foi dividido em duas fases. Na primeira fase , durante o escaneamento das transações dos dados, os conjuntos de itens candidatos foram gerados e totalizados. Se o valor do suporte de um conjunto de itens nas transações dos dados for maior que o limite do valor mínimo de suporte previamente definido, um conjunto de itens será considerado um conjunto de itens grande (*large itemsets*).

Grandes conjuntos de itens com um único item cada são então combinados para formar conjuntos de itens candidatos que contenham dois itens. Esse processo será repetido até que todos os grandes conjuntos de itens tenham sido encontrados. Na segunda fase , as regras de associação foram induzidas a partir de grandes conjuntos de itens encontrados na primeira fase.

O método de extração de regras de associação, conhecido como *market basket analysis*, se baseia em descobrir regras de associações entre atributos de valores qualitativos.

Para ilustrar melhor as regras de associação, consideremos outro exemplo de uma base de dados, representado pela Figura 12, adaptado de CHEN et al. (1996) e de AGRAWAL e SRIKANT (1994), que é o banco de dados de transações efetuadas pelos clientes de um supermercado. A cada compra de um cliente, são registrados nesse banco de dados todos os itens (produtos) comprados naquele momento. Se este mesmo cliente ao final da compra, isto é, após o pagamento na caixa registradora, retornar ao supermercado e efetuar uma nova compra, com um ou mais produtos, é considerado uma nova transação.

Podemos então dizer que a Tabela 1 representa as transações ocorridas na Figura 12. No exemplo em questão, consideramos $I = \{i_1 , i_2 \ldots , i_n \}$ o conjunto de todos os itens da cesta de compras (pão, açúcar, leite, papel e manteiga), e $T = \{t_1 , t_2 , \ldots , t_n\}$ o conjunto de todas as transações (100, 200, 300 e 400).

Figura 12 – Transações de compra no supermercado.

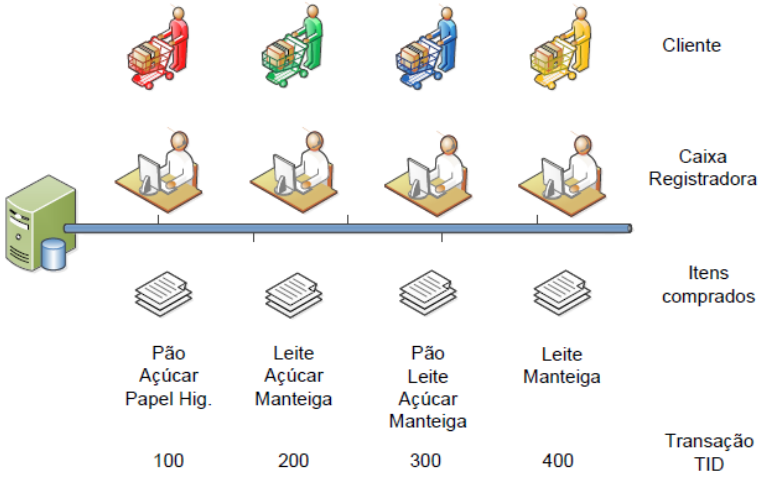

Fonte: O autor, 2013. Modificado - CHEN et al., (1996).

Cada transação t_n é um *itemset* que contêm *k-itemset,* onde *k* é o número de itens da transação. A transação TID=100 é um *itemset* com 3-*itemset.*

Tabela 1 – Transações de compras armazenadas no banco de dados.

TID	ITENS	ITEMSET
100	Pão, Açúcar e Papel	3-*itemset*
200	Leite, Açúcar e Manteiga	3-*itemset*
300	Pão, Leite, Açúcar e Manteiga	4-*itemset*
400	Leite e Manteiga	2-*itemsets*

Ainda no exemplo da Figura 12, podemos dizer que com relação aos itens leite, açúcar, papel e manteiga, temos as seguintes possíveis associações de regras e respectivas medidas de *suporte* e *confiança* apresentadas na Tabela 2.

Tabela 2 – Associações de regras x suporte e confiança.

(se) antecedente (então) consequente			Suporte (%)	Confiança (%)
leite (3)	=>	manteiga (3)	75	100
leite (3)	=>	açúcar (2)	75	66,67
leite e açúcar (2)	=>	manteiga (2)	50	100
pão e leite (1)	=>	papel (0)	25	0
papel (1)	=>	pão (1)	25	100

Nesse caso cabe uma questão: Será que o fato de uma possível regra de associação ter um grau de confiança alto é suficiente para a considerarmos uma regra forte? No exemplo anterior (Tabela 2), os itens pão e papel aparecem juntos somente na primeira transação (TID 100), ou seja, poucos consumidores compram estes dois itens juntos. Entretanto, apenas pelo fato de que em 100% das transações em que o papel aparece, o item pão também aparece, temos que o grau de confiança da regra {papel} > {pão} é de 100%. Nesse caso não podemos afirmar que pelo fato do grau de confiança ser alto a regra seja boa, pois esta confiança diz respeito somente a uma única transação suportada {pão, açúcar, papel}.

Nesse sentido, as regras são consideradas fortes quando possuem os valores de suporte e confiança acima dos valores mínimos previamente definidos, e este critério vai depender do tipo de aplicação. Por exemplo, um analista de *marketing* interessado em encontrar qual supermercado compra juntos determinados itens, pode definir um nível mínimo de suporte e confiança como sendo 20% e 70% respectivamente. Por outro lado, um analista de segurança de TI teria necessidade de reduzir o nível de suporte mínimo para 1% ou menos, desde que considere interessante diminuir o número de transações fraudulentas (LAROSE, 2005).

O grande problema que os algoritmos enfrentam ao extrair essas associações de regras é quanto à dimensionalidade. O número de possíveis associações aumenta exponencialmente com o número do aumento de atributos na ordem de $k \times 2^{k-1}$ possíveis regras de associação. No exemplo anterior temos 4 itens, então seguindo essa relação teremos 32 possíveis associações de regras. Suponha-se que agora uma loja de conveniência tenha 100 diferentes itens: um consumidor pode comprar ou não qualquer combinação desses 100 itens. Então, um total de $100 \times 2^{99} \approx 6.4 \times 10^{31}$ possíveis associações de regras aguardam para serem varridas pelo algoritmo.

Para contornar esse problema, a maioria dos algoritmos possui uma estratégia em comum, que é separar o problema de gerar regras de associação em duas subtarefas principais (TAN et al., 2006), a geração de itemsets frequentes e a geração das regras de associação propriamente dita.

Geração de *itemsets* frequentes: fazer uma busca no conjunto de dados e selecionar todos os *itemsets* que satisfaçam o limiar do valor mínimo de suporte (*minsup*);

Geração de Regras de associação: extrair todas as regras com confiança superior a *minconf* a partir dos *itemsets* frequentes encontrados na etapa anterior.

Nesse sentido, o algoritmo denominado Apriori foi um dos primeiros algoritmos que utilizaram a técnica de geração de itemset frequentes e posterior geração de regras de associação, e será base do desenvolvimento dessa dissertação.

2.4.1 O Algoritmo APRIORI

Quando se trata do assunto de extração de regras de associação em mineração de dados, o algoritmo Apriori é um dos mais conhecidos e considerado um clássico. Concebido pela equipe de pesquisa do Projeto QUEST da IBM, que originou o software *Intelligent Miner* (AGRAWAL, 1994) e (SRIKANT, 1994), trata-se de um algoritmo que resolve o problema de mineração de *itemsets* frequentes.

Dado um banco de dados com conjunto de transações D e um nível mínimo de suporte β, o algoritmo encontra todos os *itemsets* frequentes com relação a D e β. De posse de todos os *itemsets* frequentes com relação a D e β, para obter-se as regras de associação interessantes, basta considerar, para cada *itemset* frequente *L*, todas as regras candidatas $A \rightarrow (L - A)$, onde $A \subset L$, e testar para cada uma destas regras candidatas se o seu grau de confiança atende o nível mínimo de confiança α.

A estratégia do algoritmo Apriori é basicamente realizada em duas etapas, sendo elas: i) geração de itens frequentes e ii) geração de regras. A primeira etapa de geração de itens frequentes é realizada em duas outras subetapas, sendo elas: i) *a geração e poda de conjuntos de itens frequentes* e ii) o *cálculo de suporte dos candidatos*.

O diferencial deste algoritmo está na criação dos *itemsets* candidatos, usando a propriedade *anti-monotonicity,* que garante que, se um conjunto de itens não for frequente, então os seus superconjuntos também não o serão. Assim, o algoritmo aumenta seu desempenho, já que não perde tempo varrendo e analisando esses superconjuntos. Essa otimização é possível de ocorrer porque a busca em largura

garante que os valores dos suportes de todos os subconjuntos de um *itemset* candidato são previamente conhecidos.

PITONI (2002) apresenta, de forma simplificada, o fluxograma do processo descrito anteriormente (Figura 13).

Figura 13 - Fluxograma do algoritmo Apriori.

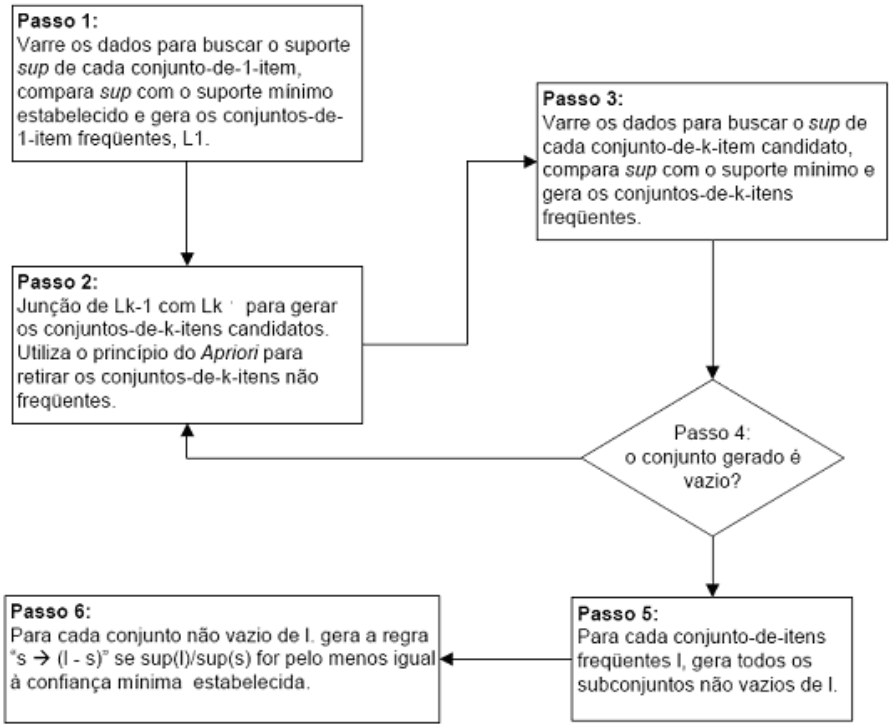

Fonte: PITONI,2002.

2.4.1.1 Geração e poda de candidatos e cálculo do suporte

A Figura 14 mostra o pseudocódigo principal do Algoritmo Apriori. O primeiro passo consiste numa varredura na base de dados para cada conjunto de *itemsets* candidatos de tamanho k e que posteriormente, para cada próximo passo k, ocorrem as seguintes operações:

i) os conjuntos de itens candidatos de tamanho K são gerados, tendo como base o conjunto de itens frequentes encontrados anteriormente (passo anterior k - 1) através da função *apriori-gen*;

ii) o suporte de cada candidato “c” é calculado através de uma contagem “c.count+”;

iii) o algoritmo prossegue iterativamente até que o conjunto dos itens frequentes L_k (que atingirem o suporte mínimo determinado) é gerado, e cuja união constitui a “saída” do algoritmo.

Figura 14 - Pseudocódigo principal do algoritmo Apriori.

```
1.  Entrada: Uma base de dados D e o valor de suporte mínimo min_sup.
2.  Saída: O conjunto L com todos os itemsets frequentes.
3.  Função apriori-main(D, min_sup)
4.  L1 = {conjunto dos itemsets frequentes de tamanho 1 contidos em D};
5.  para (k = 2; Lk−1 ≠ ∅; k++)
6.      Ck = apriori-gen(Lk−1);
7.      para todas transações t ∈ D fazer
8.          Ct = subset(Ck, t);
9.          para todos candidatos c ∈ Ct fazer
10.             c.count++;
11.         fim para
12.     fim para
```

Fonte: MARIANO, 2011.

Observa-se que o algoritmo faz uso de duas funções, *apriori-gen* e *subset*, onde cada uma realiza uma operação específica (MARIANO, 2011).

- A função *apriori-gen* (linha 6), recebe como argumento o conjunto L_{k-1} (composto por todos os *(k-1)-itemsets* frequentes) e retorna o conjunto C_k (composto por todos *k-itemsets* candidatos). A tarefa realizada por essa função é dividida em dois passos: *join* (junção) e *prune* (ajuste). No passo *join* são geradas as combinações através da junção de L_{k-1} com L_{k-1} . Já no passo *prune* são eliminados os *itemsets* candidatos que possuem algum subconjunto não frequente. Em resumo, é feito um ajuste através do qual são removidos todos os *k-itemsets* $c \in C_k$ se existe um *(k-1)-itemset s*, em que $s \subset$ c e s $\notin L_{k-1.}$ Esses dois passos podem ser visualizados na Figura 15.
- A função subset (linha 8 da Figura 14) recebe como argumento o conjunto C_k com os itemsets já podados e uma transação *t* da base de dados, e retorna o conjunto C_t composto pelos *itemsets* presentes em *t*. Essa função utiliza a *hash-tree* para encontrar os *itemsets* de C_k em uma

transação *t*. Com isso, o suporte de cada *itemset c* em C_k é determinado no propósito de eliminar os *itemsets* que não são frequentes na base de dados de entrada.

Figura 15 - Pseudocódigo da função *apriori-gen* do algoritmo Apriori.

```
1.  Função apriori-gen(L_k)
//  Passo 1 (join)
2.  para cada itemset l_1 ∈ L_{k-1} fazer
3.      para cada itemset l_2 ∈ L_{k-1} fazer
4.          se (l_1[1] = l_2[1] ∧ l_1[2] = l_2[2] ∧ ... ∧ l_1[k-1] < l_2[k-1]) então
5.              c = l_1[1] . l_1[2] ... l_1[k-2] . l_1[k-1] . l_2[k-1];
6.              adicione c em C_k;
7.          fim se
8.      fim para
9.  fim para
//  Passo 2 (prune)
10. para todos candidatos c ∈ C_k fazer
11.     para todos (k-1)-subsets s ⊂ c fazer
12.         se (s ∉ L_{k-1}) então
13.             delete c de C_k;
14.         fim se
15.     fim para
16. fim para
17. retorne C_k;
```

Fonte: MARIANO, 2011.

O algoritmo Apriori, bem como outros algoritmos, na fase de *prune* (passo 2) exploram uma propriedade que otimiza seu desempenho na busca de conjuntos de itens frequentes. É conhecida como "*downward closure property*" de suporte (AGRAWAL, 1993 e TAN, 2005) ou como "*anti-monotonicity*" (PEI, HAN e LAKSHMANAN, 2001). Essa propriedade diz que se um conjunto de itens é frequente, então todos os seus subconjuntos também devem ser frequentes, além de utilizar recursos da memória principal e estrutura *hash*. Isso significa que se *X* está contido em *Y* e *X* não é frequente, logo Y também não é frequente. E implica uma diminuição do tempo de execução, pois se X não é frequente, então não será necessário calcular o suporte de Y, e o algoritmo não precisará ler novamente todo o bando de dados. Para ilustrar a ideia por trás dessa propriedade, considere a rede de *itemset* da Figura 16, que mostra uma rede de conjuntos de itens possíveis de combinação a partir da lista de itens {a, b, c, d, e}.

Suponha que {c, d, e} é um *itemset* frequente. Obviamente qualquer transação que contém {c,d,e} precisa também conter seus subsets, {c,d}, {c,e}, {d,e}, {c}, {d} e {e}. Como resultado, se {c,d,e} é frequente, então todos subsets de {c,d,e} (sombreados na figura) devem também ser frequentes (Figura 17).

Figura 16 – Rede de conjunto de itens.

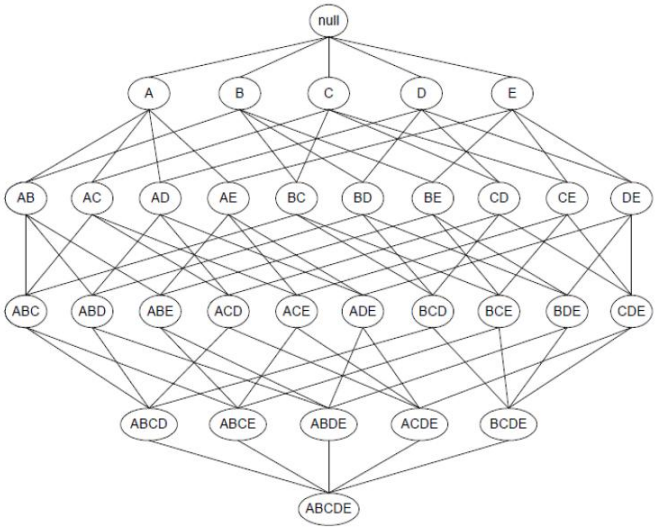

Figura 17 – Princípio Apriori aplicado na rede de itemsets

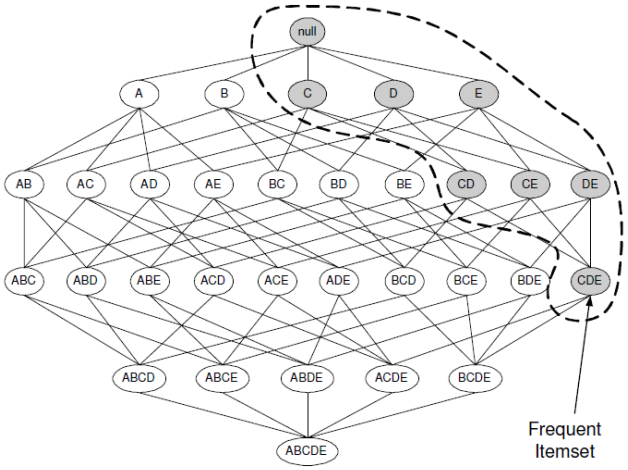

2.4.1.2 Geração de regras de associação

Após gerar o conjunto *L* contendo todos os *itemsets* frequentes, é possível iniciar a fase de extração de regras de associação através do uso da função *ap-*

genrules (Figura 18). Nessa fase o conjunto *L* é recebido como argumento juntamente com o valor *min_conf* (valor de confiança mínima definida para as regras). A partir de cada *itemset* presente em *L*, são extraídos todos os subconjuntos de itens possíveis, onde em cada subconjunto se calcula a confiança da regra a ser gerada, definida por: *confiança = suporte(X)/suporte(Y),* com *X = {k-itemset | k-itemset* $\in$ *L}* e *Y = {1 ≤ i < k | i-itemset* $\subset$ *k-itemset}.* Caso o valor da confiança satisfaça o valor mínimo definido previamente, a regra poderá ser extraída. Sendo assim, todas as possíveis associações de regras são geradas a partir do conjunto de *itemsets* frequentes, e exibidas ao final da execução do algoritmo (MARIANO, 2011).

Figura 18 - Pseudocódigo da função *genrules* do algoritmo Apriori.

```
1.  Entrada: Um conjunto de itemsets L e a confiança mínima da regra min_conf.
2.  Saída: O conjunto de regras R.
3.  Função ap-genrules(L, min_conf)
4.  para todos k-itemsets ∈ L fazer
5.      para (i = k-1; i ≥ 1; i--)
6.          para todos i-itemsets ⊂ k-itemset fazer
7.              conf = suporte(k-itemset) / suporte(i-itemset);
8.              se (conf ≥ min_conf) então
9.                  adicione i-itemset → (k-itemset − i-itemset) em R;
10.             fim se
11.         fim para
12.     fim para
13. fim para
14. retorne R;
```

Fonte: MARIANO, 2011.

2.4.2 Exemplo de aplicação - Qualitativo / Booleanos

De maneira a exemplificar o funcionamento do Algoritmo Apriori, será utilizado a mesma base de dados da Figura 12. A base de dados D é formada por cinco atributos {pão, leite, açúcar, papel, manteiga} e quatro transações (TID) (Tabela 3), tendo como medida de suporte mínimo 50%.

Para ilustrar o problema, na Tabela 4 são exibidas as ocorrências e o suporte de cada atributo, mas essa fase inicial de ordenamento o *Conjunto de Itens* e de

contagem de cada item e sua respectiva incidência dentro da base é feita pelo algoritmo gerando C_1.

Tabela 3 – Base de dados D e respectivos *itemsets.*

TID	PÃO	LEITE	AÇÚCAR	PAPEL	MANTEIGA
100	SIM	não	SIM	SIM	não
200	não	SIM	SIM	não	SIM
300	SIM	SIM	SIM	não	SIM
400	não	SIM	não	não	SIM

Tabela 4 – Ocorrência e suporte dos atributos.

	PÃO	LEITE	AÇÚCAR	PAPEL	MANTEIGA
Ocorrências	2	3	3	1	3
Suporte	50%	75%	75%	25%	75%

Todas as fases subsequentes descritas a seguir estão representadas na Figura 19. O próximo passo é efetuar a “poda” do item que não obtiver uma frequência na base de dados. Para o exemplo estará sendo considerado como medida de suporte mínimo o valor de 50% (frequência 2). Nesse caso, o item que sofrerá a “poda” é o {papel}, pois contém apenas uma incidência na base, gerando então o conjunto de itens L_1. Em seguida, o algoritmo efetua mais uma verificação das incidências de itens compostos e os ordena, gerando assim C_2. Mais uma vez o algoritmo efetua a análise da base D e novamente exclui os itens que não possuírem frequência mínima na base, que nesse caso são os itens {pão, leite} e {pão, manteiga}, gerando o L_2. Em seguida, é feita nova checagem das incidências para gerar um novo conjunto de itens C_3 que neste caso gerou {leite, açúcar, manteiga}. O algoritmo retorna as análises da base D para gerar o L_3 e finaliza o processo, pois não existe mais conjunto a ser gerado além do conjunto de itens L_3.

Figura 19 - Exemplo de aplicação do Algoritmo Apriori.

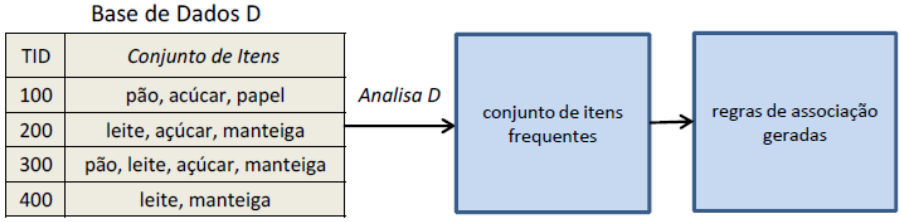

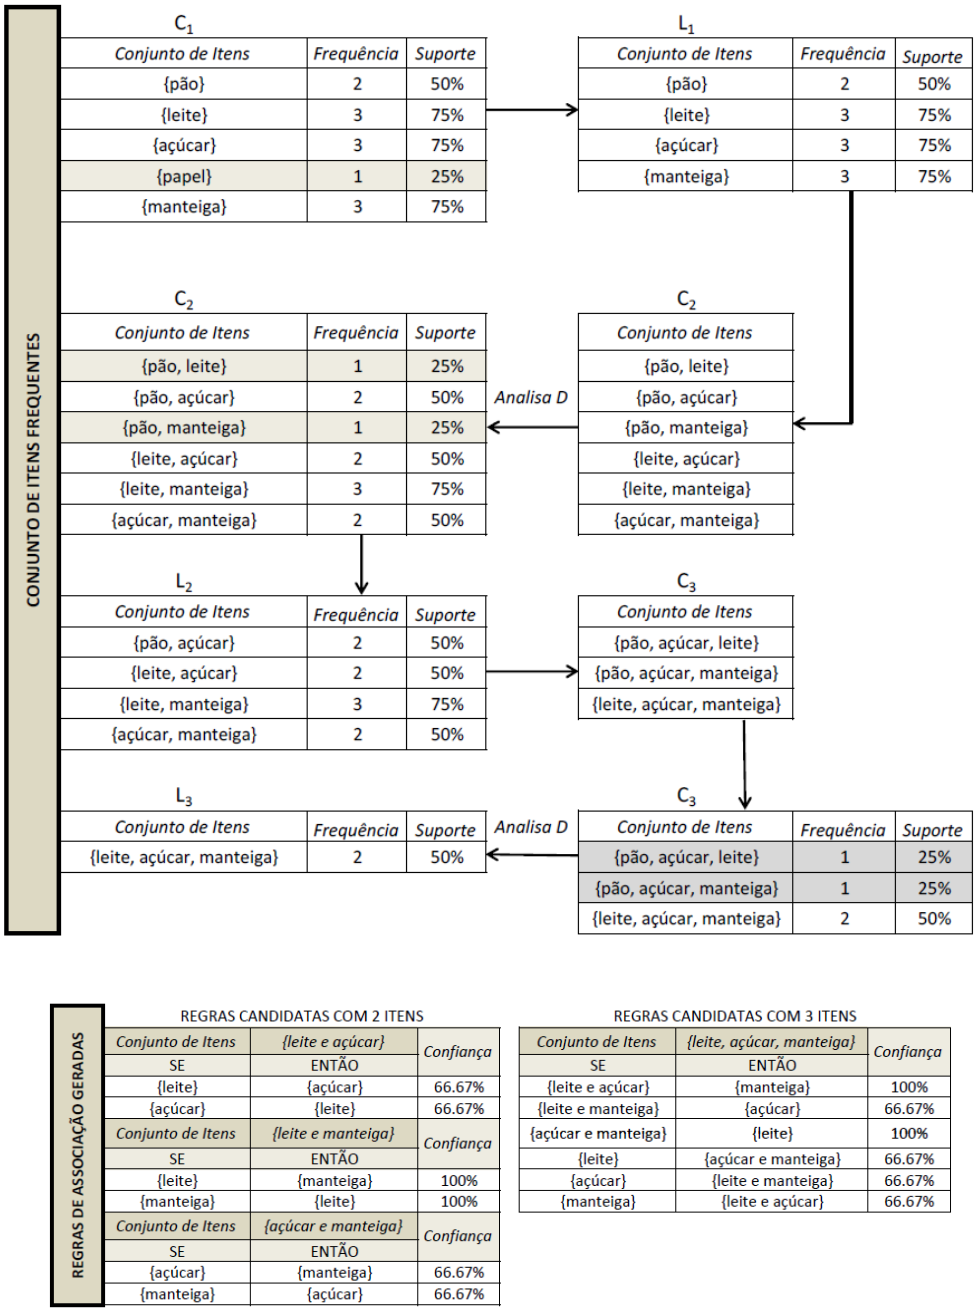

Fonte: Autor, 2014.

2.5 Extração de Regras de Associação (Quantitativo - *CRIPS)*

Conforme visto na seção anterior, em AGRAWAL et al. (1994), foi proposto método para extração de regras de associação de valores binários. Entretanto, atributos podem ser quantitativos ou qualitativos. Atributos booleanos podem ser

considerados um caso especial de atributos qualitativos. Como não é possível aplicar diretamente algoritmos binários, é preciso transformar o problema de atributos quantitativos em binários.

AGRAWAL et al. (1996) propôs um método para extração de regras de associação, mas dessa vez para atributos com valores quantitativos. Seu método propõe primeiro determinar o número de partições para cada atributo quantitativo, para então serem mapeados todos os valores possíveis de cada atributo em um conjunto de inteiros consecutivos (discretizar). Em seguida são encontrados os *itemsets* frequentes, cujo valor de suporte seja maior que o valor mínimo de suporte previamente definido pelo usuário. Esses *itemset* frequentes são então processados para gerar as regras de associação.

2.5.1 Mapeando atributos quantitativos em Booleanos

Um conjunto de transações é formado por linhas (instâncias) e colunas (atributos), onde para cada atributo tem-se um item e um valor correspondente para cada instância. O valor de um atributo para um dado registro é "1" se o item correspondente ao atributo é presente na transação correspondente ao registro, e "0", se não. Atributos podem ser quantitativos (idade, salário) ou qualitativos (cor, marca de carro). Atributos booleanos pode ser considerados como um caso especial de atributo qualitativo.

Se o domínio de valores quantitativos é grande, primeiro será feita uma partição dos valores em intervalos, para então se mapear cada par (atributo,intervalo) em atributo booleano. Uma vez mapeados todos os atributos, é possível usar qualquer algoritmo aplicado para extração de regras de associação *fuzzy*, como por exemplo o algoritmo Apriori (AGRAWAL et al.,1994).

2.5.2 Exemplo de aplicação - Quantitativo / Booleano

Considerando a tabela "Pessoa" da Figura 20 (a), notam-se dois atributos quantitativos, *Idade* e *NumCars.* O atributo Idade é particionado em dois intervalos, e o atributo qualitativo, *Casado*, tem dois atributos booleanos "Casado: sim" e "Casado: não". Como o número de valores para *NumCars* é pequeno, NumCars não é particionado em intervalos; cada valor é mapeado para um campo booleano (Figura 20 (b)). Assumindo um valor mínimo de suporte de 40% e de confiança mínima de 50%, a Figura 20 (c) mostra algumas regras (AGRAWAL et al., 1996).

Figura 20 – Exemplo de extração de regra quantitativa - *Crisp*.

Pessoas

ID	Idade	Casado	NumCars
100	23	não	1
200	25	sim	1
300	29	não	0
400	34	sim	2
500	38	sim	2

(a)

Mapeando para Regras de Associação Booleana

ID	Idade {20..29}	Idade {30..39}	Casado (sim)	Casado (não)	NumCars {0}	NumCars {1}	NumCars {2}
100	1	0	0	1	0	1	0
200	1	0	1	0	0	1	0
300	1	0	0	1	1	0	0
400	0	1	1	0	0	0	1
500	0	1	1	0	0	0	1

(b)

Amostra: Regras

Regra	Suporte	Confiança
{idade: 30..39} e {casado: sim} □{NumCars: 2}	40%	100%
{idade: 20..29} □{NumCars: 1}	60%	66.6%

(c)

2.5.3 Classificação associativa - Algoritmo CBA

O algoritmo aplicado para classificação das regras de associação foi o classificador JCBA (implementação JAVA do algoritmo CBA), que trabalha com regras de associação de classe.

Extração de regras de classificação destina-se a descobrir um conjunto pequeno de regras que vai formar um classificador preciso. Enquanto em regras de associação a classe (target) pode ou não estar presente, o que é o caso do conjunto de dados utilizado neste trabalho em que a classe é o tipo de ataque: para regras de classificação existe um e somente um predeterminado atributo classe.

A proposta do algoritmo introduzida por LIU et al. (1998), chamada de algoritmo CBA (*Classification Based on Association*), é integrar essas duas técnicas de extração (associação e classificação). A sua construção é dividida em duas etapas. A primeira é feita com a extração de um subconjunto especial de regras de associação, cujo lado direito da regra (consequente) é restrito à classificação do atributo classe. Este subconjunto de regras é chamado de *class association rules* (CARs), que é uma adaptação do algoritmo de extração de regras de associação introduzido por AGRAWAL e SRIKANT (1994); e a segunda é construir um classificador baseando-se nas regras CARs geradas.

Para construir o melhor classificador de todo o conjunto de regras geradas, o algoritmo envolve a avaliação de todos os possíveis subconjuntos de regras. Aplicado no conjunto de dados treinamento, é selecionado o subconjunto de regras que possui a sequência de regras que vai fornecer o menor número de erros durante a classificação. Seja *R* um conjunto de regras geradas (CARs), e *D* o conjunto treinamento: o algoritmo vai aplicar filtros para eliminar as regras de *R* que geram mais erros (p.ex: regras conflitantes), selecionando, assim, um conjunto de regras de alta confiança em *R* que satisfaça *D* para criar um classificador.

2.6 Extração de Regras de Associação (Quantitativo - *FUZZY)*

Conforme visto na seção anterior, em AGRAWAL et al. (1996), foi proposta extração de regras de associação de atributos com valores quantitativos. Esse algoritmo encontrava as regras de associação particionando os domínios dos atributos e combinando partições adjacentes (discretização), então transformando os atributos em binários. Embora esse método possa resolver o problema ocasionado por domínio infinito, causa o problema de *sharp boundary*. Ou seja, ele subvaloriza ou supervaloriza os elementos próximos aos limites das partições. Entretanto, com a introdução da Teoria *Fuzzy* proposta por ZADEH (1965), foi possível resolver o problema de *sharp boundary*, e vem sendo amplamente utilizada nos domínios de extração de regras de associação.

Em KUOK et al. (1998), foi introduzido o algoritmo para extração de regras de associação de atributos quantitativos, utilizando-se a teoria dos conjuntos Fuzzy.

Nomeada como *Fuzzy Apriori*, a proposta de extração de regras de associação de atributos com valores quantitativos se divide em duas etapas, sendo: i) transformar os valores dos atributos quantitativos em termos linguísticos com sua respectiva variável linguística e função de pertinência associada (partições *fuzzy*), e em seguida fazer seleção de um único termo linguístico que possui a máxima cardinalidade escalar[10], mantendo assim o número de regiões fuzzy igual ao número original de atributos; ii) encontrar os *item sets* frequentes *a* partir de um valor de suporte mínimo e, através de um valor mínimo de confiança, extrair as regras de associação. Pode-se dizer então que, dado um conjunto de dados $\mathrm{D} = \{\mathrm{t}_1, \mathrm{t}_2, \ldots . \mathrm{t}_\mathrm{n}\}$ com atributos I e conjuntos fuzzy associados com atributos em I, se deseje encontrar relações de interesse potencialmente úteis. A expressão para uma regra de associação fuzzy é dada por:

$$\text{If } \mathrm{X} = \{\mathrm{x}_1, \mathrm{x}_2, \ldots . \mathrm{x}_\mathrm{i}\} \text{ é } \mathrm{A} = \{\mathrm{f}_1, \mathrm{f}_2, \ldots . \mathrm{f}_i\} \text{ então } \mathrm{Y} = \{\mathrm{y}_1, \mathrm{y}_2, \ldots . \mathrm{y}_j\} \text{ é } \mathrm{B} = \{\mathrm{g}_1, \mathrm{g}_2, \ldots . \mathrm{g}_\mathrm{j}\} \quad (5)$$

onde

[10] Dado um conjunto fuzzy Ã, definido em X, é o somatório dos graus de pertinência de todos os elementos de X em Ã.

$$f_i \in \{\text{conjuntos fuzzy relacionados ao atributo } x_i\}$$
$$g_j \in \{\text{conjuntos fuzzy relacionados ao atributo } y_j\}$$

e *X, Y* são itemsets. *X* e *Y* são subconjuntos de *I* e eles são desassociados, o que significa que não compartilham os mesmos atributos. *A* e *B* contêm conjuntos associados com atributos correspondentes em X e Y. Como na associação binária, "*X é A*" é chamado de antecedente da regra, enquanto que "*Y é B*" é chamado de consequente da regra. Se a regra é interessante, deve ter valor de suporte suficiente e valor alto de confiança.

2.6.1 Algoritmo *Fuzzy* Apriori

Estudos têm desenvolvido algoritmos para extrair regras de associação fuzzy introduzidos por KUOK et al. (1998). Conforme visto na seção anterior, a extração de regras de associação de atributos com valores quantitativos se divide em duas etapas, sendo: i) no primeiro passo, *fuzzy* frequente 1 - conjuntos de itens L1 são gerados através do escaneamento da base de dados. Juntando-se L1 a ele mesmo, é possível formar novos candidatos de conjuntos de itens fuzzy C_2. De acordo com o princípio Apriori, C_2 é reduzido para formar L_2, consequentemente gerando L_3, ..., L_k. O algoritmo para extrair regras de associação fuzzy a partir de conjunto de itens fuzzy é similar à extração de regras de associação Booleana. A Figura 21 mostra o fluxo básico do algoritmo clássico Fuzzy Apriori.

Figura 21 – Fluxograma Algoritmo Fuzzy Apriori Clássico

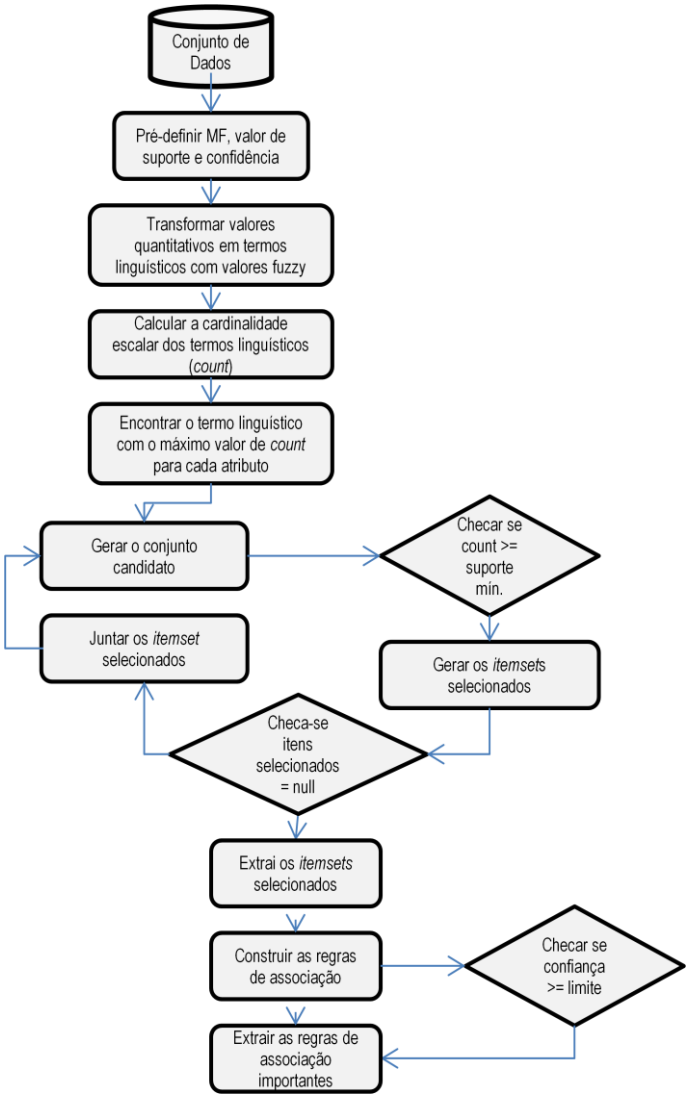

Fonte: HONG et al., 2001.

O algoritmo *fuzzy apriori* utilizado nos experimentos (*FuzzyApriori-A*) foi introduzido por HONG et al. (2001). O autor baseou-se numa pequena variação do *fuzzy apriori* clássico. Segundo sua proposta, todos os termos linguístico são usados, mas com a condição de que termos linguísticos pertencentes ao mesmo atributo não podem pertencer ao mesmo conjunto de itens. A diferença entre eles é observada na área mais escura da Figura 22.

Figura 22 – Fluxograma Algoritmo Fuzzy Apriori-A.

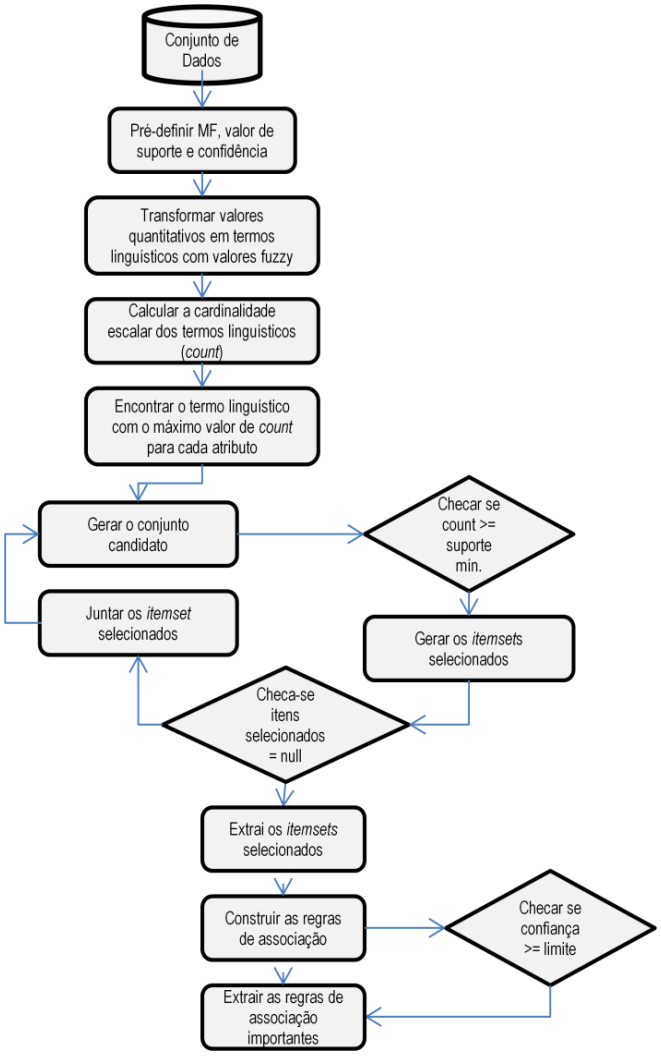

Fonte: HONG et al., 2001.

2.6.2 Exemplo de aplicação - Quantitativo / *Fuzzy*

Nesta sessão será apresentado um exemplo clássico para ilustrar a aplicação do algoritmo *Fuzzy* Apriori, onde será utilizado um conjunto de dados com atributos de valores quantitativos. O exemplo, segundo HONG et. al. (2004), aplica o algoritmo Fuzzy Apriori proposto por KUOK et al. (1998), com o objetivo de reduzir o tempo computacional. O algoritmo é aplicado para extrair regras de associação para uma grade de cursos de acordo com dados históricos relativos às notas dos estudantes nos cursos. O conjunto de dados inclui 10 instâncias, como se mostra na Tabela 5.

Tabela 5 – Exemplo do conjunto de dados.

Caso #	ST	DB	OOP	DS	MIS
1	86.0	77.0	86.0	71.0	68.0
2	61.0	79.0	89.0	77.0	80.0
3	84.0	89.0	86.0	79.0	89.0
4	73.0	86.0	79.0	84.0	62.0
5	70.0	89.0	87.0	72.0	79.0
6	65.0	77.0	86.0	61.0	87.0
7	67.0	87.0	75.0	71.0	80.0
8	86.0	63.0	64.0	84.0	86.0
9	75.0	65.0	79.0	87.0	88.0
10	79.0	63.0	63.0	85.0	89.0

Cada caso consiste de cinco notas: Estatística (ST), Banco de Dados (DB), Programação orientada a objeto (OOP), Estrutura de Dados (DS), e Sistema de Gerenciamento de Informação (MIS). As funções de pertinência triangular são usadas para representar o conjunto *fuzzy* para as notas dos cursos (Figura 23).

Figura 23 – Função de pertinência usada no exemplo.

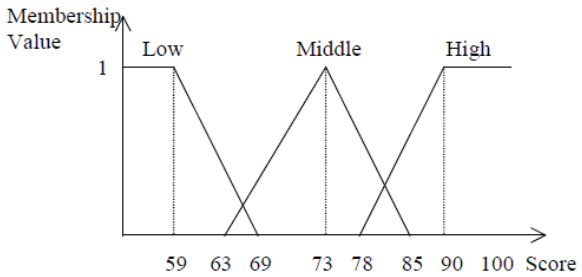

Fonte: HONG, et. al., 2004.

A partir da Tabela 5, cada atributo tem 3 regiões *fuzzy*: *Low, Middle e High*. Então, os 3 valores de pertinência *fuzzy* são atribuídos para cada nota dos cursos, de acordo com a função de pertinência predefinida. Para as transações de dados da Tabela 5, a proposta do algoritmo para extração de regras de associação segue os passos abaixo.

Passo 1: Transformar os valores quantitativos de cada transação em *fuzzy set* (Tabela 6). O valor que está em negrito é o valor (diferente de zero) que está na região da partição *fuzzy* que possui a cardinalidade escalar de maior valor, e que será visto no Passo x.

Tabela 6 – Conjuntos *fuzzy* transformados a partir da Tabela 5.

Case	ST			DB			OOP			DS			MIS		
	Low	Middle	High	Low	Middle	High	Low	Middle	High	Low	Middle	High	Low	Middle	High
1	0.0	0.0	0.7	0.0	0.7	0.0	0.0	0.0	**0.7**	0.0	**0.8**	0.0	0.1	0.5	0.0
2	0.8	0.0	0.0	0.0	0.5	**0.1**	0.0	0.0	**0.9**	0.0	**0.7**	0.0	0.0	0.4	**0.2**
3	0.0	**0.1**	0.5	0.0	0.0	**0.9**	0.0	0.0	**0.7**	0.0	**0.5**	0.1	0.0	0.0	**0.9**
4	0.0	**1.0**	0.0	0.0	0.0	**0.7**	0.0	0.5	**0.1**	0.0	**0.1**	0.5	0.7	0.0	0.0
5	0.0	**0.7**	0.0	0.0	0.0	**0.9**	0.0	0.0	**0.8**	0.0	**0.9**	0.0	0.0	0.5	**0.1**
6	0.4	**0.2**	0.0	0.0	0.7	0.0	0.0	0.0	**0.7**	0.8	0.0	0.0	0.0	0.0	**0.8**
7	0.2	**0.4**	0.0	0.0	0.0	**0.8**	0.0	0.8	0.0	0.0	**0.8**	0.0	0.0	0.4	**0.2**
8	0.0	0.0	0.7	0.6	0.0	0.0	0.5	0.1	0.0	0.0	**0.1**	0.5	0.0	0.0	**0.7**
9	0.0	**0.8**	0.0	0.4	0.2	0.0	0.0	0.5	**0.1**	0.0	0.0	0.8	0.0	0.0	**0.8**
10	0.0	**0.5**	0.1	0.6	0.0	0.0	0.6	0.0	0.0	0.0	0.0	0.6	0.0	0.0	**0.9**
Count	1.4	3.7	2.0	1.6	2.1	3.4	1.1	1.9	4.0	0.8	3.9	2.5	0.8	1.8	4.6

Passo 2: Construir um conjunto de dados temporário, incluindo todos os pares de cada dado (Tabela 7).

Tabela 7 – Conjuntos temporários C1.

Case	**Conjunto de *Itemsets***
1	{(ST_Hight,0.7) , (DB_Middle,0.7) , (OOP_High,0.7) , (DS_Middle,0.8) , (MIS_Low,0.1) , (MIS_Middle,0.5)}
2	{(ST_Low,0.8) , (DB_Middle,0.5) , (DB_High,0.1) , (OOP_High,0.9) , (DS_Middle,0.7) , (MIS_Middle,0.4) , (MIS_High,0.2)}
3	{(ST_Middle,0.1) , (ST_High,0.5) , (DB_High,0.9) , (OOP_High,0.7) , (DS_Middle,0.5) , (DS_High,0.1) , (MIS_High,0.9)}
4	{(ST_Middle,1.0) , (DB_High,0.7) , (OOP_Middle,0.5) , (OOP_High,0.1) , (DS_Middle,0.1) , (DS_High,0.5) , (MIS_Low,0.7)}
5	{(ST_Middle,0.7) , (DB_High,0.9) , (OOP_High,0.8) , (DS_Middle,0.9) , (MIS_Middle,0.5) , (MIS_High,0.1)}
6	{(ST_Low,0.4) , (ST_Middle,0.2) , (DB_Middle,0.7) , (OOP_High,0.7) , (DS_Low,0.8) , (MIS_High,0.8)}
7	{(ST_Low,0.2) , (ST_Middle,0.4) , (DB_High,0.8) , (OOP_Middle,0.8) , (DS_Middle,0.8) , (MIS_Middle,0.4) , (MIS_High,0.2)}
8	{(ST_Hight,0.7) , (DB_Low,0.6) , (OOP_Low,0.5) , (OOP_Middle,0.1) , (DS_Middle,0.1) , (DS_High,0.5) , (MIS_High,0.7)}
9	{(ST_Middle,0.8) , (DB_Low,0.4) , (DB_Middle,0.2) , (OOP_Middle,0.5) , (OOP_High,0.1) , (DS_High,0.8) , (MIS_High,0.8)}
10	{(ST_Middle,0.5) , (ST_High,0.1) , (DB_Low,0.6) , (OOP_Low,0.6) , (DS_High,0.6) , (MIS_High,0.9)}

Passo 3: Para cada região (*Low, Middle, High*), calcular a cardinalidade escalar de todas as transações. Ver *count* na Tabela 6. Tendo ST_Low como exemplo, a cardinalidade escalar = (0.8 + 0.4 + 0.2) = 1.4. Repetir esse cálculo para todas as demais regiões (Tabela 8).

Tabela 8 – Conjuntos de 1-itemsets com seus valores *count*.

Itemset	*Count*
ST_Low	1.4
ST_Middle	3.7
ST_High	2
DB_Low	1.6
DB_Middle	2.1
DB_High	3.4
OOP_Low	1.1
OOP_Middle	1.9
OOP_High	4
DS_Low	0.8
DS_Middle	3.9
DS_High	2.5
MIS_Low	0.8
MIS_Middle	1.8
MIS_High	4.6

Passo 4: Para cada região, encontrar o maior valor *count* entre as 3 possíveis regiões. Tendo o curso *ST* como exemplo, o *count* é 1.4 para região *Low*, 3.7 para região *Middle*, e 2.0 para região *High*. Desde que o valor *count* para região *Middle* é a maior entre as 3, esta região então será usada para representar o curso *ST* no processo de mineração posterior. Esses passos são repetidos para as outras regiões. Fica então para o curso *DB*, *OOP* e *MIS* a região *High* como escolhida., e para os cursos ST e DS a região *Middle*.

Passo 5: Para cada região selecionada no Passo 4, verificar se o valor *count* é maior ou igual ao valor de suporte mínimo α predefinido. Esse valor de suporte é usualmente atribuído pelo usuário de acordo com a distribuição dos itens frequentes. Para o exemplo será assumido que o valor de suporte mínimo α = 2.0. Como os valores de *ST_Middle, DB_Middle, OOP_High, DS_MIddle* e MIS_High são maiores que 2.0, esses itens são colocados em L_1 (Tabela 9).

Tabela 9 – Conjuntos de 1-itemsets L_1.

Itemset	*Count*
ST_Middle	3.7
DB_High	3.4
OOP_High	4
DS_Middle	3.9
MIS_High	4.6

Passo 6: Novo ciclo para gerar novos candidatos. Setar *r*=1.

Passo 7: Gerar o conjunto-candidato Cr+1 a partir de L1., C2 é primeiro gerado a partir de L1. Ou seja, são geradas todas as possíveis combinações entre os itemsets de L1, conforme se segue: *(ST_Middle, DB_High), (ST_Middle, OOP_High), (ST_Middle, DS_Middle), (ST_Middle, MIS_High), (DB_High, OOP_High), (DB_High, DS_Middle), (DB_High, MIS_High), (OOP_High, DS_Middle), (OOP_High, MIS_High), (DS_Middle, MIS_High).*

Passo 8: Construir um conjunto vazio temporário: $\overline{C}_{r+1}$. $\overline{C}_2$ é então construído.

Passo 9: Para cada novo *itemset* candidato formado em C_2, seguir os seguintes sub-passos:

a) Para cada transação, é calculado o valor de pertinência *fuzzy* para o *itemset* a partir de $\overline{C_1}$. O operador mínimo é usado para a intersecção. Somente os casos 3, 4, 5 e 7 contêm ambos os itens *ST_Middle e DB_High* em $\overline{C_1}$ (Tabela 10).

Tabela 10 – O valor de pertinência para (*ST_Middle, DB_High*).

Case	ST_Middle	DB_High	(ST_Middle, DB_High). operador mínimo
1	0.0	0.0	0.0
2	**0.0**	0.1	0.0
3	**0.1**	0.9	0.1
4	1.0	**0.7**	0.7
5	**0.7**	0.9	0.7
6	0.2	**0.0**	0.0
7	**0.4**	0.8	0.4
8	0.0	0.0	0.0
9	0.8	**0.0**	0.0
10	0.5	**0.0**	0.0

Os resultados para os demais 2-itemsets podem ser vistos na Tabela 11.

Tabela 11 – Valor de pertinência dos demais 2-itemset.

Case	ST_Middle	OOP_High	Op. Min.	ST_Middle	DS_Middle	Op. Min.	ST_Middle	MIS_High	Op. Min..
1	**0.0**	0.7	0.0	**0.0**	0.8	0.0	0.0	0.0	0.0
2	**0.0**	0.9	0.0	**0.0**	0.7	0.0	**0.0**	0.2	0.0
3	**0.1**	0.7	0.1	**0.1**	0.5	0.1	**0.1**	0.9	0.1
4	1.0	**0.1**	0.1	1.0	**0.1**	0.1	1.0	**0.0**	0.0
5	**0.7**	0.8	0.7	**0.7**	0.9	0.7	0.7	**0.1**	0.1
6	**0.2**	0.7	0.2	0.2	**0.0**	0.0	**0.2**	0.8	0.2
7	0.4	**0.0**	0.0	**0.4**	0.8	0.4	**0.4**	0.2	0.2
8	0.0	0.0	0.0	**0.0**	0.1	0.0	**0.0**	0.7	0.0
9	0.8	**0.1**	0.1	0.8	**0.0**	0.0	0.8	0.8	0.8
10	0.5	**0.0**	0.0	0.5	**0.0**	0.0	**0.5**	0.9	0.5

Case	DB_High	OOP_High	Op. Min.	DB_High	DS_Middle	Op. Min.	DB_High	MIS_High	Op. Min.
1	**0.0**	0.7	0.0	**0.0**	0.8	0.0	0.0	0.0	0.0
2	**0.1**	0.9	0.1	**0.1**	0.7	0.1	**0.1**	0.2	0.1
3	0.9	**0.7**	0.7	0.9	**0.5**	0.5	0.9	0.9	0.9
4	0.7	**0.1**	0.1	0.7	**0.1**	0.1	0.7	**0.0**	0.0
5	0.9	**0.8**	0.8	0.9	0.9	0.9	0.9	**0.1**	0.1
6	**0.0**	0.7	0.0	0.0	0.0	0.0	**0.0**	0.8	0.0
7	0.8	**0.0**	0.0	0.8	0.8	0.8	0.8	**0.2**	0.2
8	0.0	0.0	0.0	**0.0**	0.1	0.0	**0.0**	0.7	0.0
9	**0.0**	0.1	0.0	0.0	0.0	0.0	**0.0**	0.8	0.0
10	0.0	0.0	0.0	0.0	0.0	0.0	**0.0**	0.9	0.0

Case	OOP_High	DS_Middle	Op. Min.	OOP_High	MIS_High	Op. Min.
1	**0.7**	0.8	0.7	0.7	**0.0**	0.0
2	0.9	**0.7**	0.7	0.9	**0.2**	0.2
3	0.7	**0.5**	0.5	**0.7**	0.9	0.7
4	0.1	0.1	0.1	0.1	**0.0**	0.0
5	**0.8**	0.9	0.8	0.8	**0.1**	0.1
6	0.7	**0.0**	0.0	**0.7**	0.8	0.7
7	**0.0**	0.8	0.0	**0.0**	0.2	0.0
8	**0.0**	0.1	0.0	**0.0**	0.7	0.0
9	0.1	**0.0**	0.0	**0.1**	0.8	0.1
10	0.0	0.0	0.0	**0.0**	0.9	0.0

Case	DS_Middle	MIS _High	Op. Min.
1	0.8	0.0	0.0
2	0.7	0.2	0.2
3	0.5	0.9	0.5
4	0.1	0.0	0.0
5	0.9	0.1	0.1
6	0.0	0.8	0.0
7	0.8	0.2	0.2
8	0.1	0.7	0.1
9	0.0	0.8	0.0
10	0.0	0.9	0.0

b) Armazenar os pares de cada *case* em $\overline{2}$ (Tabela 12).

Tabela 12 – Conjunto temporário $\overline{2}$.

Case	**Conjunto de *Itemsets***
1	{(OOP_High,DS_Middle,0.8)}
2	{(DB_High,OOP_High,0.1),(DB_High,DS_Middle,0.1),(DB_High,MIS_High,0.1),(OOP_High,DS_Middle,0.7),(OOP_High,MIS_High,0.2) ,(DS_Middle,MIS_High,0.2)}
3	{(ST_Middle,DB_High,0.1),(ST_Middle,OOP_High,0.1),(ST_Middle,DS_Middle,0.1),(ST_Middle,MIS_High,0.1),(DB_High,OOP_High,0.7),(DB_High,DS_Middle,0.5),(DB_High,MIS_High,0.9),(OOP_High,DS_Middle,0.5),(OOP_High,MIS_High,0.7),(DS_Middle,MIS_High,0.5)}
4	{(ST_Middle,DB_High,0.7),(ST_Middle,OOP_High,0.1),(ST_Middle,DS_Middle,0.1),(DB_High,OOP_High,0.1),(DB_High,DS_Middle,0.1),(OOP_High,DS_Middle,0.1) }
5	{(ST_Middle,DB_High,0.7),(ST_Middle,OOP_High,0.7),(ST_Middle,DS_Middle,0.7),(ST_Middle,MIS_High,0.1),(DB_High,OOP_High,0.8),(DB_High,DS_Middle,0.9),(DB_High,MIS_High,0.1),(OOP_High,DS_Middle,0.8),(OOP_High,MIS_High,0.1),(DS_Middle,MIS_High,0.1)}
6	{(ST_Middle,OOP_High,0.2),(ST_Middle,MIS_High,0.2),(OOP_High,MIS_High,0.7) }
7	{(ST_Middle,DB_High,0.4),(ST_Middle,DS_Middle,0.4),(ST_Middle,MIS_High,0.2),(DB_High,DS_Middle,0.8),(DB_High,MIS_High,0.2),(DS_Middle,MIS_High,0.2)}
8	{(DS_Middle,MIS_High,0.1)}

9	{(ST_Middle,OOP_High,0.1),(ST_Middle,MIS_High,0.8),(OOP_High,MIS_High,0.1) }
10	{(ST_Middle,MIS_High,0.5)}

c) Habilitar *counts* usando $\overline{\square 2}$. A cardinalidade escalar (*count*) de cada itemset candidato em C_2 é então calculada (Tabela 13). O valor em negrito será visto no subpasso seguinte.

Tabela 13 – Counts dos itemsets *fuzzy* em C2 .

Itemset	**Count**
(ST_Middle, DB_High)	1.9
(ST_Middle, OOP_High)	1.2
(ST_Middle, DS_Middle)	1.3
(ST_Middle, MIS_High)	1.9
(DB_High, OOP_High)	1.7
(DB_High,DS_Middle)	**2.4**
(DB_High,MIS_High)	1.3
(OOP_High,DS_Middle)	**2.8**
(OOP_High, MIS_High)	1.8
(DS_Middle, MIS_High)	1.1

d) Verificar quais *counts* são maiores ou iguais ao valor de suporte mínimo do suporte predefinido, no exemplo α = 2.0. (Tabela 13). Dois *itemsets*, (DB_Hight, DS_Midlle) e (OOP_High, DS_Middle), são mantidos em L_2 (Tabela 14).

Tabela 14 – *Itemset* e seus respectivos *count* em L_2 .

Itemset	**Count**
(DB_High,DS_Middle)	2.4
(OOP_High,DS_Middle)	2.8

Passo 10: Se L_{r+1} é nulo, executar o passo seguinte; caso contrário, habilitar *r* = *r+1* = 2. Os passos 7 a 10 são repetidos para encontrar L_3. C_3 é primeiro gerado à partir de L_2, e somente o itemset (*DB_High, OOP_High, DS_Middle*) é formado e possui seu valor count = 1.5 (Tabela 15). Ou seja, menor que o valor de suporte mínimo predefinido (α = 2). Então, este valor não é colocado em L_3. Desde que L_3 é um conjunto vazio, o passo 11 começa.

Tabela 15 – *Itemset* e seus respectivos *count* em L_2 .

Case	DB _High	OOP_High	DS_Middle	Op. Min.
1	**0.0**	0.7	0.8	0.0
2	**0.1**	0.9	0.7	0.1
3	0.9	0.7	**0.5**	0.5
4	0.7	**0.1**	**0.1**	0.1
5	0.9	**0.8**	0.9	0.8
6	**0.0**	0.7	**0.0**	0.0
7	0.8	**0.0**	0.8	0.0
8	**0.0**	**0.0**	0.1	0.0
9	**0.0**	0.1	**0.0**	0.0
10	0.0	0.0	0.0	0.0
			count	1.5

Passo 11: Construir as regras de associação para cada *itemset* que teve o valor *count* superior ou igual ao valor mínimo de suporte predefinido.

a) As 4 possíveis regras de associação são geradas a partir de 2-itemsets (DB_High,DS_Middle) e (OOP_High,DS_Middle).

SE *DB* = *High*, ENTÃO *DS* = *Middle*
SE *DS* = *Middle*, ENTÃO *DB* = *High*
SE *OOP* = *High*, ENTÃO *DS* = *Middle*
SE *DS* = *Middle*, ENTÃO *OOP* = *High*

b) Calcular os valores de confiança das regras de associação acima. Assume-se que, para o exemplo, o valor mínimo de confiança λ é 0.7.

SE *DB* = *High*, ENTÃO *DS* = *Middle*

DB_High ∩ *DS_Middle*	2.4	0.71
DB_High	3.4	

SE *DS* = *Middle*, ENTÃO *DB* = *High*

DS_Middle ∩ *DB_High*	2.4	0.62
DS_Middle	3.9	

SE *OOP* = *High*, ENTÃO *DS* = *Middle*

OOP_High ∩ *DS_Middle*	2.8	0.70
OOP_High	4.0	

SE *DS* = *Middle*, ENTÃO *OOP* = *High*

DS_Middle ∩ *OOP_High*	2.8	0.72
DS_Middle	3.9	

Passo 12: Verificar quais valores de confiança das regras de associação acima são maiores ou iguais ao valor mínimo de confiança λ predefinido. Desde que o valor de confiança é definido como 0.7, as seguintes 3 regras são dadas como resultado de saída ao usuário.

1) Se a nota de *Database* é *high*, então a nota de *Data Structure* é *middle* com valor de confiança de 0.71;

2) Se a nota de *Programação orientada a objeto* é *high*, então a nota de *Data Structure* é *middle* com valor de confiança de 0.70;

3) Se a nota de *Data Structure* é *middle*, então a nota de *Programação orientada a objeto* é *high* com valor de confiança de 0.72;

Depois do Passo 12: As 3 regras acima são então as saídas como meta-conhecimento atribuído às dadas transações.

2.6.3 Classificação associativa - Algoritmo CFAR

O algoritmo aplicado para classificação das regras de associação foi o classificador CFAR (Classification with Fuzzy Association Rules) (CHEN, 2008).

O problema de *sharp boundary* que ocorre com as regras de associação de atributos com valores quantitativos foi resolvido com a proposta de regras de associação baseada em conjuntos fuzzy. O mesmo problema de *sharp boundary* ocorre com a classificação associativa, na qual a partição dos atributos quantitativos, na etapa de geração de regras, também é baseada em conjuntos fuzzy.

Como no classificador CBA, a classificação baseada em regras de associação proposta no classificador CFAR tem o objetivo de construir um classificador através da eliminação de regras de baixa qualidade e assim selecionar um subconjunto de regras de alta confiança para criar um classificador associativo.

3 SISTEMA DE DETECÇÃO DE INTRUSOS

3.1 Introdução

Os dados que trafegam nas redes de computadores são cada vez mais importantes e valiosos, e essas devem ser seguras para que todas as pessoas possam utilizá-la sem risco e medo. O objetivo da segurança é fazer com que as pessoas se sintam livres e seguras para desfrutar das redes de computadores sem medo ou preocupação de comprometer suas informações, garantindo assim seus direitos, interesses e privacidade (WANG, 2009).

A Segurança da Informação se refere à proteção existente sobre as informações tanto no ambiente corporativo (empresas) quanto às pessoais. Entende-se por informação todo e qualquer conteúdo ou dado que tenha valor para alguma organização ou pessoa.

A norma ABNBT NBR ISO/IEC 27002:2005 define segurança da informação como a proteção da informação contra os vários tipos de ameaças, com o objetivo de garantir a continuidade do negócio, minimizar seus riscos e maximizar o retorno sobre os investimentos e as oportunidades do negócio.

Existem três aspectos-chave da segurança da informação comumente referidos como CIA[11] Triad: Confidencialidade, Integridade e Disponibilidade.

- A confidencialidade: nenhum acesso à informação deverá ser garantido a pessoas ou sistemas não autorizados, isto é, apenas aqueles com os direitos e privilégios necessários e concedidos serão capazes de acessar a informação, independente do seu local de armazenamento, ou ainda que esteja em processamento ou em trânsito. A violação da confidencialidade pode ocorrer por modo intencional através de ataques, captura de tráfego, entre outros fatores, bem como de forma não deliberada, por imperícia ou negligência da pessoa.

[11] CIA (Central Intelligence Agency) é uma referência amplamente utilizada para a avaliação de segurança de sistemas de informação.

- A integridade: se refere-se à confiabilidade dos recursos de informação, e isso inclui o conceito de integridade de dados, ou seja, que os dados não foram alterados de forma inadequada, seja por acidente, seja deliberadamente, por atividade nociva entre os momentos de transmissão e recepção.
- A disponibilidade: é o aspecto da segurança da informação que diz que esta deve estar disponível para ser acessada quando solicitada por uma pessoa ou sistema legítimo. Isto requer que toda estrutura que permite acesso e transporte da informação deve ser protegida para que não seja degradada ou se torne indisponível. Com relação à disponibilidade, os tipos de ataque que representam maior ameaça são DoS (*Denial of Service*) e DDoS (*Distributed Denial of Service*) , que visam a danificar ou sobrecarregar sistemas.

Segurança é um processo e não um estado. Envolve quatro etapas, sendo estas de avaliação, proteção, de detecção e resposta ao ocorrido. A etapa de detecção é o tema principal deste trabalho, que focaliza a aplicação dos algoritmos de extração de regras de associação numa base de dados de um Sistema de Detecção de Intrusos.

Segundo BACE (2000), detecção de intrusão é definida como o processo de monitorar eventos que ocorrem em um sistema computacional ou em redes de computadores, de forma a encontrar evidências de possíveis ataques à segurança.

Existe uma lista extensa de tecnologias que protegem o perímetro das redes de computadores contra invasões e ameaças externas. No entanto, esses sistemas não podem interromper os invasores que obtêm acesso autenticado e se utilizam do sistema como se fossem usuários legítimos. Assim, torna-se importante monitorar as informações embutidas nos pacotes que atravessam o *firewall* para analisar como os usuários, legítimos ou não, utilizam seus ambientes computacionais, monitorando suas atividades e permitindo a detecção das ações de invasão (WANG, 2009).

Os primeiros conceitos sobre sistemas com características para detectar intrusos foram propostos por James P. Anderson em 1980 (ANDERSON, 1980). Segundo WANG (2009), os sistemas para detectar invasões tiveram seu início (segundo Dorothy Denning e Peter Neumann) também em meados de 1980. Na época, eles observaram que os invasores tinham uma forma de agir diferente dos usuários normais do sistema, sendo assim possível a análise quantitativa do ataque.

Para identificar os eventos de ataques nos sistemas, é necessário a criação de ferramentas inteligentes que analisam os protocolos de rede, análise de estatísticas computacionais e mineração de dados.

Essas ferramentas chamadas de Sistemas de Detecção de Intrusão (SDI), são sistemas automatizados que procuram por evidências de intrusão direta ou indireta, incluindo eventos que já aconteceram ou que estão atualmente em curso. Quanto mais rápida for a detecção do evento, menores serão os prejuízos para o ambiente computacional causados pelo ataque.

O funcionamento de um SDI é baseado na premissa de ser possível detectar o comportamento anormal, pois este será notoriamente diferente de um comportamento considerado padrão, usualmente praticado por um usuário legítimo. Normalmente, os SDIs implementam modelos estatísticos ou se baseiam em regras que detectam o uso indevido.

DENNING (1987) propõe um modelo de sistema especialista para detecção de intrusão em tempo real capaz de detectar interrupções, penetrações e outras formas de ataque. Esse modelo se baseia na hipótese de que um evento pode ser detectado a partir do monitoramento dos registros de auditoria dos sistemas em busca de padrões de uso anormal.

3.2 Arquitetura dos SDIs

Os SDIs são classificados em dois modelos de monitoração: Host (HIDS - *Host Intrusion Detection System*) ou em Rede (NIDS - *Network Intrusion Detection System*). HIDS refere-se à detecção de intrusão que ocorre em um sistema host único. HIDS atualmente envolve a instalação de um agente na máquina local que monitora e informa sobre a atividade de configuração do sistema e da aplicação. Algumas habilidades comuns de sistemas HIDS incluem análise de *log*, correlação de eventos, verificação de integridade, aplicação de políticas, detecção de *rootkit*, e alertas. NIDS tem seu funcionamento baseado na análise do tráfego da rede, pacote a pacote, em busca de atividades suspeitas, que poderiam ser um ataque ou atividade não autorizada.

Os SDIs podem detectar a intrusão para poucos ataques em tempo real ou a posteriori; neste último, os dados são analisados de forma seqüencial *off- line* (batch). Geralmente os SDIs adotam uma configuração de “quase tempo real” para alguns ataques, ou seja, necessitam agregar informações suficientes durante algum tempo para poder fazer um julgamento. Ao detectar um ataque, porém, o SDI pode agir passiva ou ativamente: no primeiro caso, envia alertas sobre o evento; no segundo, atua sobre os dispositivos de proteção, fazendo com que bloqueiem o ataque. Este modo, no entanto, deve ser utilizado com muito cuidado, pois pode se tornar uma nova vulnerabilidade.

As abordagens de detecção da intrusão consistem em três categorias. A primeira, por uso indevido (*misuse detection*): a partir de um banco de dados de assinaturas de eventos anteriormente caracterizados como maliciosos, procura-se pela presença destas particularidades no tráfego analisado; a segunda, por detecção por anomalia (*anomaly detection*): a partir de uma referência de características de comportamento considerados normais, pesquisa-se qualquer desvio que seja significativo dentro de limites pré-estabelecidos pelo especialista; e a terceira, por sistemas híbridos, que basicamente utilizam as técnicas citadas anteriormente.

3.2.1 Detecção por uso indevido

A detecção por uso indevido baseia-se na representação dos eventos na forma de padrões ou assinaturas, os quais permitirão detectar pequenas variações nas características do ataque. Embora seja totalmente eficaz na descoberta de ataques conhecidos, é totalmente ineficaz quando confrontada com padrões de ataques novos ou desconhecidos, já que as novas assinaturas ainda não estão disponíveis.

O desafio dos sistemas de detecção por uso indevido é definir regras que atendam todas as possibilidades de ataques. Quaisquer erros na definição destas assinaturas irá aumentar a taxa de falsos alarmes e comprometerá a eficácia da técnica de detecção.

A Figura 24 ilustra um modelo típico de detecção por uso indevido. O modelo consiste de quatro componentes: coletor de dados, perfil do sistema, detecção de uso indevido e saída / resposta em forma de alerta. Os dados são coletados a partir de uma ou várias fontes de dados, tráfego de rede, sistema de rastreamento etc.

Figura 24 - Sistema de Detecção de Intrusão por uso indevido.

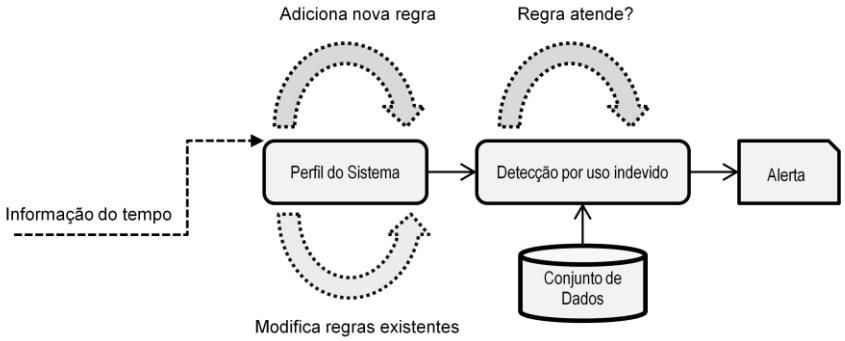

Os sistemas baseados em assinatura podem ser:

- Sistemas especialistas: capazes de analisar através de regras SE/ENTÃO, reconhecendo ataques e formulando uma solução ao problema;
- Por modelamento: compara informações de registros de auditoria com modelos de comportamentos de ataque, para gerar uma suspeita ou para descartá-la.

3.2.2 Detecção por anomalia

Diferente da técnica de detecção de uso indevido, detecção de anomalias é dedicado a estabelecer perfis normais de atividade para o sistema. Baseia-se no pressuposto de que todas as atividades de um intruso são necessariamente anômalas. Essa técnica estrutura primeiro um perfil de utilização normal do sistema, e qualquer variação ou desvio deste perfil que tenha significado estatístico e ultrapasse os limites previamente estabelecidos, pode vir a ser um ataque.

Os dados de tráfego tidos como normais são obtidos e salvos pelo componente coleção. O componente de detecção de anomalias decide quão longe as atividades atuais se desviam dos perfis normais do sistema e qual percentagem

dessas atividades deve ser marcada como anormal. Finalmente, o componente de resposta relata a intrusão e, possivelmente, a correspondente informação de tempo.

A principal vantagem da detecção de anomalias é a sua capacidade para encontrar novos ataques assim que ocorrem, porém requerem uma fase de treinamento e uma configuração mais específica e cuidadosa do seu limiar de detecção. O seu maior desafio é estabelecer um limiar no qual não se deixe de detectar tentativas reais, chamadas de falso negativo (Figura 25).

Figura 25 - Probabilidade de Detecção entre Atividades Normais e Anormais.

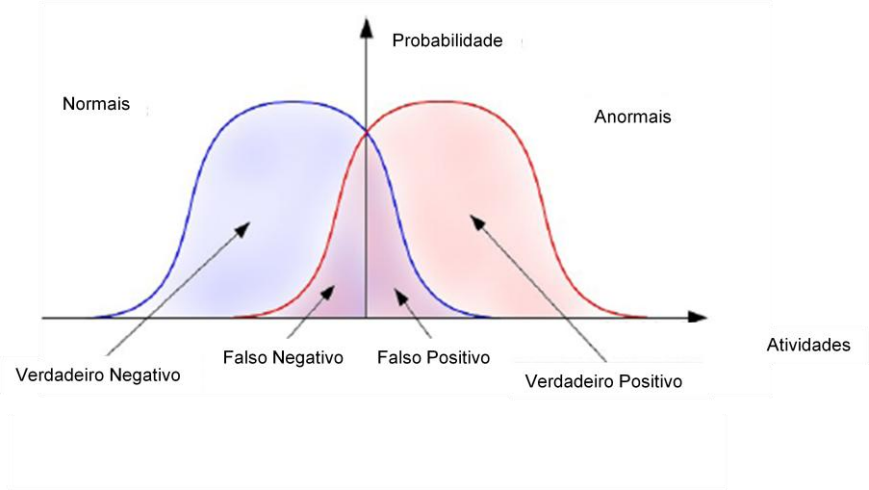

A Figura 26 ilustra um modelo típico de detecção por anomalia. O modelo consiste de quatro componentes: coletor de dados, perfil normal do sistema , detecção de anomalias e saída/resposta em forma de alerta. Os dados são coletados a partir de uma ou várias fontes de dados, do tráfego de rede, do sistema de rastreamento etc.

Figura 26 - Sistema de Detecção de Intrusão por anomalia.

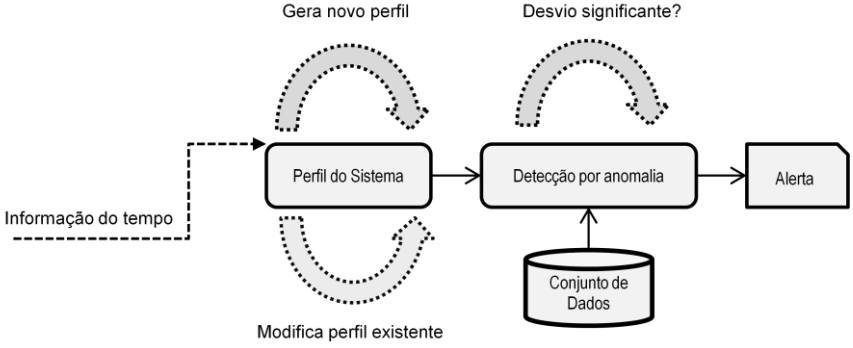

4 EXPERIMENTOS

Este capítulo aborda a modelagem dos dados utilizados para os experimentos desta dissertação. Os dados utilizados foram extraídos de uma base de dados utilizada no KDD Cup 1999 Data - Terceira Competição Internacional de Descoberta de Conhecimento e Ferramentas de Mineração de Dados, que ocorreu em conjunto com a Quinta Conferência Internacional de Descoberta de Conhecimento e Mineração (KDD99). Nessa competição foi escolhido o problema de detecção de intruso, e a base de dados serviu como *benchmarking* para a construção de uma rede de detecção de intrusos, em que um modelo preditivo seria capaz de distinguir entre conexões “ruins” como invasões ou ataques, e “boas” como conexões normais.

4.1 Ferramentas de mineração de dados

Importante destacar neste trabalho a dificuldade de se encontrar *software* com interface GUI (*Graphical User Interface*) para aplicação do algoritmo *Fuzzy* Apriori para a extração de regras de associação. Alguns softwares voltados para mineração de dados aplicados em conjunto de dados com atributos de valores quantitativos, mas com pré-processamento na forma de discretização para aplicação do algoritmo Apriori, foram encontrados. Dentre todos os pesquisados, o WEKA, além de ser o mais utilizado e possuir vasta literatura, foi compatível com os experimentos deste trabalho.

Entretanto, para a aplicação do algoritmo *Fuzzy* Apriori, nenhum software havia sido encontrado. Todos os trabalhos relacionados apontavam para utilização de pseudoscódigos, menção de que os experimentos foram feitos na linguagem C+, Java ou no ambiente Matlab, mas efetivamente nenhuma ferramenta GUI que pudesse ser utilizada para a análise de desempenho dos dois algoritmos.

Depois de uma extensa pesquisa, primeiramente foi encontrado o *software Fuzzy* Apriori-T (LUCS/KDD)[12] desenvolvido pela equipe do Dr. Coenen[13], da Universidade de Liverpool. Entretanto a ferramenta não possui uma interface amigável e os dados para serem lidos possuem formatação própria que exigiu um esforço computacional e de preparação dos dados excessivo.

O *software* KEEL surgiu como uma opção que poderia ser utilizada no trabalho. Tendo que optar entre o LUCS/KDD e o KEEL, apesar do KEEL também não apresentar usabilidade muito favorável, mas muito mais amigável que o LUCS/KDD, optou-se por este, tendo como justificativas sua similaridade com o software WEKA em termos de formato de arquivo, a opção de desenvolvimento de experimentos e principalmente a disponibilidade de outros algoritmos agregados à ferramenta, tais como os de classificação de regras.

Para o desenvolvimento dos experimentos dessa dissertação, foram então escolhidas as duas ferramentas baseadas em software do tipo *open source*, sendo elas: WEKA (HALL et. al., 2009) na versão 3.7.10 e KEEL (ALCALA et. al., 2011).na versão *Open source version de 01-04-2013)*.

4.2 Descrição dos dados

O arquivo fonte extraído do repositório UC Irvine Machine Learning Repository (UCI)[14] , para a realização dos experimentos. Os dados são formados por um conjunto de registros de conexões de pacotes TCP, começando e terminando em um tempo definido, um fluxo de dados tendo como origem e destino um endereço IP, origem e alvo respectivamente, e um protocolo bem definido. Os dados incluem um conjunto de dados de treinamento e outro de teste. O de treinamento foi formado após 7 semanas de monitoramento do ambiente de rede, e o de teste foi formado após 2 semanas de monitoramento, não possuindo a mesma probabilidade de distribuição do conjunto de treinamento. Desde que a distribuição de probabilidade não é a mesma, em nosso experimento, iremos usar apenas o conjunto de

---

[12] *Fuzzy* Apriori-T: http://cgi.csc.liv.ac.uk/~frans/KDD/Software/*Fuzzy*AprioriT/*fuzzy*AprioriT.html
[13] Professor e Vice-Chefe do Departamento de Ciência da Computação da Universidade de Liverpool.
[14] University of California - Irvine - http://archive.ics.uci.edu/ml/index.html

treinamento. O conjunto de dados foi pré-processado em aproximadamente 5.000.000 de registros de conexões, como KDD Cup 1999.

4.2.1 Características da base de dados KDD99

Cada conexão de rede é representada por 41 atributos (KDD99) que descrevem as diferentes características de cada conexão e ainda uma classe nomeada por um rótulo, assumido por cada uma delas como um tipo de ataque específico ou normal. Cada atributo que caracteriza cada uma das conexões é classificado como qualitativo ou quantitativo, sendo que os qualitativos assumem valores 0 ou 1, normal ou erro, e os quantitativos variam dentro de uma faixa de valores. A Figura 27 representa o modelo básico dos registros de conexões, e a Tabela 16 representa os 41 atributos do conjunto de dados KDD99 com a respectiva categoria.

Figura 27 - Modelo básico dos registros de conexões.

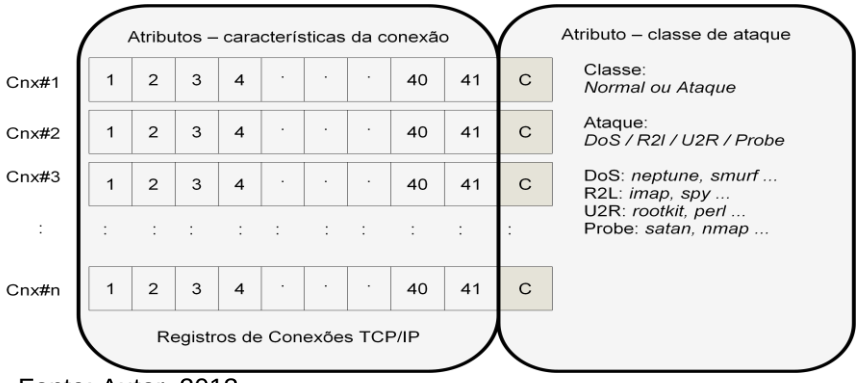

Fonte: Autor, 2013

Tabela 16 – Atributos das conexões de rede.

#	Atributos	Categoria	#	Atributos	Categoria
1	duration	Quantitativo	22	*is_guest_login*	*Qualitativo*
2	*protocol_type*	*Qualitativo*	23	count	Quantitativo
3	*service*	*Qualitativo*	24	srv_count	Quantitativo
4	src_byte	Quantitativo	25	serror_rate	Quantitativo
5	dst_byte	Quantitativo	26	srv_serror_rate	Quantitativo
6	*flag*	*Qualitativo*	27	rerror_rate	Quantitativo

7	*land*	*Qualitativo*	28	srv_rerror_rate	Quantitativo
8	wrong_fragment	Quantitativo	29	same_srv_rate	Quantitativo
9	urgent	Quantitativo	30	diff_srv_rate	Quantitativo
10	hot	Quantitativo	31	srv_diff_host_rate	Quantitativo
11	num_failed_logins	Quantitativo	32	dst_host_count	Quantitativo
12	*logged_in*	*Qualitativo*	33	dst_host_srv_count	Quantitativo
13	num_comprissed	Quantitativo	34	dst_host_same_srv_count	Quantitativo
14	*root_shell*	*Qualitativo*	35	dst_host_diff_srv_rate	Quantitativo
15	*su_attempted*	*Qualitativo*	36	dst_host_same_src_port_rate	Quantitativo
16	num_root	Quantitativo	37	dst_host_srv_diff_host_rate	Quantitativo
17	num_file_creations	Quantitativo	38	dst_host_serror_rate	Quantitativo
18	num_shells	Quantitativo	39	dst_host_srv_serror_rate	Quantitativo
19	num_access_files	Quantitativo	40	dst_host_rerror_rate	Quantitativo
20	num_outbund_cmds	Quantitativo	41	dst_host_srv_rerror_rate	Quantitativo
21	*is_hot_login*	*Qualitativo*			

Esses atributos da conexão são agrupados em três categorias. A primeira categoria, STOLFO et al. (1999) definem como sendo atributos de nível superior que ajudam a distinguir as conexões normais de ataques. São conhecidas como atributos básicos do protocolo TCP/IP. Para a segunda categoria, STOLFO et al. (1999) utilizam o domínio do conhecimento para adicionar atributos que parecem ser um comportamento suspeito, como, por exemplo, o número de tentativas de login. Esses atributos são chamados de atributos de conteúdo. Fechando a terceira categoria, temos os atributos de tráfego calculado, usando a teoria da janela de dois segundos. Uma breve descrição de cada um desses três agrupamentos e dos respectivos atributos o respectivo é feita a seguir:

a) **Características básicas do TCP/IP**: atributos de nível superior que ajudam a distinguir as conexões normais de ataques. São conhecidas como atributos básicos ao se analisar um fluxo de pacotes de protocolo TCP/IP (Tabela 17).

Tabela 17 – Categoria dos atributos - básicas do TCP/IP.

Atributo	Descrição
duration	Tempo em segundos de conexão
protocol_type	Tipo de protocolo usado (TCP, UDP etc.)
service	Serviço de rede utilizado (HTTP, Telnet etc.)
src_byte	Número de bytes enviados da origem ao destino

dst_byte	Número de bytes enviados do destino à origem
flag	Estado da conexão (normal ou erro)
land	“1” se o host e a porta da origem e destino são os mesmos, “0” caso contrário
wrong_fragment	Número de fragmentos com erro
urgent	Número de pacotes com flag urgente habilitado

b) **Características sugeridas através do conhecimento da área**: utiliza o domínio do conhecimento para adicionar atributos que parecem ser um comportamento suspeito. Ou seja, apenas com o auxílio de especialistas para se chegar a conclusões de que padrões associados a conexões podem representar um dado tipo de ataque, como, por exemplo, o número de tentativas de login como usuário privilegiado em determinada conexão. Esses atributos são chamados de atributos de conteúdo (Tabela 18).

Tabela 18 – Categoria dos atributos - por conhecimento especialista.

Atributo	Descrição
hot	Número de indicadores “chaves”
num_failed_logins	Número de tentativa de login com falha
logged_in	“1” se o login obteve sucesso, e “0” caso contrário
num_comprissed	Número de condições de “comprometimento”
root_shell	“1” se o shell root é obtido; “0” caso contrário
su_attempted	“1” se comando “su root” é atendido; “0” caso contrário
num_root	Número de acessos como root
num_file_creations	Número de operações de criação de arquivos
num_shells	Números de Shell prompts abertos
num_access_files	Número de operações a arquivos de controle de acesso
num_outbund_cmds	Número de comandos externos em uma sessão FTP
is_hot_login	“1” se o login pertence à lista “hot”, “0” caso contrário
is_guest_login	“1” se login é do tipo “guest”, “0” caso contrário

c) **Características obtidas através de uma janela de 2 segundos:** são atributos de tráfego calculado, usando-se a teoria da janela de dois segundos. Informações importantes referentes a certos ataques somente podem ser obtidas levando-se o tempo em consideração (Tabela 19).

Tabela 19 – Categoria dos atributos - teoria da janela de dois segundos.

Atributo	Descrição
count	Número de conexões para o mesmo host como conexão atual nos últimos 2 segundos.
srv_count	Número de conexões para o mesmo serviço que o usado nesta conexão nos últimos 2 segundos.
serror_rate	% de conexões que tiveram erros do tipo “SYN”.
srv_serror_rate	% de conexões que tiveram erros do tipo “SYN” para este serviço.
rerror_rate	% de conexões que tiveram erros do tipo “REJ”.
srv_rerror_rate	% de conexões que tiveram erros do tipo “REJ” para este serviço.
same_srv_rate	% de conexões ao mesmo serviço.
diff_srv_rate	% de conexões a diferentes serviços
srv_diff_host_rate	% de conexões a diferentes hosts.
dst_host_count	Número de conexões com mesmo host de destino que esta.
dst_host_srv_count	Número de conexões com mesmo host de destino e mesmo serviço que esta.
dst_host_same_srv_count	% de conexões com o mesmo host de destino e mesmo serviço que esta.
dst_host_diff_srv_rate	% de conexões com o mesmo host de destino e serviços diferentes que esta.
dst_host_same_src_port_rate	% de conexões com o mesmo host de destino e a mesma porta de origem que a conexão atual.
dst_host_srv_diff_host_rate	% de conexões para o mesmo serviço vindo de diferentes hosts.
dst_host_serror_rate	% de conexões para o mesmo host que o da conexão atual e que possui um erro S0
dst_host_srv_serror_rate	% de conexões para o mesmo host e serviço que o da conexão atual e que possui um erro S0.
dst_host_rerror_rate	% de conexões para o mesmo host que apresentem flag RST.
dst_host_srv_rerror_rate	% de conexões para o mesmo host e serviço da conexão atual que apresentem flag RST.

Conforme mencionado anteriormente, cada conexão de rede é representada por 41 atributos e mais um atributo de classe nomeado por um rótulo, assumido por cada uma delas como um tipo de ataque específico ou normal. A taxonomia propõe a classificação dos tipos de ataque e intrusões em quatro categorias distintas, sendo elas:

- (DOS) - negação de serviço *denial of service*.
- (Remoto para usuário - R2L) - acesso não autorizado de máquina remota, isto é, adivinhar senha *guessing password*.

- (Usuário para usuário - U2R) - acesso não autorizado de usuário para privilégios de superusuário (*root*).
- (PROBING) – reconhecimento.

DoS: é uma classe de ataques contra a disponibilidade de sistemas computacionais. O objetivo do atacante é causar a indisponibilidade do serviço-alvo, seja através do consumo excessivo de recursos computacionais como memória, processador ou rede para atendimento a solicitações falsas, seja através de indisponibilidade total do serviço por exploração de uma falha grave nele existente.

R2L: essa categoria de ataques e intrusões engloba todos os ataques em que o intruso possui acesso ao sistema como um usuário normal e consegue elevar seu nível de privilégio para o de um usuário especial (como o usuário root em sistemas Unix ou administrador em outras plataformas).

U2R: responde a situações em que o intruso possui conectividade com a máquina-vítima – sem, entretanto, possuir uma conta de usuário – e explorando alguma vulnerabilidade existente, consegue obter acesso local à máquina.

PROBING: emprega-se normalmente em uma etapa que antecede o ataque ou intrusão. Nesta categoria estão ferramentas e mecanismos automatizados que permitem ao invasor encontrar novas vítimas e conhecê-las melhor. O invasor pode descobrir, por exemplo, quais sistemas estão ativos em determinado momento, quais serviços estão ativos em determinado computador, fabricante e versão do software que fornece cada um destes serviços, dentre outras informações.

4.2.2 Distribuição dos registro de conexões e ataques

O conjunto de dados utilizado na competição KDD 99 foi dividido em três bases de dados diferentes denominadas de 10% KDD, *Corrected KDD* e *Whole* KDD. Tais bases referem-se à base de dados utilizada para treinamento, teste e o conjunto original respectivamente. A base de dados 10% KDD, empregada como proposta da fase de treinamento, leva esse nome por representar apenas 10% dos dados originais (*Whole KDD*) e contém 22 tipos de ataques dos 39 presentes na fase de teste. Ou seja, os ataques conhecidos são aqueles presentes na fase de treinamento, enquanto os novos ataques são os ataques adicionais na fase de teste,

não disponíveis na fase de treinamento. Essa base de dados 10% KDD contém mais exemplos de ataque do que conexão normal, e os tipos de ataques não são representados igualmente. Por causa da sua natureza, ataques do tipo DoS contabilizam a maioria dos ataques.

A base de dados KDD10% utilizada inicialmente nesta dissertação consiste de 494.020 registros de conexões dentre os quais 97.277 (19,69%) são normais, 391.458 (79,24%) sofreram o tipo de ataque DOS, 4.107 (0,83%), do tipo Probe, 1.126 (0,23%) do tipo R2L e 52 (0,01%) do tipo U2R. A respectiva distribuição dos tipos de ataque na base de dados 10%KDD (treinamento), *Corrected KDD* (teste) e *Whole KDD* (base original) podem ser visualizadas na Tabela 20.

Tabela 20 - Características básicas da base de dados KDD99 em termos de número de amostras e percentual por tipo de categoria de ataque.

Categoria Ataque	10% KDD		*Corrected* KDD		*Whole* KDD	
	Treinamento	%	Teste	%	Original	%
DoS	391458	79,24%	229853	73,90%	3883370	79,28%
Probe	4107	0,83%	4166	1,34%	41102	0,84%
u2r	52	0,01%	70	0,02%	52	0,001%
r2l	1126	0,23%	16347	5,26%	1126	0,02%
Normal	97277	19,69%	60593	19,48%	972780	19,86%
Total	494020	100%	311029	100%	4898430	100%

A lista dos rótulos de classe de ataque (Ataque) com a quantidade de amostras (Qtd amostra), o percentual da quantidade de amostras (%) e as respectivas categorias de tipo de ataque (Categoria) para cada base de dados do KDD99, sendo 10% KDD (treinamento), Corrected (teste) e Whole KDD (original), podem ser vistas na Tabela 21, Tabela 22 e Tabela 23, respectivamente.

Tabela 21 - Tipos de ataque, quantidade de amostras e classe da categoria da base de dados de treinamento (10% KDD).

Ataque	Qtd amostra	%	Categoria
Smurf	280790	56.84%	dos
Neptune	107201	21.70%	dos
Normal	97277	19.69%	normal
Back	2203	0.45%	dos
Satan	1589	0.32%	probe

Ipsweep	1247	0.25%	probe
portsweep	1040	0.21%	probe
warezclient	1020	0.21%	r2l
Teardrop	979	0.20%	dos
Pod	264	0.05%	dos
Nmap	231	0.05%	probe
guess_passwd	53	0.01%	r2l
buffer_overflow	30	0.01%	u2r
Land	21	0.00%	dos
warezmaster	20	0.00%	r2l
imap	12	0.00%	r2l
rootkit	10	0.00%	u2r
loadmodule	9	0.00%	u2r
ftp_write	8	0.00%	r2l
multihop	7	0.00%	r2l
phf	4	0.00%	r2l
perl	3	0.00%	u2r
spy	2	0.00%	r2l
TOTAL	494020	100%	

Tabela 22 - Tipos de ataque, quantidade de amostras e classe da categoria da base de dados de teste (*Corrected*).

Ataque	Qtd. amostra	%	Categoria
smurf	164091	52,75746%	DOS
normal	60593	19,48146%	Normal
neptune	58001	18,64810%	DOS
snmpgetattack	7741	2,48884%	r2l
mailbomb	5000	1,60757%	DOS
guess_passwd	4367	1,40405%	r2l
snmpguess	2406	0,77356%	r2l
satan	1633	0,52503%	Probing
warezmaster	1602	0,51506%	r2l
back	1098	0,35302%	DOS
mscan	1053	0,33855%	Probing
apache2	794	0,25528%	DOS
processatable	759	0,24403%	DOS
saint	736	0,23663%	Probing
portsweep	354	0,11382%	Probing
ipsweep	306	0,09838%	Probing
httptunnel	158	0,05080%	u2r
pod	87	0,02797%	DOS
nmap	84	0,02701%	Probing
buffer_overflow	22	0,00707%	u2r

multihop	18	0,00579%	r2l
named	17	0,00547%	r2l
sendmail	17	0,00547%	r2l
ps	16	0,00514%	u2r
rootkit	13	0,00418%	u2r
xterm	13	0,00418%	u2r
teardrop	12	0,00386%	DOS
land	9	0,00289%	DOS
xlock	9	0,00289%	r2l
xsnoop	4	0,00129%	r2l
ftp_write	3	0,00096%	r2l
udpstorm	2	0,00064%	DOS
phf	2	0,00064%	r2l
loadmodule	2	0,00064%	u2r
perl	2	0,00064%	u2r
sqlattack	2	0,00064%	u2r
worm	2	0,00064%	r2l
imap	1	0,00032%	r2l
TOTAL	311029	100%	

Tabela 23 - Tipos de ataques, quantidades de amostras e classes da categoria da base de dados original (Whole KDD).

Ataque	Qtd amostra	%	Categoria
smurf	2807886	57,32219%	DOS
neptune	1072017	21,88492%	DOS
normal	972780	19,85902%	Normal
satan	15892	0,32443%	Probing
ipsweep	12481	0,25480%	Probing
portsweep	10413	0,21258%	Probing
nmap	2316	0,04728%	Probing
back	2203	0,04497%	DOS
warezclient	1020	0,02082%	r2l
teardrop	979	0,01999%	DOS
pod	264	0,00539%	DOS
guess_passwd	53	0,00108%	r2l
buffer_overflow	30	0,00061%	u2r
land	21	0,00043%	DOS
warezmaster	20	0,00041%	r2l
imap	12	0,00024%	r2l
rootkit	10	0,00020%	u2r
loadmodule	9	0,00018%	u2r
ftp_write	8	0,00016%	r2l
multihop	5	0,00010%	r2l

phf	4	0,00008%	r2l
perl	3	0,00006%	u2r
spy	2	0,00004%	r2l
TOTAL	4898428	100%	

4.2.3 Reamostragem do conjunto de dados

Um aspecto que tem grande impacto em problemas de mineração de regras de associação e classificação é a desigualdade na distribuição dos padrões entre os grupos, que tende a aparecer quando as informações associadas a determinadas classes são mais difíceis de se obter. Pode-se observar esse comportamento, por exemplo, em um estudo sobre uma doença rara em uma certa população. A proporção de pessoas doentes encontradas é muito menor que a proporção de pessoas sadias. Em situação com problemas dessa natureza, onde o número de exemplos entre as classes no conjunto de treinamento variam significativamente, algoritmos de aprendizagem tradicionais têm apresentado dificuldade em distinguir entre os vários grupos. Em geral, a tendência é favorecer as classes com maior probabilidade de ocorrência, resultando em baixas taxas de reconhecimento para os grupos minoritários. O problema de classes desbalanceadas tende a aparecer porque principalmente os algoritmos tradicionais assumem diferentes erros como igualmente importantes, supondo que as distribuições são relativamente equilibradas

No caso do conjunto de dados KDD99, pode ser visto anteriormente na Tabela 20, este desbalanceamento de dados. A categoria de ataque DoS possui no conjunto de dados de treinamento mais de 79,24% dos tipos de ataque, 1,07% os demais ataques e 19,69% são os registros sem ataque ditos normais. Como o objetivo do trabalho é fazer uma análise comparativa de algoritmo aplicado na mineração de regras de associação e posterior classificação, buscou-se reduzir a amostra de registros (instâncias) desconsiderando aqueles inexpressivos. Para o desenvolvimento do trabalho foi então escolhido um novo conjunto de dados denominado 10%KDD/DoS que, se comparado com o conjunto de dados de treinamento 10%KDD original, mostra que a redução de amostras é menor que 1 % (Tabela 24). Ou seja, é uma redução insignificante e que, para a proposta desta dissertação, ainda torna os experimentos com alto custo computacional.

Tabela 24 - Conjunto de dados 10%KDD x 10%KDD/DoS.

Categoria Ataque	Qtd amostra - 10% KDD		Qtd amostra - 10% KDD - DoS	
DoS	391458	79.24%	391458	80.10%
Probe	4107	0.83%	0	0.00%
u2r	52	0.01%	0	0.00%
r2l	1126	0.23%	0	0.00%
Normal	97277	19.69%	97277	19.90%
Total	494020	100%	488735	100.0%

Outro ponto a ser observado neste conjunto de dados KDD/DoS é o mesmo problema de desbalanceamento de dados quanto à distribuição individual dos tipos de ataques da categoria DoS. Os ataques *back, teardrop, pod e land* juntos representam 0.7% do total dos ataques (Tabela 25). Percentual bem inferior aos 79.38% dos demais ataques smurf e neptune, o que apontou para uma reamostragem do conjunto DoS de forma a tratar este desbalanceamento de dados.

Tabela 25 - Conjunto de dados 10%KDD/DoS.

Ataque	Qtd amostra	%	Categoria
Smurf	280790	57.45%	dos
Neptune	107201	21.93%	dos
Normal	97277	19.90%	normal
Back	2203	0.45%	dos
Teardrop	979	0.20%	dos
Pod	264	0.05%	dos
Land	21	0.004%	dos
TOTAL	488735	100%	

Apesar da tarefa de reamostragem ser anterior a etapa de seleção de atributos na etapa de pré-processamento de mineração de dados, ela se deu após a escolha do trabalho segundo WANG et. al. (2008) para seleção de atributos relevantes, o que será visto no tópico seguinte. De maneira a tornar coerentes os dados desta dissertação, a exemplo da seleção dos atributos relevantes, a reamostragem do conjunto de dados DoS segundo WANG et. al. (2008) também foi utilizada (Tabela 26) (Gráfico 1).

Tabela 26 - Reamostragem segundo WANG.

Ataque	10%KDD/DoS	%	WANG	%
Smurf	280790	57.45%	10000	17.70%
Neptune	107201	21.93%	5000	8.85%
Normal	97277	19.90%	40000	70.78%
Back	2203	0.45%	1000	1.77%
Teardrop	979	0.20%	400	0.71%
Pod	264	0.05%	100	0.18%
Land	21	0.004%	10	0.02%
TOTAL	488735	100%	56510	100%

Gráfico 1 - Comparação da distribuição da amostragem dos tipos de ataques DoS (10%KDD/DoS x WANG).

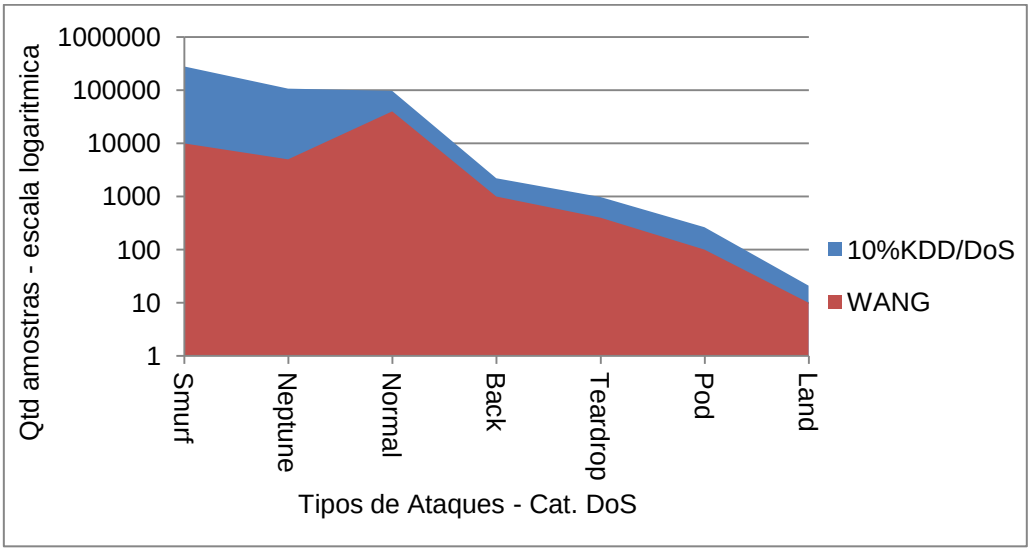

Fonte: Autor, 2014.

4.2.4 Seleção de atributos relevantes do conjunto de dados

Segundo LIU e MOTODA (1998), o processo de seleção de atributo é definido como a determinação de um subconjunto de atributos que será responsável por generalizar a informação contida na base de dados, isto de acordo com a resposta que se espera obter de tal base de dados.

A seleção de atributos juntamente com a reamostragem são tarefas da etapa da fase de preparação do processo de Descoberta de Conhecimento em Banco de

Dados. Já implícito no nome, o objetivo é escolher um subconjunto de atributos (na literatura também chamado de variáveis), ditos relevantes, a fim de reduzir a dimensão do banco de dados. Assim, reduz-se a complexidade do banco de dados, bem como o tempo de processamento para extrair dele algum conhecimento. Além disso, atributos irrelevantes (que não possuem informação útil para a tarefa), tais como aqueles que possuem valor constante para todos os registros, podem causar ruído no resultado final. É usual também encontrar, em grandes bases de dados, atributos redundantes, que são aqueles que possuem valores iguais ou proporcionais, e isto pode ser evitado com a aplicação de técnicas de Seleção de Atributos.

Segundo KAYACIK et al. (2005), um dos maiores desafios na detecção de intrusão baseada em rede é a extensa quantidade de dados coletados a partir da rede. Portanto, antes de alimentar com dados um algoritmo de aprendizado de máquina, o tráfego da rede original, sem tratamento, precisa ser reduzido em registros de conexão de alta relevância, de maneira que não haja comprometimento da qualidade do processo de mineração dos dados. Cada registro de conexão de alto nível possui uma característica composta por conjunto de atributos. A seleção desses atributos relevantes requer amplo conhecimento de domínio, que é fundamental para a eficácia dos algoritmos empregados, levando à simplificação do problema, ao aumento do desempenho e a maior acurácia nas taxas de detecção (OLUSOLA et al., 2010).

Pesquisadores aplicam vários procedimentos de análise dos dados a fim de selecionar o conjunto de atributos que maximizam a eficácia das técnicas de mineração de dados. Cada um desses atributos oferece um pedaço valioso de informação do sistema. A extração de atributos pode ser classificada em relação à sua contribuição e de acordo com a utilização. Ou seja, determinar a característica mais relevante dos atributos, a que melhor discrimina o comportamento da rede, de maneira a determinar a classe, de ataque ou normal.

Métodos de seleção de atributo podem ser dividido em filtros e abordagens *wrapper*. Para esta dissertação não serão objeto de estudo métodos para seleção de atributos em máquina de aprendizagem aplicados em sistema de detecção de intruso. Primeiramente serão apresentados trabalhos realizados na área de seleção de atributos em sistemas de detecção de intruso. Em seguida, selecionar-se-á um

trabalho de tal forma que à seleção de atributos proposta sejam aplicadas técnicas de regras de associação em valores quantitativos.

4.2.4.1 Trabalhos selecionados para seleção de atributos num IDS

A pesquisa de trabalhos realizados na área de seleção de atributos em Sistemas de Detecção de Intruso (IDS) foi baseada em relevância e trabalhos correlacionados com a proposta apresentada nesta dissertação, que é a extração de regras de associação em valores quantitativos, que no caso utiliza a base de dados de treinamento do KDD99 (10%KDD) como referência. Dentre os trabalhos selecionados, tem-se:

(OLUSOLA et. al., 2010) - *Analysis of KDD'99 Detection Dataset for Selection of Relevance Features*.

O conjunto grau dependência e índice de dependência de cada classe foram empregados para determinar os atributos mais relevantes para cada classe. Os resultados empíricos mostraram que sete características não foram relevantes na detecção de qualquer classe.

(KAYACIK et. al., 2005) - *Selecting Features for Intrusion Detection: A Feature Relevance Analysis on KDD 99 Intrusion Detection Datasets.*

O índice de ganho de informação (*information gain*) foi empregado para determinar os atributos relevantes para cada classe. Os resultados indicam que as classes de ataque normal, neptune e smurf são altamente relacionados com algum atributo que faz sua classificação se tornar fácil. Desde que essas três classes consomem até 98% dos dados de treinamento, é muito fácil para um algoritmo de máquina de aprendizagem atingir bons resultados.

(YOGENDRA et. al., 2011) - *Intrusion Detection using Supervised Learning with Feature Set Reduction*.

O índice de ganho de informação (*information gain*) foi empregado para determinar os atributos relevantes para cada classe. Dois algoritmos de aprendizagem (NB e BayesNet) foram usados para a tarefa de

detecção de intruso e comparados seus desempenhos relativos. Os resultados mostraram que 11 atributos foram selecionados com algum ganho de informação.

(WANG et. al., 2008) - *Towards fast detecting intrusions - using key attributes of network traffic*.

Os índices de ganho de informação (*information gain*), *wrapper* com *Bayesian Network* (BN) e árvore de decisão (C.45), respectivamente foram empregados para determinar os atributos relevantes para classe de ataque DoS. O resultado empírico baseado no conjunto de dados KDD99, bem como a classe de ataque DoS mostraram que, usando-se somente 10 atributos, a acurácia de detecção se mantém a mesma ou às vezes se torna melhor, comparada com o uso dos 41 atributos, em ambos os casos utilizando-se classificadores BN e C4.5.

(CHOU et. al., 2008) - *Network Intrusion Detection Design Using Feature Selection of Soft Computing Paradigms*.

Neste trabalho, dois algoritmos baseados para seleção de atributos, *Correlation Based Feature Selection* (CFS) e *Fast Correlation-Based Filter* (FCBF), e 2 dois algoritmos de aprendizagem de máquina, NB e C4.5, para avaliar a acurácia de detecção, são usados. Os resultados empíricos indicam que o algoritmo para seleção de atributos, para cada classe de ataque, é capaz de reduzir o tamanho do banco de dados.

O resultado dos trabalhos de WANG e CHOU são segmentados por categoria de ataque DoS, Probe, U2R e R2L. Já os trabalhos de KAYACIK, OLUSOLA e YOGENDRA abrangem todos os tipos de ataque, independentes de sua categoria. A consolidação dessa pesquisa de trabalhos relacionados à seleção de atributos relevantes pode ser visualizada na Tabela 27.

Tabela 27 - Seleção de atributos relevantes da base de dados KDD99.

#	Atributo	WEI				Chou				Kayacik	Olusola	Yogendra
		DoS	Probe	U2R	R2L	DoS	Probe	U2R	R2L			
1	Duration			x	x	x	x	x	x	x		
2	Protocol Type				x	x	x	x	x	x	x	
3	Service	x	x	x	x	x	x	x	x	x	x	x
4	Flag	x	x			x	x		x	x	x	x
5	SrcBytes	x	x	x	x	x			x	x	x	x
6	DstBytes	x	x	x		x				x	x	x
7	land									x	x	
8	wrong_fragment	x								x	x	
9	urgente											
10	hot	x			x			x	x	x		
11	FailedLogins										x	
12	loggd_in			x		x	x			x	x	x
13	num_compromised	x			x					x		
14	root_shell				x							
15	su_attempted									x		
16	NumRoot						x	x		x		
17	num_file_creations									x		
18	num_shells									x		
19	num_access_files									x		
20	num_outbound_cmds											
21	is_host_login											
22	is_guest_login			x					x			
23	Count	x		x		x				x	x	x
24	SrvCount	x				x				x		
25	serror_rate						x			x	x	
26	srv_serror_rate									x	x	
27	rerror_rate						x			x		
28	srv_rerror_rate						x			x		
29	same_srv_rate		x				x			x	x	
30	diff_srv_rate		x				x			x	x	
31	srv_diff_host_rate			x		x				x	x	
32	dst_host_count		x	x	x	x				x	x	x
33	dst_host_srv_count			x	x					x		
34	dst_hot_same_srv_rate									x	x	
35	dst_host_diff_srv_rate		x							x	x	x
36	dst_host_same_src_port_rate				x					x	x	
37	dst_host_srv_diff_host_rate	x				x				x	x	x
38	dst_host_serror_rate									x	x	x
39	dst_host_srv_serror_rate		x							x	x	x
40	dst_host_rerror_rate		x				x			x		
41	dst_hot_srv_rerror_rate									x		
	Atributos selecionados	**10**	**10**	**10**	**10**	**12**	**12**	**5**	**7**	**35**	**22**	**11**

Fonte: Autor, 2014.

4.2.4.2 Atributos relevantes selecionados para o trabalho

Conforme pôde ser observado anteriormente na Tabela 20, existe um grande desequilíbrio entre o quantitativo de amostras para cada tipo de ataque e suas respectivas categorias consequentemente. Observa-se no Gráfico 3 que mais de 98% das amostras estão distribuídas entre a classe normal e os ataques smurf e neptune, ambos da categoria de ataque DoS, e isso indica que essas classes são altamente relacionadas com algum atributo, tornando-se assim de fácil classificação para os algoritmos (KAYACIK et. al., 2005).

Gráfico 2 - Distribuição das amostras dos tipos de ataques do conjunto de dados de treinamento KDD99.

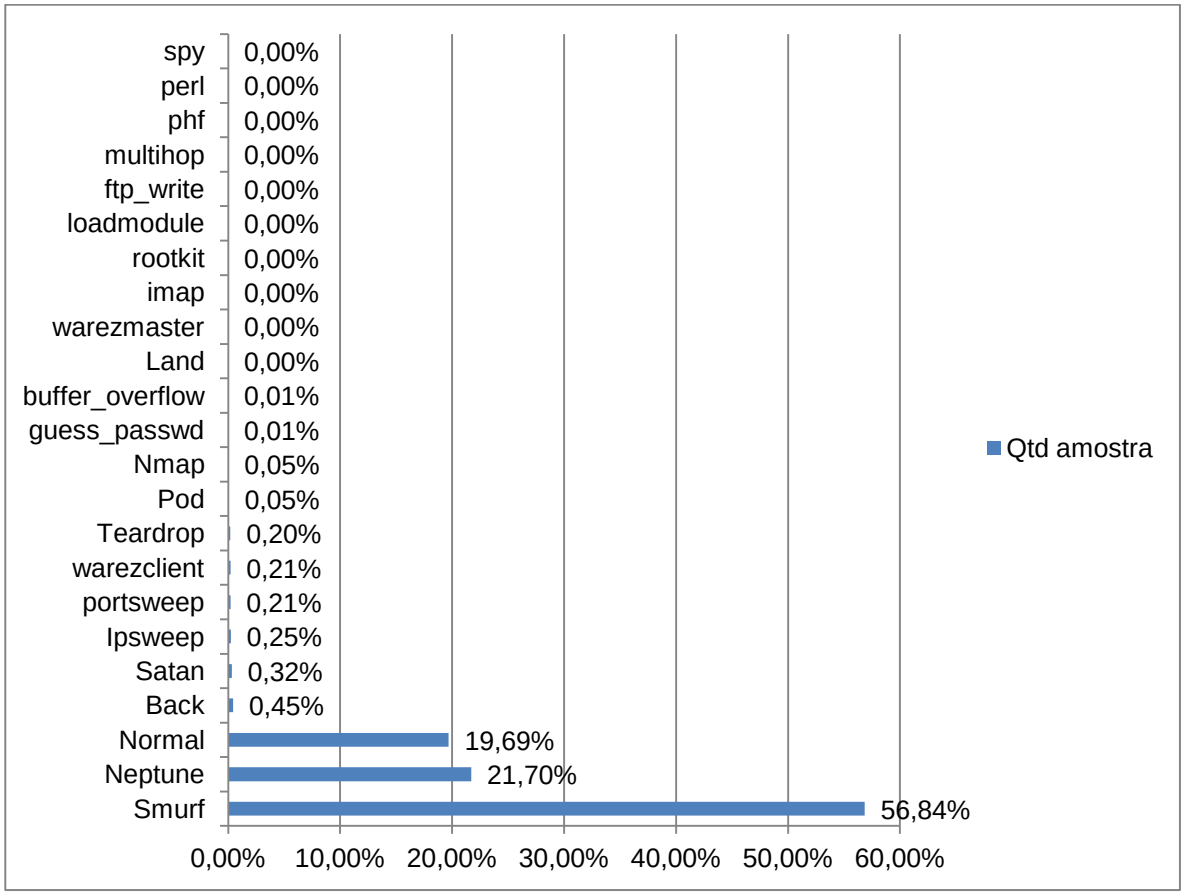

Fonte: O Autor, 2014.

Como o objetivo da dissertação está direcionada à análise de desempenho de algoritmos de extração de regras de associação de valores quantitativos e não à

análise de algoritmos para seleção de atributos, buscou-se o melhor modelo de conjunto de dados para aplicar os experimentos envolvendo os algoritmos Apriori e Fuzzy Apriori. Nesse sentido, optou-se por fazer a seleção de atributos relevantes relacionados aos ataques do tipo DoS, já que representam mais de 98% das classes na amostra de treinamento 10%KDD.

A seleção de atributos por tipo de categoria de ataque (DoS, Probe, U2R e R2L) ficou resumida aos trabalhos de WANG e CHOU, que apresentaram 7 atributos relevantes em comum: *Service, Flag, Src_Bytes, Dst_Bytes, Count, Srv_Count e dst_host_srv_diff_host_rate*. Quanto aos demais três atributos relevantes selecionados em cada um dos trabalhos, tiveram ao menos uma indicação em outro trabalho, conforme sinalizado com "x" em negrito na Tabela 28. O atributo W*rong_fragment* do trabalho de WANG teve também uma indicação no trabalho segundo OLUSOLA et. al. (2010) e KAYACIK, e *logged_ind* e d*st_host_count* do trabalho de CHOU tiveram também indicação no trabalho segundo YOGENDRA et. al. (2011) nos demais trabalhos.

Tabela 28 - Seleção de atributos relevantes em base de dados KDD99

#	Atributo	WANG	Chou	Kayacik	Olusola	Yogendra
		DoS	DoS			
1	Duration		**x**	x		
2	Protocol_type		**x**	x	x	
3	Service	x	x	x	x	x
4	Flag	x	x	x	x	x
5	SrcBytes	x	x	x	x	x
6	DstBytes	x	x	x	x	x
8	wrong_fragment	**x**		x	x	
10	hot	**x**		x		
12	loggd_in		**x**	x	x	x
13	num_compromised	**x**		x		
23	Count	x	x	x	x	x
24	SrvCount	x	x	x		
31	srv_diff_host_rate		**x**	x	x	
32	dst_host_count		**x**	x	x	x
37	dst_host_srv_diff_host_rate	x	x	x	x	x
	Atributos selecionados	**10**	**12**	**15**	**11**	**8**

Fonte: O Autor, 2014.

A avaliação da efetividade dos atributos selecionados (WANG e CHOU), em ambos os trabalhos, comparando-se com os resultados do uso de todos os 41 atributos, pode ser vista na Tabela 29. A taxa de detecção (*Detection Rate*), calculada como percentagem de intrusões detectadas, e a taxa de falso positivo (FPR), calculada como percentagem de conexões normais falsamente classificadas como intrusão, foram os critérios utilizados pelos autores para avaliação.

Tabela 29 - Avaliação da efetividade dos 10 atributos selecionados.

Método	Usando 41 atributos				WANG 10 atributos - CHOU 12 atributos			
	DR(%)		FPR(%)		DR(%)		FPR(%)	
	WANG	CHOU	WANG	CHOU	WANG	CHOU	WANG	CHOU
BN	98.73	99.12	0.08	0.01	**99.88**	99.16	**0**	0.01
C4.5	99.96	99.97	0.15	0.04	99.87	**99.97**	0.14	**0.03**

Fonte: O Autor, 2014.

Em geral, resultados de detecção são ideais quando as taxas de detecção são muito altas enquanto as taxas falso positivo são muito baixas (WANG et. al., 2008). Os resultados mostram que usando-se os atributos selecionados o método de classificação BN apresentou melhores resultados, tanto para DR quanto para FPR, no modelo segundo WANG. Já para o método de classificação C4.5, tanto para DR quanto para FPR, o modelo segundo CHOU apresentou melhores resultados.

Apesar dos resultados apresentados pelas taxas DR e FPR terem sidos favoráveis para ambos os trabalhos, WANG et. al., (2008) utilizaram o tradicional método de ranqueamento de ganho de informação (*gain information*), muito usado por diversos autores. E ainda, em WANG, os testes conduzidos foram separados por tipo de categoria de classe de ataque. Ou seja, 4 experimentos individualmente por tipo de ataque foram realizados. Para finalizar, WANG sugere em seu trabalho uma reamostragem da distribuição dos tipos de ataque por categoria, que será a mesma base de dados utilizada nesta dissertação.

Baseando-se em todas as informações coletadas para definição de quais atributos relevantes serão selecionados, optou-se pelo conjunto de atributos sugerido segundo WANG et al. (2008). A distribuição dos valores dos atributos selecionados no conjunto de dados 10%KDD é apresentado na Tabela 30.

Tabela 30 – Distribuição dos valores dos atributos em 10%KDD.

#	ATRIBUTO	VARIAÇÃO	QTDS
3	Service	nominal	66
4	Flag	nominal	11
5	SrcBytes	0 - 693375640	3300
6	DstBytes	0 - 5155468	10725
8	wrong_fragment	0 - 3	3
10	hot	0 -30	22
13	num_compromised	0 - 884	23
23	Count	0 - 511	490
24	SrvCount	0 - 511	470
37	dst_host_srv_diff_host_rate	0 - 1	65

4.2.5 Conjunto de dados KDD99/DoS pré-processados

A distribuição final do conjunto de dados 10%KDD/DoS, após as tarefas de reamostragem e seleção de atributos relevantes, é apresentada na Tabela 31.

Tabela 31 – Distribuição dos valores dos atributos em 10%KDD/DoS.

#	ATRIBUTO	CATEGORIA	VARIAÇÃO	QTDS
3	Service	nominal	-	16
4	Flag	nominal	-	9
5	SrcBytes	quantitativo	0 - 2194619	2386
6	DstBytes	quantitativo	0 - 2432884	7120
8	wrong_fragment	quantitativo	0 - 3	3
10	hot	quantitativo	0 -30	17
13	num_compromised	quantitativo	0 - 884	10
23	Count	quantitativo	0 - 511	397
24	SrvCount	quantitativo	0 - 511	346
37	dst_host_srv_diff_host_rate	quantitativo	0 - 1	58

Consolidando as informações referentes ao conjunto de dados KDD99/DoS que será utilizado no desenvolvimento dos experimentos, temos:

- Base de Dados de treinamento 10% KDD

  # registros de conexões: 494.021 registros

  # atributos: 41

  # classes: categorias de ataques (4) + normal / tipos de ataques (22)

- Pós Pré-processamento - Base de Dados de treinamento 10% KDD/DoS

  # registros de conexões: 56.510 registros

  # atributos: 10

  # classes: os 6 tipos de ataque da categoria DoS foram consolidados em um único tipo de ataque nomeado de "ataque". Total de classes: 2 (ataque e normal)

  # *resample* realizado individualmente em cada tipo de ataque (WEKA).

  # o atributo SERVICE foi analisado no sentido de agrupar os valores que apontavam para a mesma classe de ataque. Dos 66 tipos de SERVICE, 42 foram agrupados como *service_neptune* e 8 como *service_normal.*

Concluídas as tarefas de reamostragem e seleção de atributos relevantes, é possível representar uma comparação entre o conjunto de dados original 10%KDD e o que será utilizado nos experimentos (10%KDD/DoS) (Figura 28).

Figura 28 - Matriz conjunto de dados 10%KDD x 10%KDD/DoS.

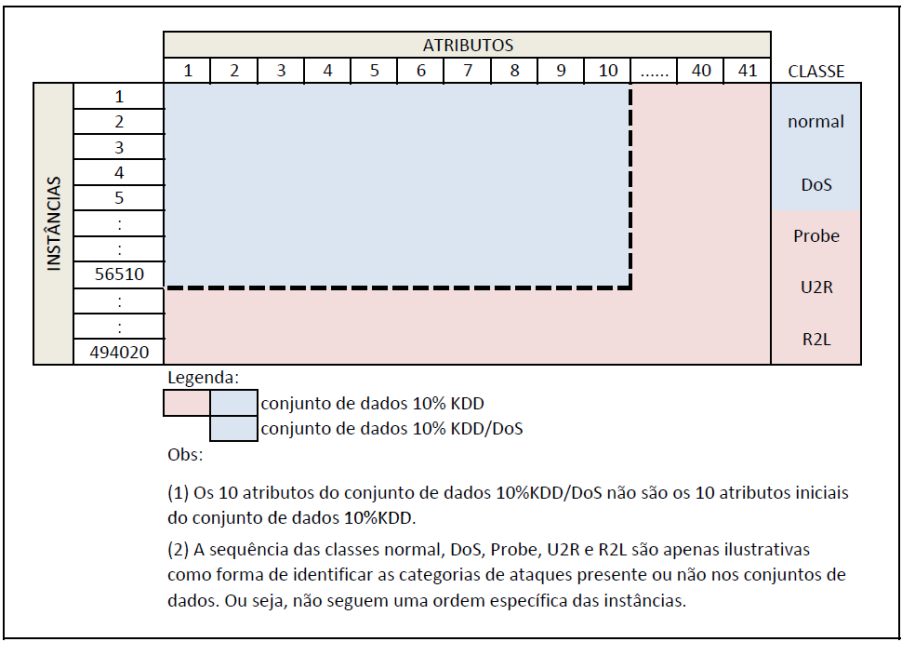

Fonte: O Autor, 2014.

4.3 Metodologia

O capítulo a seguir tem o objetivo de detalhar todas as etapas realizadas em nossa proposta de trabalho. As etapas aqui consideradas seguirão os tópicos: pré-processamento (reamostragem e seleção de atributos), transformação dos dados (discretização e conjuntos fuzzy), mineração de dados (extração de regras de associação), interpretação e avaliação (classificação) e resultados.

Todos os experimentos foram desenvolvidos utilizando-se as ferramentas de mineração de dados baseadas no software *open source, sendo elas Weka e Keel,* já abordados na seção 3.1. O parâmetro de configuração de memória no Weka *foi maxheap=2048M.*

Na Tabela 32 detalha-se as etapas do processo de descoberta de conhecimento - KDD (pré-processamento e mineração de dados) e as respectivas tarefas e técnicas aplicadas que serão abordadas neste capítulo.

Tabela 32 - Ferramentas e tarefas utilizadas no desenvolvimento.

Ferramenta	Etapa	#	Tarefa	Técnica
WEKA (3.7.10) 	Pré-processamento	4.3.1.1	Reamostragem do conjunto de dados 10%KDD/DoS	Filter/Unsupervised/Instance/Resample
		4.3.1.2	Seleção de Atributos	Não se aplica. Tarefa segundo WANG
	Transformação dos Dados	4.3.2.1	Discretização dos atributos com valores quantitativos	Filter/Supervised/Attribute/Discretize
	Mineração dos Dados	4.3.2.2	Extração de Regras de Associação	Algoritmo Apriori
	Interpretação e Avaliação	4.3.2.3	Classificadores de regras	Classifiers/Rules/CAR/JCBA
KEEL (2.0) (2013-04-01) 	Transformação dos Dados	4.3.3.1	Particionamento *Fuzzy* dos atributos quantitativos	Algoritmo *Fuzzy* Apriori
	Mineração de Dados		Extração de Regras de Associação	Algoritmo *Fuzzy* Apriori
	Interpretação e Avaliação	4.3.3.2	Classificadores de regras de associação	Algoritmo CFAR

4.3.1 Pré-processamento

Esta seção aborda dois tópicos da etapa de pré-processamento do processo KDD antes dos experimentos com o algoritmo Apriori, sendo eles: reamostragem e seleção de atributos relevantes.

4.3.1.1 Reamostragem

Na proposta de reamostragem do conjunto de dados de treinamento 10%KDD_DoS segundo WANG et al. (2008), um percentual de redutor servirá de parâmetro para aplicação no filtro não supervisionado de instância no WEKA. A Tabela 33 mostra, para cada um dos tipos de ataque, a quantidade de amostras do conjunto de dados 10%KDD/DoS, a quantidade de amostras segundo a proposta de reamostramento de WANG et al. (2008) e o respectivo percentual do redutor (% redutor).

Tabela 33 - Arquivos gerados para serem filtrados.

Ataque	Qtd amostras 10%KDD/DoS	Qtd iamostras WANG	% redutor
smurf	280790	10000	3.562
neptune	107201	5000	4.665
normal	97277	40000	41.12
back	2203	1000	45.393
teardrop	979	400	40.86
pod	264	100	37.88
land	21	10	47.62
TOTAL	488735	56510	

O filtro de reamostragem selecionado foi Choose / filters / unsupervised / instance / resample. Antes de aplicar o filtro, é necessário ajustar parâmetros, sendo eles: noReplacement (*False)*, ou seja, com substituição, e em *sampleSizePercent. E*sse valor é alterado de 100.0 para o *% redutor* respectivo de cada tipo de ataque visto anteriormente na Tabela 33. Os demais parâmetros permanecem inalterados.

Com objetivo de melhorar o desempenho dos algoritmos, reduzindo o número de valores nominais das variáveis categóricas que não acrescentam informação para descoberta de conhecimento, essas variáveis tiveram seu conteúdo modificado. Nesse sentido, verificou-se que o atributo *service*, composto por 65 valores nominais diferentes, possui 42 valores com um único tipo de classe *atack_type* - *neptune*, e 8 variáveis com o único tipo de classe *atack_type* - *normal*. Então, os 42 valores nominais foram renomeados para *service_neptune,* e os 8 valores nominais para *service_normal*.

4.3.1.2 Seleção de atributos

Os 10 atributos relevantes selecionados para o trabalho, com a respectiva característica de cada atributo, são representados na Tabela 34. A *Categoria* indica a característica de cada atributo (nominal ou quantitativo), em que os atributos quantitativos serão particionados em segmentos discretizados ou em conjuntos *fuzzy*. *Variação* indica a faixa de valores de cada atributo e *QTDS* é a quantidade de valores diferentes. Por exemplo, o atributo FLAG possuiu 9 tipos de valores, sendo eles: *private, ecr_i, tim_i, finger, telnet, http, domain, service_neptune, time, pop_3, other, auth, ftp, ftp_data, smtp.*

Tabela 34 - Atributos relevantes selecionados em 10%KDD_DoS.

#	ATRIBUTO	CATEGORIA	VARIAÇÃO	QTDS
3	Service	nominal	-	16
4	Flag	nominal	-	9
5	SrcBytes	quantitativo	0 - 2194619	2386
6	DstBytes	quantitativo	0 - 2432884	7120
8	wrong_fragment	quantitativo	0 - 3	3
10	hot	quantitativo	0 -30	17
13	num_compromised	quantitativo	0 - 884	10
23	Count	quantitativo	0 - 511	397
24	SrvCount	quantitativo	0 - 511	346
37	dst_host_srv_diff_host_rate	quantitativo	0 - 1	58

4.3.2 Aplicação do Algoritmo APRIORI

As três etapas do processo KDD, transformação dos dados, mineração dos dados e interpretação e avaliação durante o desenvolvimento do algoritmo Apriori, serão abordadas à seguir.

4.3.2.1 Transformação dos dados - Discretização

Antes de iniciar a tarefa de extração das regras de associação do conjunto de dados 10$KDD/DoS, é necessário particionar os atributos quantitativos em intervalos e definir quantas partições cada uma deve ter. O problema potencial em combinar intervalos para atributos quantitativos é o número de regras encontradas, que pode ser muito grande (AGRAWAL, et. al., 2006).

O software WEKA possui dois filtros de discretização, sendo um supervisionado e outro não supervisionado. Basicamente o modo não supervisionado possibilita definir o número de partições dos atributos quantitativos e também possui o parâmetro *useEqualFrequency,* que define que as partições sejam de mesma frequência. O modo supervisionado não define um valor fixo de partições, mas tem a opção de usar uma codificação mais eficiente, ou não, do ponto de divisão das partições (*useBetterEncoding*).

Antes de definir qual o método de filtragem para discretização (supervisionado ou não supervisionado), um teste de comparação de quantitativo de regras de associação extraídas foi realizado. Utilizou-se como valor mínimo do parâmetro confiança 40% e a faixa de 10% a 80% para o parâmetro suporte. Os parâmetros de configuração considerados foram: i) supervisionado: *useBetterEncoding* (True), ii) supervisionado: *useBetterEncoding* (False) e iii) não supervisionado: *bins* (5) e *useEqualFrequency* (True). Os resultados encontrados mostram que o modo não supervisionado apresentou quantitativo de regras de associação menor que ambos os modos supervisionados (Figura 29), e será adotado nos experimentos deste capítulo.

Figura 29 - Comparação dos métodos de discretização supervisionado e não supervisionado.

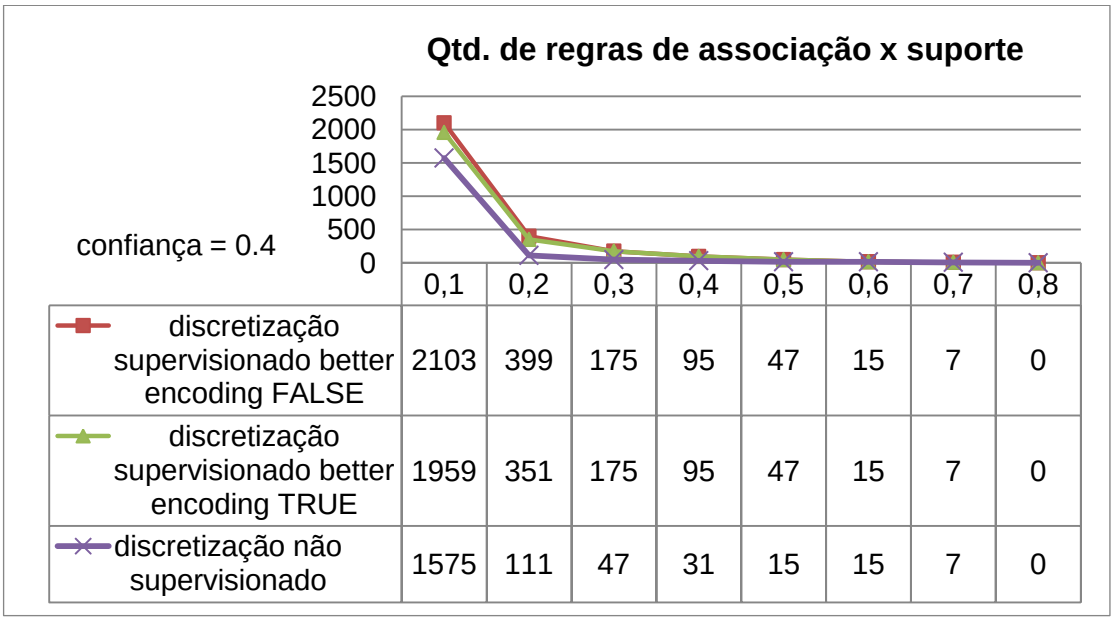

O filtro selecionado para discretização foi *Choose* / *filters* / *unsupervised* / *attribute* / *discretize*. Antes de aplicar o filtro é necessário ajustar os parâmetros, sendo eles: *bins* (5) e *useEqualFrequency* (True). Os atributos quantitativos foram discretizados em 5 partições de iguais frequências, para posterior aplicação do algoritmo Apriori.

4.3.2.2 Mineração dos Dados - Extração de regras de associação

Esta seção abordará a extração de regras de associação do conjunto de dados 10%KDD_DoS, utilizando o algoritmo Apriori. Usando-se o arquivo 10%KDD/DoS (discretizado), é selecionado no WEKA o algoritmo Apriori no caminho: *Associate*/*Associator* (Choose) */associations/Apriori.* Os parâmetros utilizados na configuração são: *car* (TRUE) (a classe de regras de associação é habilitada, em vez de generalizar todas as regras de associação), *classindex* (11) (é o index da classe *attack_type*), *lowerBoundMinSupport* (valor mínimo de suporte); *metricType* (*confidence* - confiança) e *minMetric* (valor mínimo de confiança) são previamente definidos.

Para os experimentos, será feita uma variação dos parâmetros de suporte e confiança para avaliar o quantitativo de regas de associação geradas em função desses 2 parâmetros. O valor de suporte variou de 5% a 70% (7 valores), e o valor de confiança, 40%, 60%, 80% e 90% (4 valores).

4.3.2.3 Interpretação e Avaliação - Classificador de regras

Esta seção abordará a classificação das regras de associação geradas no tópico anterior. O algoritmo aplicado para classificação foi o classificador JCBA (implementação JAVA do algoritmo CBA), que trabalha com regras de associação de classe.

Na tela de configuração do classificador JCBA, o parâmetro *carminer* permite a seleção do algoritmo para a extração das regras de associação, que em nosso trabalho será o *Apriori*. Isso significa que o classificador JCBA possui na verdade 2 tarefas embutidas, sendo a primeira a geração dos itens frequentes e a extração das regras de associação (clássico Apriori), e a segunda, a classificação das regras de associação propriamente ditas.

No WEKA, o classificador CBA é selecionado no caminho: *Classify*/*Classifiers* (Choose) */rules/car/JCBA.* O parâmetro *carminer* (Choose)/*Apriori* é previamente definido, e para os experimento será feita uma variação dos parâmetros de suporte e confiança para classificar as regas de associação geradas em função desses 2 parâmetros. O valor de suporte variou de 5% até 70% (7 valores), e o valor de confiança, 40%, 60¨%, 80% e 90%.

No parâmetro de teste em *Test Option,* a opção *Use Training Set* foi selecionada. As demais opções implicaram em demora muito significativa, com uma diferença sem relevância no resulto da acurácia da regra classificada. Por exemplo, selecionando *Cross Validation* (10), em suporte 20% e confiança 50%, o tempo de espera foi maior quase 800% (15 s contra 119 s), e o percentual de precisão, uma diferença de 0.02% (98.53% contra 98.55%).

4.3.3 Aplicação do Algoritmo *FUZZY* APRIORI

Nesta sessão será abordada a aplicação do algoritmo *Fuzzy* Apriori para extração de regras de associação *fuzzy* e interpretação e avaliação do conjunto de dados KDD99. A etapa de transformação dos dados (discretização), que foi realizada anteriormente durante o desenvolvimento do algoritmo Apriori, agora, no algoritmo *Fuzzy* Apriori, é feita na mesma etapa de mineração dos dados. Ou seja, antes da mineração das regras de associação, inicialmente é realizado o particionamento dos atributos de entrada em conjuntos *fuzzy*.

4.3.3.1 Mineração dos Dados - Extração de regras de associação

O algoritmo *FUZZY APRIORI-A* (HONG et al., 2001), disponível no software KEEL, será utilizado para a tarefa de extração de regras de associação *fuzzy*.

O software KEEL não tem a mesma usabilidade[15] que o software WEKA, pois necessita de interações consecutivas do usuário até que se tenha o resultado esperado. Como as regras de associação geradas no KEEL incluem consequentes diferentes da Classe *Ataque, o*s arquivos de resultados *.tra* e *.tst* tiveram que ser convertidos para *.xml, e* posteriormente tratados no Excel para que fossem obtidos apenas os consequentes de Classe *Ataque*.

No modo *Experiments* do KEEL, o tipo de experimento Unsupervised Learning é o método a ser selecionado, e o tipo de partição foi *without validation*. No algoritmo selecionado na árvore de diretório *Algorithms/Association_Rules,* a opção *Fuzzy*Apriori-A é aplicado ao conjunto de dados do experimento. O mesmo número de partições nos experimentos do algoritmo Apriori foi escolhido para o *Fuzzy* Apriori, ou seja, cinco partições. Para os experimentos, foi feita uma variação dos parâmetros de suporte e confiança, sendo: valor de suporte variou de 5% a 70% (7 valores), e o valor de confiança, 40%, 60%, 80% e 90%.

---

[15] Termo usado para definir a facilidade com que as pessoas podem empregar uma ferramenta ou objeto a fim de realizar uma tarefa específica e importante.

4.3.3.2 Interpretação e Avaliação - Classificador de regras

O algoritmo aplicado para classificação foi o classificador CFA-R, que trabalha com regras de associação de classe (CHEN, 1998). A exemplo do classificador (LIU, et. al., 1998 e LI, et al., 2001), visto anteriormente, são regras de associação que possuem exclusivamente uma classe de atributo, que é o único atributo consequente na relação *Se / Então*.

No modo *Experiments* da ferramenta, o tipo de experimento selecionado é *Classification,* e o tipo de partição, *without validation,* e o algoritmo de classificação CFAR-C é selecionado dentre as opções de *Associative Classification*. Os parâmetros de configuração do classificador são: o número de partições (5) e os parâmetros de suporte e confiança, sendo: o valor de suporte variou de 5% a 70% (7 valores), e o valor de confiança, 40%, 60%, 80% e 90%. Ou seja, foram os mesmos parâmetros utilizados no algoritmo Apriori. A proposta de manter os mesmos parâmetros de quantidade de partições (discretas ou *fuzzy*) e de suporte e confiança tem como objetivo igualar as condições previamente determinadas dos experimentos. Assim, os resultados alcançados poderão ser analisados de forma mais homogênea.

5 RESULTADOS E ANÁLISE DOS EXPERIMETOS

Neste capítulo são apresentados os resultados obtidos e a avaliação dos experimentos de acordo com a metodologia proposta no capítulo anterior. Apresentamos os resultados pertinentes ao desempenho de cada algoritmo nos experimentos realizados, o que permitem uma comparação dos resultados, de forma a apontar qual a melhor indicação para o uso de cada um dos algoritmos no ambiente proposto.

5.1 Introdução

Cada um dos algoritmos aplicados durante a realização dos experimentos teve como objetivo extrair regras de associação de uma base de dados contendo registros de conexões TCP/IP. Essa base de dados foi utilizada numa competição internacional de descoberta de conhecimento e ferramentas de mineração de dados e serviu como benchmarking para a construção de um Sistema de Detecção de Intrusos. A proposta foi criar modelo preditivo capaz de distinguir entre conexões “ruins” como invasões ou ataques, e “boas” como conexões normais.

Uma vez gerados os resultados relativos à extração das regras de associação, procedeu-se a uma análise de desempenho das regras geradas através de algoritmos de classificação.

5.2 Aplicação do Algoritmo Apriori

Conforme visto no capítulo dos Experimentos, fez-se uma variação dos parâmetros de suporte mínimo e de confiança mínimo para avaliar o quantitativo de regas de associação geradas e para cálculo da acurácia em função desses 2 parâmetros. O valor de suporte variou de 5% a 70% (8 valores), e o valor de confiança, 40%, 60%, 80% e 90% (4 valores).

5.2.1 Quantidade de regras de associação extraídas

Os resultados da distribuição do número de regras de associação extraídas, variando os valores de suporte e de confiança mínimos são mostrados na Figura 30.

Figura 30 - Relação entre o número de regras de associação e valor mínimo de suporte para valores de confiança mínimos.

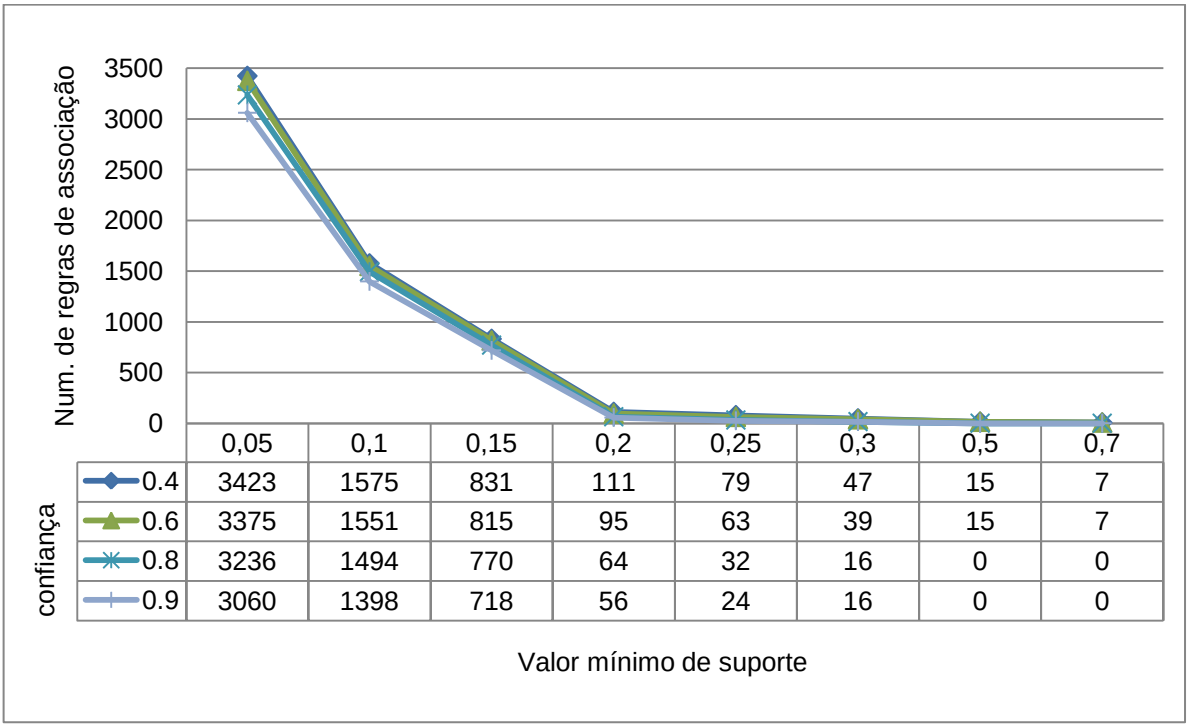

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
0.4	3423	1575	831	111	79	47	15	7
0.6	3375	1551	815	95	63	39	15	7
0.8	3236	1494	770	64	32	16	0	0
0.9	3060	1398	718	56	24	16	0	0

Pela Figura 30. pode ser visto que o número de regras de associação decresce conforme o valor de suporte mínimo aumenta. Esta observação é consistente, pois, devido à redução do número de *large itemsets,* o quantitativo de regras diminui. Além disso, observa-se também que a curva do número de regras de associação com valores mínimos de confiança maiores foi praticamente imperceptível em relação àqueles com valores mínimos de confiança menores, o que significa que o valor mínimo de suporte não teve um grande efeito sobre o número de regras de associações derivada de valores menores ou maiores de confiança mínimo.

5.2.2 Conjunto de regras de classificação

Experimentos foram feitos para descobrir um pequeno conjunto de regras de associação, denominadas de regras de classificação, para formar um classificador associativo (CBA). O percentual de acurácia de acerto deste classificador é mostrado na Figura 31.

Figura 31 - Relação entre número de regras de classificação e valor mínimo de suporte para valores de confiança mínimos.

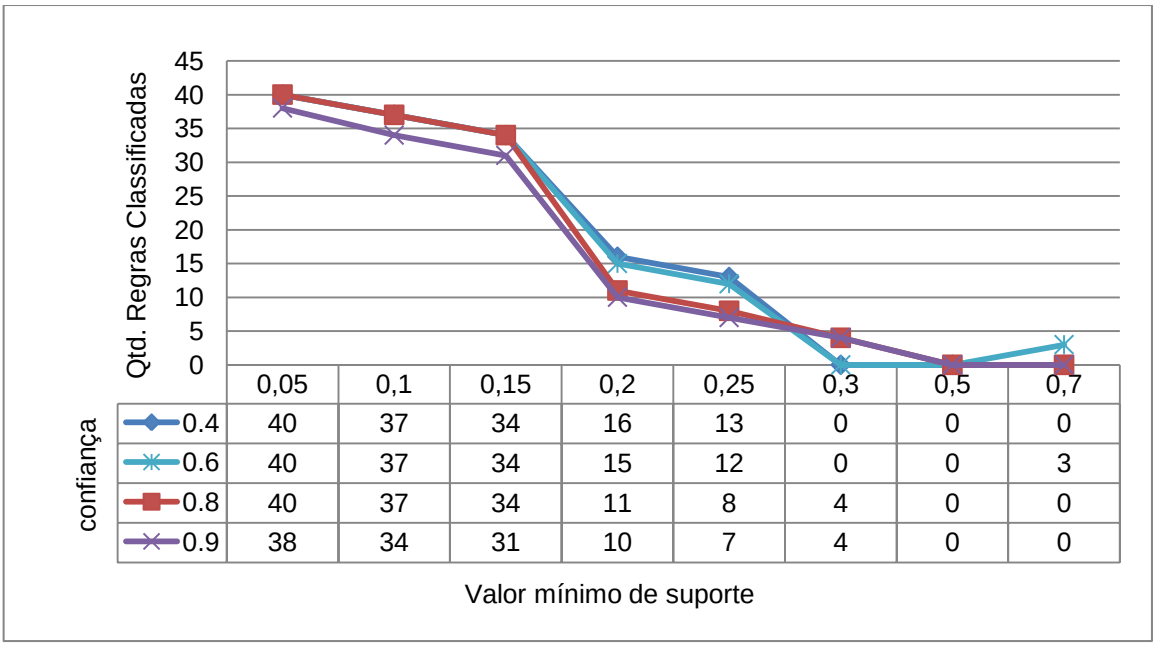

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
0.4	40	37	34	16	13	0	0	0
0.6	40	37	34	15	12	0	0	3
0.8	40	37	34	11	8	4	0	0
0.9	38	34	31	10	7	4	0	0

Pela Figura 31. pode-se ver que o número de regras de classificação decresce conforme o valor de suporte mínimo aumenta. Essa observação também é consistente, pois as regras de classificação são pequenos conjuntos de regras gerados a partir do conjunto de regras de associação extraídas anteriormente.

Observa-se também que a curva do número de regras de associação para valores de suporte mínimo entre 5% e 15% não teve nenhum efeito sobre o número de regras de associação derivadas de valores menores ou maiores de confiança mínimos entre 40% e 80%. Apresenta apenas uma redução do número de regras de associação para o valor de confiança mínimo de 90%.

Já os valores de suporte mínimo de 20% e 25% é que tiveram efeito sobre o número de regras de associação derivadas de valores mínimos de confiança.

A partir do valor de suporte mínimo de 30% não foram mais geradas regras de classificação, com exceção do valor de suporte mínimo de 30% e do valor de confiança mínimo de 80% e 90%, que registrou a ocorrência de 4 regras de classificação.

5.2.3 Acurácia das regras de associação

Experimentos foram feitos para medir a acurácia das regras de associação extraídas, tendo como parâmetro o conjunto de regras de classificação geradas no tópico anterior. Os resultados, seguindo a mesma variação dos valores mínimos de suporte e confiança, são mostrados na Figura 32.

Figura 32 - Relação entre o percentual de acurácia alcançado e valor mínimo de suporte para valores de confiança mínimos.

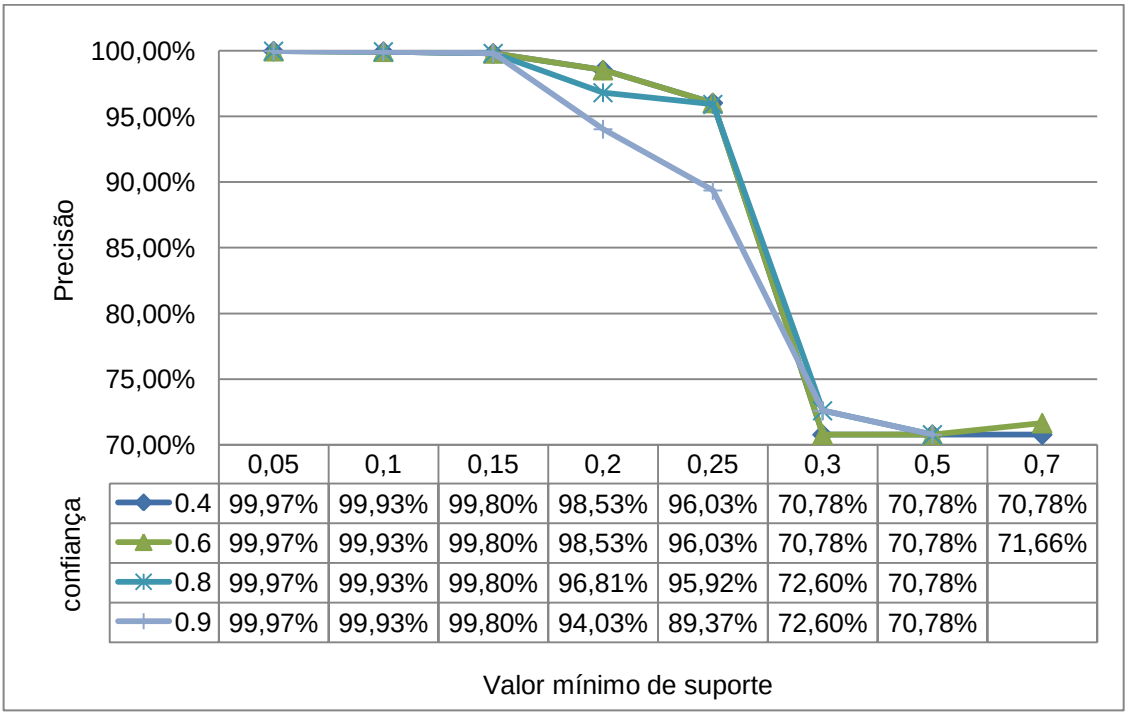

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
0.4	99,97%	99,93%	99,80%	98,53%	96,03%	70,78%	70,78%	70,78%
0.6	99,97%	99,93%	99,80%	98,53%	96,03%	70,78%	70,78%	71,66%
0.8	99,97%	99,93%	99,80%	96,81%	95,92%	72,60%	70,78%	
0.9	99,97%	99,93%	99,80%	94,03%	89,37%	72,60%	70,78%	

Observa-se que os valores menores de suporte mínimo (5% a 15%) mantêm a acurácia em valores altos, próximos de 100%, permanecendo inalterada,

independente dos valores mínimos de confiança. Ou seja, o valor mínimo de confiança não teve impacto na acurácia das regras extraídas num determinado valor de suporte mínimo (5% a 15%). Esse resultado era esperado, pois a quantidade de regras de associação geradas também se manteve inalterada, com exceção do valor mínimo de confiança de 90%, mas que não teve impacto no resultado da precisão.

Os valores de suporte mínimo entre 20% e 25% é que apresentaram variação de acurácia significante e decrescente, conforme a variação do valor de confiança mínimo.

Os valores de suporte mínimo, a partir de 30%, apresentam percentual de acurácia de 70.78%. Através da matriz confusão, percebe-se que dos 56510 registros de conexões TCP/IP de possíveis ataques, apenas os ataques da categoria *Normal* são reconhecidos como *Normal* na sua totalidade (40.000 registros). Os ataques da categoria *Ataque* (16510 registros) não são reconhecidos como *Ataque* (Figura 33). Com exceção apenas dos valores de confiança mínimo de 80% e 90%, aqueles foram os que ainda apresentaram algum percentual de acerto (6.5% - *ataque* e 56.7% - *normal*) (Figura 34).

Figura 33 - Matriz confusão: suporte 30% e confiança 60%.

```
   a     b   <-- classified as
   0 16510 |     a = ATAQUE
   0 40000 |     b = NORMAL
```

Figura 34 - Matriz confusão: suporte 30% e confiança 90%.

```
   a     b   <-- classified as
15500  1010 |     a = ATAQUE
14476 25524 |     b = NORMAL
```

5.3 Aplicação do Algoritmo Fuzzy Apriori

Conforme visto no capítulo dos Experimentos, fez-se uma variação dos parâmetros de suporte e confiança, para se avaliar o quantitativo de regas de

associação geradas e para se calcular a acurácia em função desses 2 parâmetros. O valor de suporte variou de 5% a 70% (8 valores), e o valor de confiança, 40%, 60%, 80% e 90% (4 valores).

5.3.1 Quantidade de regras de associação extraídas

Os resultados da distribuição do número de regras de associação extraídas, variando os valores de suporte mínimo e de confiança mínimos, são mostrados na Figura 35.

Figura 35 - Relação entre número de regras de associação e valor mínimo de suporte para vários valores de confiança mínimos.

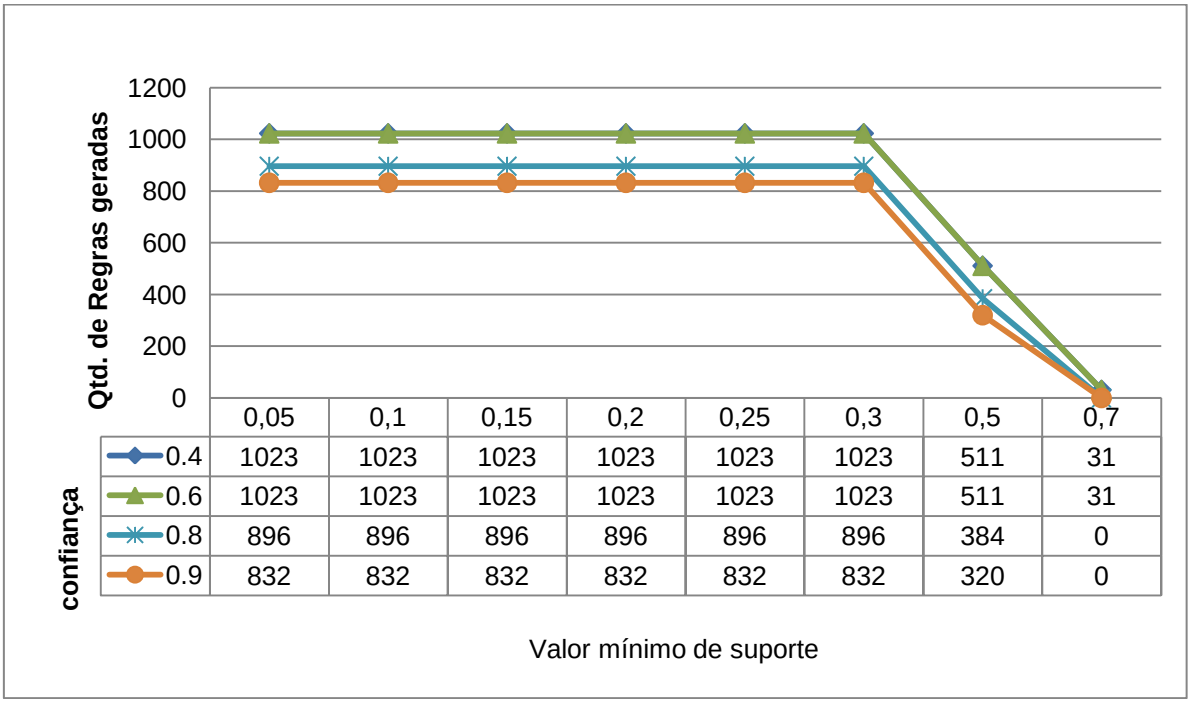

Pela Figura 35 pode ser visto que o número de regras de associação decresce suavemente conforme o valor de confiança mínimo aumenta. No entanto, a variação do valor de suporte mínimo entre 5% e 30%, em um determinado valor de confiança mínimo, não teve impacto no quantitativo de regras de associação extraídas. Valores de suporte mínimo superior a 30% indicam redução do número de regras de associação extraídas.

5.3.2 Conjunto de regras de classificação

Experimentos foram feitos para se descobrir um pequeno conjunto de regras de associação, denominadas de regras de classificação, a fim de se formar um classificador associativo (CFAR). O percentual de acurácia de acerto desse classificador é mostrado na Figura 36.

Figura 36 - Relação entre número de regras de classificação e valor mínimo de suporte para valores de confiança mínimos.

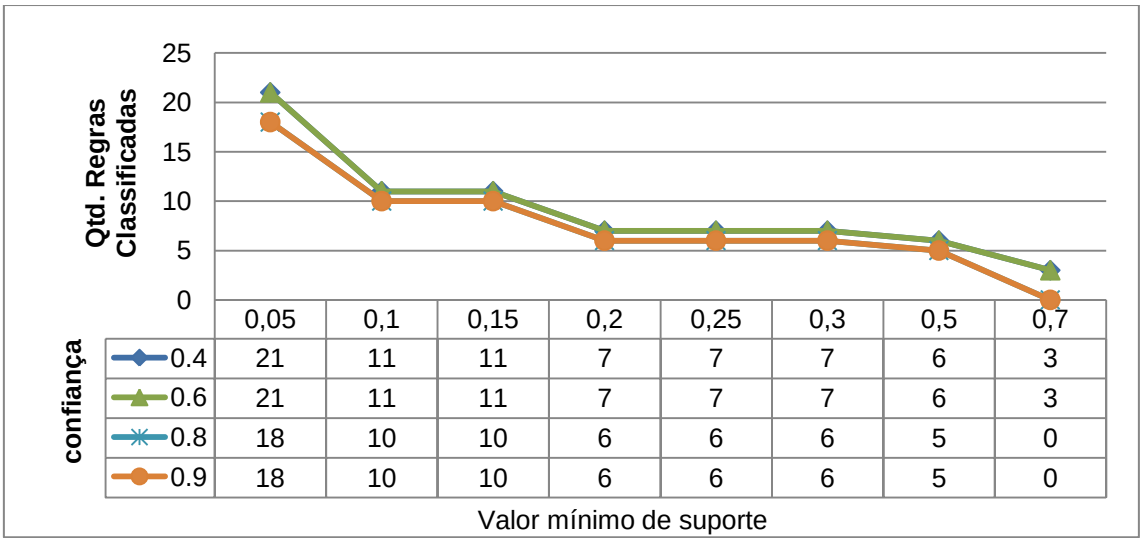

Observa-se que o número de regras de classificação decresce muito suavemente conforme o valor de suporte mínimo aumenta.

Observa-se também que a curva do número de regras de classificação para valores de confiança mínimo de 40% e 60% permaneceu inalterada, porém, diferenciada dos valores de confiança mínimo de 80% e 90%, que também permaneceram inalterados.

5.3.3 Acurácia das regras de associação

Experimentos foram feitos para medir a acurácia das regras de associação extraídas, tendo como parâmetro o conjunto de regras de classificação geradas no

tópico anterior. Os resultados, seguindo a mesma variação dos valores mínimos de suporte e confiança, são mostrados na Figura 37.

Figura 37 - Relação entre percentual de acurácia alcançado e valor mínimo de suporte para valores de confiança mínimos.

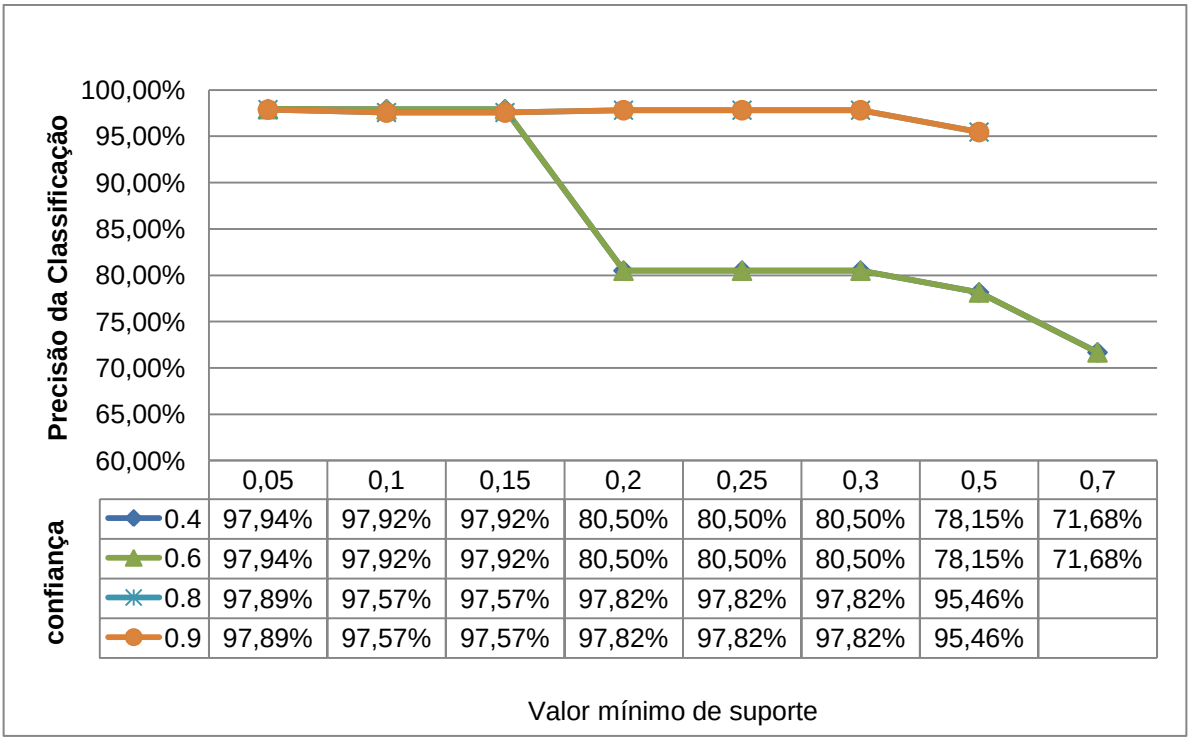

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
0.4	97,94%	97,92%	97,92%	80,50%	80,50%	80,50%	78,15%	71,68%
0.6	97,94%	97,92%	97,92%	80,50%	80,50%	80,50%	78,15%	71,68%
0.8	97,89%	97,57%	97,57%	97,82%	97,82%	97,82%	95,46%	
0.9	97,89%	97,57%	97,57%	97,82%	97,82%	97,82%	95,46%	

Observa-se que os valores menores de suporte mínimo (5% a 15%) mantêm a acurácia em valores altos, próximos de 100%. Para valores de suporte mínimo a partir de 20%, o percentual de acurácia para valores mínimos de confiança de 40% e 60% começam a reduzir. Para valores de confiança mínimo de 80% e 90% o percentual de acurácia se mantém em valores altos, tendo uma pequena redução a partir do valor mínimo de suporte de 50%.

5.4 Algoritmo Apriori x Fuzzy Apriori

Para análise de desempenho dos Algoritmos Apriori e Fuzzy Apriori, foram selecionados valores mínimos de suporte e confiança que apresentassem melhores resultados para essa análise. Na análise comparativa de quantidade de regras de

associação e de regras de classificação foram utilizados, por exemplo, os valores de confiança mínimos de 40% e 90% (Tabelas 35 e 36). As curvas dos demais valores de confiança apresentaram distribuição semelhante.

Tabela 35 - Dados comparativos dos Algoritmos Apriori e Fuzzy Apriori para valor de confiança mínimo de 40%.

		APRIORI			FUZZY APRIORI		
Sup. Min.	Conf. Min.	Qtd. de Regras de Associação extraídas	% acerto	Qtd. de Regras de Classificação	Qtd. de Regras de Associação extraídas	% acerto	Qtd. de Regras de Classificação
0.05	0.4	3423	99.97%	40	1023	97.94%	21
0.1	0.4	1575	99.93%	37	1023	97.92%	11
0.15	0.4	831	99.80%	34	1023	97.92%	11
0.2	0.4	111	98.53%	16	1023	80.50%	7
0.25	0.4	79	96.03%	13	1023	80.50%	7
0.3	0.4	47	70.78%	0	1023	80.50%	7
0.5	0.4	15	70.78%	0	511	78.15%	6
0.7	0.4	7	70.78%	0	31	71.68%	3

Tabela 36 - Dados comparativos dos Algoritmos Apriori e Fuzzy Apriori para valor de confiança mínimo de 90%.

		APRIORI			FUZZY APRIORI		
Sup. Min.	Conf. Min.	Qtd. de Regras de Associação extraídas	% acerto	Qtd. de Regras de Classificação	Qtd. de Regras de Associação extraídas	% acerto	Qtd. de Regras de Classificação
0.05	0.9	3060	99.97%	38	832	97.89%	18
0.1	0.9	1398	99.93%	34	832	97.57%	10
0.15	0.9	718	99.80%	31	832	97.57%	10
0.2	0.9	56	94.03%	10	832	97.82%	6
0.25	0.9	24	89.37%	7	832	97.82%	6
0.3	0.9	16	72.60%	4	832	97.82%	6
0.5	0.9	0	70.78%	0	320	95.46%	5
0.7	0.9	0		0	0		0

5.4.1 Análise comparativa de quantidade de regras de associação

O valor de confiança mínimo de 40% serviu de parâmetro para representar a distribuição da quantidade de regras de associação extraídas dos dois algoritmos (Figura 38).

Figura 38 - Relação entre o número de regras de associação e valor mínimo de suporte para valor de confiança mínimo de 40%.

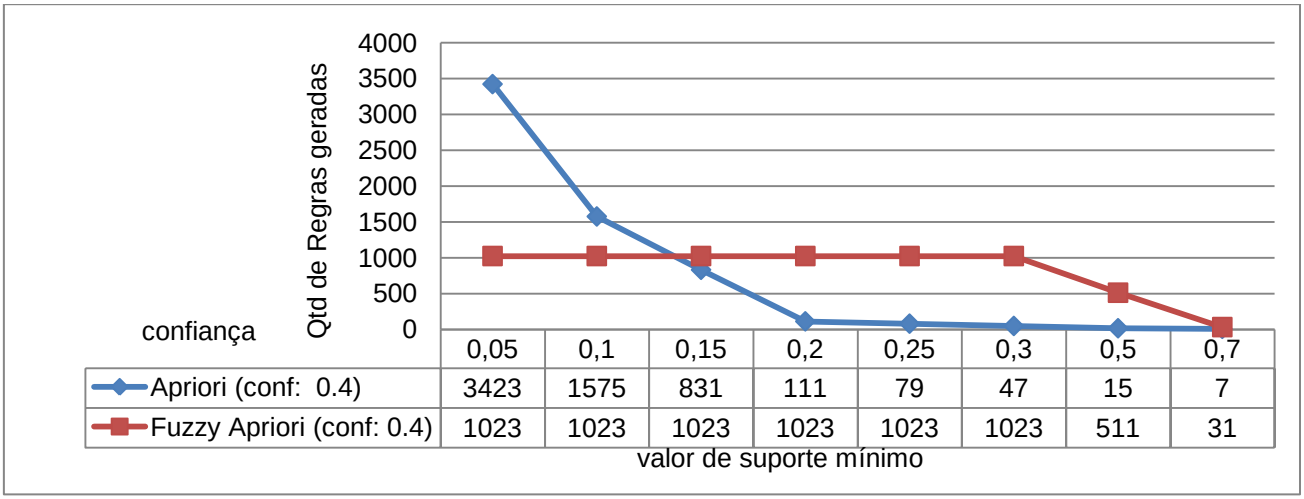

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
Apriori (conf: 0.4)	3423	1575	831	111	79	47	15	7
Fuzzy Apriori (conf: 0.4)	1023	1023	1023	1023	1023	1023	511	31

5.4.2 Análise comparativa de quantidade de regras de classificação

Os valores de confiança mínimos de 40% e 90% serviram de parâmetros para representar a distribuição da quantidade de regras de classificação extraídas dos dois algoritmos (Figura 39).

5.4.3 Análise comparativa de acurácia das regras de associação

Os valores de confiança mínimos de 40% e 90% serviram de parâmetros para representar a acurácia das regras de associação extraídas dos dois algoritmos (Figura 40).

Figura 39 - Relação entre número de regras de classificação e valor mínimo de suporte para valor de confiança mínimo de 40% e 90%.

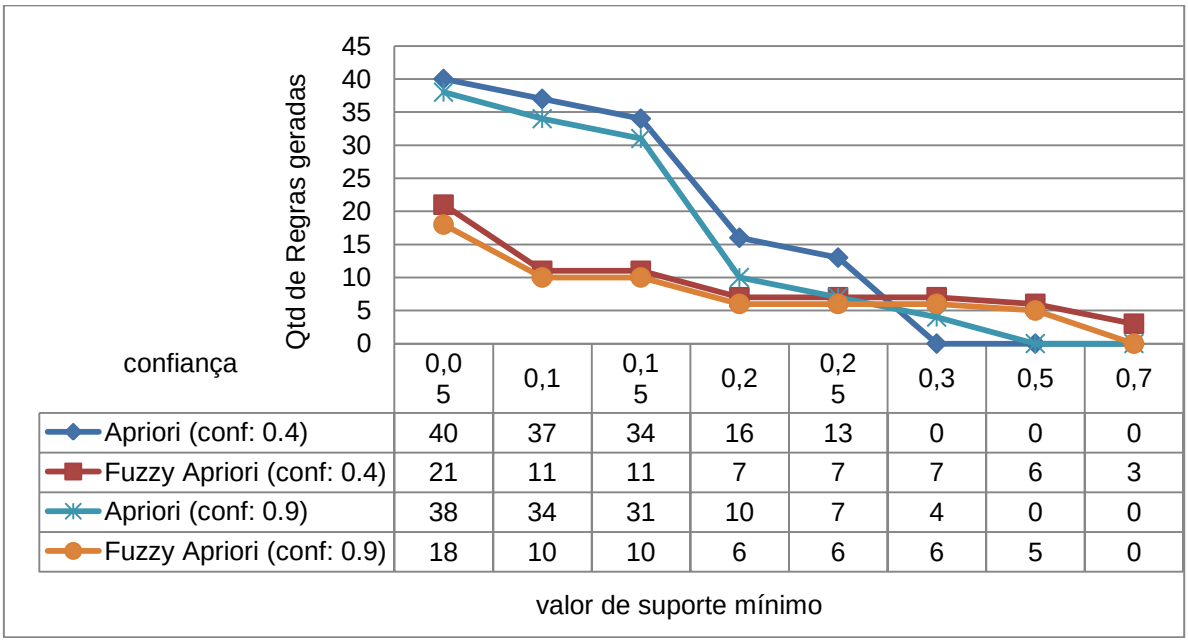

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
Apriori (conf: 0.4)	40	37	34	16	13	0	0	0
Fuzzy Apriori (conf: 0.4)	21	11	11	7	7	7	6	3
Apriori (conf: 0.9)	38	34	31	10	7	4	0	0
Fuzzy Apriori (conf: 0.9)	18	10	10	6	6	6	5	0

Figura 40 - Relação entre percentual de acurácia alcançado e valor mínimo de suporte para valor de confiança mínimo de 40% e 90%.

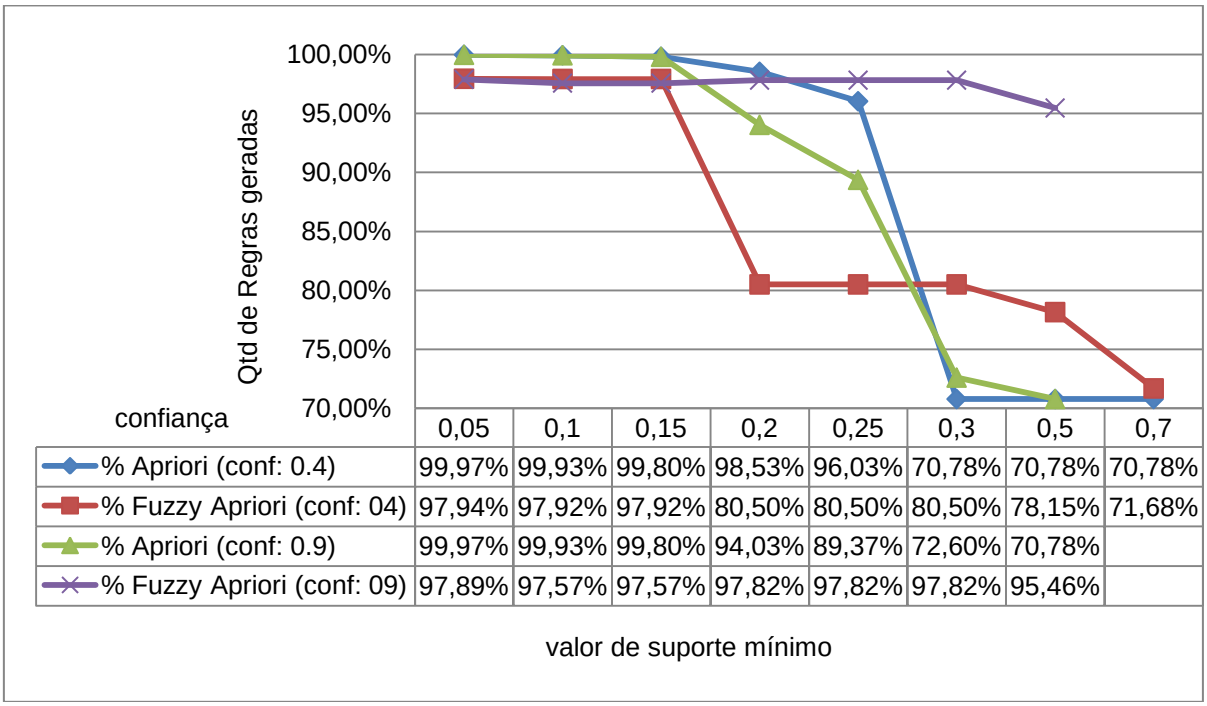

confiança	0,05	0,1	0,15	0,2	0,25	0,3	0,5	0,7
% Apriori (conf: 0.4)	99,97%	99,93%	99,80%	98,53%	96,03%	70,78%	70,78%	70,78%
% Fuzzy Apriori (conf: 04)	97,94%	97,92%	97,92%	80,50%	80,50%	80,50%	78,15%	71,68%
% Apriori (conf: 0.9)	99,97%	99,93%	99,80%	94,03%	89,37%	72,60%	70,78%	
% Fuzzy Apriori (conf: 09)	97,89%	97,57%	97,57%	97,82%	97,82%	97,82%	95,46%	

CONCLUSÃO E FUTUROS TRABALHOS

A pesquisa apresentada neste trabalho abordou uma análise comparativa de desempenho dos algoritmos de regras de associação Apriori (AGRAWAL et al.,1996) e Fuzzy Apriori (HONG et al., 2001) aplicados num conjunto de dados de Sistema de Detecção de Intrusos.

Uma das contribuições de relevância abordada nesta pesquisa refere-se à comparação de algoritmos de aprendizado de máquina na extração de conhecimento de dados aplicados em cenário real.

Este trabalho teve como objetivo comparar técnicas de extração de regras de associação de atributos relevantes de um conjunto de dados de um Sistema de Detecção de Intrusos em que se utilizou uma abordagem de detecção de intrusos por uso indevido. A proposta era de se analisar as taxas de erros alcançadas no processo de detecção de padrões de ataques.

O modelo apresentado possui uma arquitetura de dados composta por dez atributos relevantes e um atributo-classe. Considerando-se os resultados gerados pelo processo de extração de regras de associação e de extração de regras de classificação associativa, foi possível analisar os eventos em padrões considerados normais ou como ataque.

Ambos os algoritmos utilizados, Apriori e Fuzzy Apriori, extraíram regras de associação tidas como fortes, capazes de classificar os ataques presentes no conjunto de dados das conexões KDD 99.

O conjunto de dados de detecção de intrusos já tinha presente uma saída-classe previamente definida, de modo que o objetivo era extrair as regras de associação deste conjunto de dados e, através de um subconjunto de dados, fazer a classificação associativa, de modo a determinar se os registros de entrada correspondiam a uma conexão normal ou de ataque.

Devido ao fato de o conjunto de dados se apresentar desbalanceado, foi preciso fazer considerações de pré-processamento de maneira que o conjunto de dados pudesse ser analisado. Como o percentual de ataques do tipo DoS representava quase que 80% dos ataques, os ataques U2R e R2L foram desconsiderados. Devido à baixa percentagem de amostras no conjunto de dados,

os ataques U2R e R2l apresentariam baixa percentagem de acerto de detecção, o que prejudicaria na comparação dos algoritmos.

Para ambos os experimentos foram utilizadas cinco partições para os atributos de valores quantitativos, sendo no Apriori na forma discretizados e no Fuzzy Apriori na forma de conjuntos fuzzy.

Os resultados obtidos com a utilização somente dos atributos relevantes para a extração de regras de associação relevantes e a respectiva classificação foram muito satisfatórios, pois em ambos os algoritmos se aproximaram e se mantiveram em taxas de acertos elevadas.

Com relação aos experimentos realizados de quantidade de regras de associação extraídas, quantidade de regras de classificação associativa extraídas e o respectivo percentual de acerto, temos a considerar que:

- O número de regras de associação utilizando-se o algoritmo Apriori, se comportou de forma esperada. Ou seja, conforme o valor de suporte mínimo aumentava, o número de regras descrescia. Em valores de suporte mínimo inferior, o algoritmo Apriori apresentou um quantitativo de regras de associação superior ao Fuzzy Apriori. No entanto, a partir do valor de suporte mínimo de 15%, considerando em todos os valores mínimos de confiança, o quantitativo de regras de associação no Fuzzy Apriori foi superior, e sua redução, mais gradual. Em ambos a variação do valor mínimo de confiança acompanhou a mesma tendência, ou seja, conforme o valor mínimo de confiança aumentava, o número de regras diminuía.
- Com relação à quantidade do número de regras de classificação associativa, que nada mais são que um subconjunto das regras de associação, teve um comportamento similar e esperado. Ou seja, conforme o valor de suporte mínimo aumentava, o número de regras de associação classificativa diminuía. O número de regras de associação classificativa no algoritmo Fuzzy Apriori foi menor que no algoritmo Apriori em valores mínimos de suporte inferior, mas a partir do valor de suporte mínimo de 30% esse número foi superior. Observa-se que no algoritmo Fuzzy Apriori, apesar de geradas em menor quantidade para valores de suporte mínimo inferior, as regras de associação continuaram a ser geradas para valores de suporte mínimo superior. Enquanto que no algoritmo Apriori, para esses valores de suporte mínimo superior elas não foram mais geradas. Ou seja, no algoritmo

Apriori não houve um subconjunto de regras de associação suficiente que pudesse identificar a taxa de acerto das regras de associação extraídas.

- Quanto às taxas de acurácia de acertos, observa-se que, para valores de suporte inferior, o algoritmo Apriori apresentou uma taxa de acerto superior, tendo como exemplos:
    - Com valor de suporte mínimo de confiança de 40% e 60%, o percentual de acerto no Fuzzy Apriori foi superior somente após o subconjunto de regras de classificação associativa do algoritmo Apriori deixar de ser gerado.
    - Já com valor de suporte mínimo de confiança de 80% e 90%, o percentual de acerto no Fuzzy Apriori foi superior a partir do valor de suporte mínimo de 15%, mesmo tendo um subconjunto de regras de classificação associativa inferior ao subconjunto do algoritmo Apriori.

Diante dos números apresentados, podemos considerar que o número de regras de associação extraídas no algoritmo Apriori apresentou uma tendência de curva mais regular, enquanto no Fuzzy Apriori o número de regras de associação extraídas se manteve elevado e estável, em valores de suporte mínimo, entre 5% e 30%.

Quanto à taxa de acurácia de acerto dos registros de ataque do conjunto de dados do Sistema de Detecção de Intrusos, o Fuzzy Apriori apresentou taxas de acerto superiores para um subconjunto de regras inferior ao Apriori. Ou seja, com um número de regras de classificação associativa menor, a taxa de acerto foi superior. Observa-se, no entanto, que para este fato o Fuzzy Apriori teve um quantitativo de regras de associação gerada superior.

Embora o método Fuzzy Apriori se tenha apresentado como uma possível solução para um Sistema de Detecção de Intruso, observa-se que as características desse conjunto de dados não é uma das melhores opções. Segundo TAVALLAEE (2009) observou que, após realizar uma análise estatística do conjunto de dados KDD99, questões importantes observadas afetam o desempenho dos algoritmos avaliados, e os resultados podem não ser tão satisfatórios para o sistema detecção de intrusos. Uma delas foi grande número de registros redundantes. Nos conjuntos de treinamento e teste, verificou-se que cerca de 78% e 75% dos registros são duplicados, respectivamente. Essa grande quantidade de registros redundantes no

conjunto de treinamento tem como consequência que os algoritmos terão pouca quantidade de registros para extrair regras de associação fortes e consistentes, o que implicou em não considerarmos aqui os ataques U2R e R2L.

A partir das análises e comparações realizadas, uma contribuição significante deste trabalho foi a de demonstrar a qualidade do algoritmo Fuzzy Apriori em relação ao algoritmo Apriori. Dessa maneira, uma proposta de trabalho futuro seria avançar na qualidade das regras de associação extraídas de um sistema de detecção de intrusos, visando assim a melhorar a acurácia de acerto dos ataques. Uma possível sugestão seria automatizar o dimensionamento das partições fuzzy de forma que um algoritmo possa prover variáveis linguísticas com características relevantes.

REFERÊNCIAS

AGRAWAL, Rakesh; IMIELINSKI, T.; SWAMI, A. *Mining Association Rules between Sets of Items in Large Databases*, SIGMOD 5/93, 207-216, Washington, USA, 1993.

AGRAWAL, Rakesh; SRIKANT, Ramakrishnan . *Mining generalized association rules*. In: Proceedings of the 21st International Conference on Very Large Data Bases, pp. 407–419, 1995.

AGRAWAL, Rakesh; SRIKANT, Ramakrishnan. *Fast Algorithms for Mining* Association Rules. In: 20th VLDB Conference, 487-498, Santiago, Chile, 1994.

AGRAWAL, Rakesh; SRIKANT, Ramakrishnan. *Mining quantitative association rules in large relational tables*. In SIGMOD 96, 1996

ALCALA, J. ; FERNANDEZ, A.; LUENGO, J.; DERRAC, J.; GARCIA, S.; SANCHEZ, L.; HERRERA, F. *KEEL Data-Mining Software Tool: Data Set Repository, Integration of Algorithms and Experimental Analysis Framework*. Journal of Multiple-Valued Logic and Soft Computing 17:2-3 (2011) 255-287

ANDERSON, James P. *Computer Secutiry Threat Monitoring and Surveillance, Technical Report.* James P. Anderson Co. Fort Washington, PA, abr. 1980.

ASSOCIAÇÃO BRASILEIRA DE NORMAS E TÉCNICAS – ABNT. NBR ISO/IEC 17799:2005 – Tecnologia da informação – Técnicas de segurança – Código de prática para a gestão da segurança da Informação. Rio de Janeiro: ABNT, 2005.

BERRY, J. A. M.; LINOFF, Gordon. *Data Mining Techiques for Marketing, Sales, and Customer Suppo*r. John Wiley & Sons, Inc., 1997.

BIANCO, D. *The Tao of Network Security Monitoring: Beyond Intrusion Detection*. In Information Security; Dec2004, Vol. 7 Issue 12, p16

BIONDI, L. N.; COELHO, P. H. G.; AMARAL, J. L. M.; MELLO, M. H. C. S. *Minicurso de Sistemas Especialistas Nebuloso*. XXXVIII Simpósio Brasileiro de Pesquisa Operacional, 2006.

CHAPKE, P. P.; RAUT, A. B. Intrusion Detection System using fuzzy logic and Data Mining Technique. International Journal of Advanced Research ni Computer Science and Software Engineering. IJARCSSE - Volume 2, Issue 12, December 2012.

CHEN, G.; LIUI, H.; YU, L; WEI, Q.; ZHANG, X. *A New Approach to Classification Based on Association Rule Mining*. Decision Support System 42 (2006) 674-689.

CHEN, Z; CHEN, G. *Bulding an associative classifier based on fuzzy association rules*. International Journal o Computational Intelligence Systems 1:3 (2008) 262-273.

CORTES, S. C.; PORCARO, R. M.; LIFSCHITZ, Sérgio. *Mineração de Dados - Funcionalidades, Técnicas e Abordagens.* PUC-RioInf.MCC10/02, Maio 2002.

DAVENPORT, T. H., PRUSAK, L. *Conhecimento Empresarial: como as organizações gerenciam o seu capital intelectual*. 1998. Campus. Rio de Janeiro.

DENNING, D. E. *An intrusion detection model*. *IEEE Transaction on Software Eng 13* (1987), 222–232.

El-SEMARAY, A.; EDMONDS, J.; GONZALES-PINO, J.; PAPA, M. *Applying data mining of fuzzy association rules to network intrusion detection*. In Proc. of the 2006 IEEEWorkshop on Information Assurance, West Point, NY, pp. 100-107, 200.

FAYYAD, U. et al. *Advances in Knowledge Discovery and Data Mining*. MIT Press, Cambridge: 1996.

FAYYAD, U; PIATETSKY-SHAPIRO, G.; SMYTH, P. *From data mining to knowledge discovery in databases.* AI Magazine 17 (1996) 37-54.

GODINEZ, F.; HUTTER, D; MOROY, R. *Attribute Reduction for Effective Intrusion Detection*. In Proceedings of the Advances in Web Intelligence Conference (AWIC'2004), Cancum, Mexico, pp. 74-83, 2004.

GOLDSCHIMIDT, R.; PASSOS, E. *Data mining: Um guia prático*. Rio de Janeiro: Campus, 2005.

HALL, Mark; FRANK, Eibe; HOLMES, Geoffrey; PFAHRINGR, Bernhard; REUTEMAN, Peter; WITTEN, Ian H. *The WEKA Data Mining Software: An Update*. SIGKDD Explorations, 2009, Volume 11, Issue 1.

HAN Jiawei; KAMBER Micheline. *Data Mining - Concepts and Techniques.* Morgan Kaufmann Publishers, Inc, 2001.

HAN, J; PEI J; YIWEN Y; MAO, R. *Mining frequent patterns without candidate generation: A frequent-pattern tree approach*. Data Min Knowl Discov 8(1):53–87, 2004.

HONG, T. P.; KUO, C.S.;CHI, S.C. *Trade-off between computation time and number of rules for fuzzy mining from quantitative data*. International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems 9:5 (2001) 587-604.

HONG, T.P.; KUO, C.S.; WANG, S.L. *A fuzzy AprioriTid mining algorithm with reduced computational time.* Applied Soft Computing , 2004, 5(1): 1-10

HULLERMEIER, E; YI, Y. *In Defense of Fuzzy Association Analysis.* IEEE Transactions on Systems, Man, and Cybernetric - Part B, 37(4): 1039-1043, 2007.

IDRIS, N. B. *Improved Intrusion Detection System Using Fuzzy Logic For Detecting Anomaly And Misuse Type Of Attacks*. The proceedings of the International Conference on soft computing and pattern recognition, (SoCPaR), Malacca, Malaysia, 2009.

JANG, J.-S. R.; GULLEY, N. *The Fuzzy Logic Toolbox for use with MATLAB*. The MathWorks, Inc., Natick, Massachusetts, 1995.

JANG, J.S.R.; C.T.S. & MIZUTANI, i, E. (1997), *Neuro-Fuzzy and Soft Computing*, Prentice Hall, New York-USA.

KACPRZYK, J. *Multistage fuzzy control*. Chichester, UK: John Wiley Sons, 1997.

KAYACIK, H. G.; ZINCIR-HEYWOOD, A. N.; HEYWOOD, M. I. *Selecting Features for Intrusion Detection: A Feature Relevance Analysis on KDD 99 Intrusion Detection Datasets.* In Third Annual Conference on Privacy, Security and Trust, St. Andrews, New Brunswick, Canada, October 2005.

KDD Cup 1999 data (Computer network intrusion detection). Disponível em <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html> Último Aceso em: 26/01/2014.

KUOK, C. M.; FU, A.; WONG, M. H. *Mining Fuzzy Association Rules in Databases*, SIGMOD Record, pp. 41-46, Vol. 27, No. 1, 1998.

LAROSE, D. T. *Discovering Knowledge in Data: An Introduction to Data Mining*. ISBN 0-471-66657-2, John Wiley & Sons, Inc, 2005.

LEE, W.; STOLFO, S. J.; MOKD, K. W. *A data mining framework for building intrusion detection models*. In Proceedings of the 1999 IEEE Symposium on Security and Privacy, May 1999.

LI, Wenmin, HAN, Jiawei; PEI, Jian. *CMAR: Accurate and Efficient Classification Based on Multiple Class-Association Rules*. In: ICDM'01, 369-376, 2001.

LIU, B.; HSU, W.; MA, Y. *Integrating Classification and Association Rule Mining*. In: Fourth International Conference on Knowledge Discovery and Data Mining, 80-86, 1998.

LIU, H.; MOTODA, H. *Feature Selection for Knowledge Discovery and Data Mining*, July 1998, ISBN 0-7923-8198-X, by Kluwer Academic Publishers.

MAIMON, Oded; ROKACH, Lior. *Chapter 1: Introduction to Knowledge Discovery in Databases.* Data Mining and Knowledge Discovery Handbook. 2005.

MANNILA. H. (1997) *Methods and problems in data minin*g. In: Proceedings of the 6th International Conference on Database Theory (ICDT'97), LNCS, Springer-Verlag, 1186: 41–55.

MARIANO, A. M. *Comparação de Algoritmos Paralelos para a Extração de Regras de Associação no Modelo de Memória Distribuída*. Dissertação - Universidade Federal do Mato Grosso do Sul, 2011.

MENZIES, Tim; HU, Ying. *Data Mining For Busy People*. IEEE Computer, Outubro de 2003, pgs. 18-25.

MORENO, N. M.; SEGRERA, Saddys; LOPEZ, F. V. *Association Rules: Problems, solutions and new applications.* Actas del III Taller Nacional de Minería de Datos y Aprendizaje, TAMIDA 2005, pp.317-323.

OLUSOLA, A. A; OLADELE, S. A.; ABOSEDE, O. D. *Analysis of KDD'99 Intrusion Detection Dataset for Selection of Relevance Features*. In Proceeding of the Word Confress on Engineering and Computer Science, San Francisco, USA, october 2010.

PEI, J; HAN, J; LAKSHMANAN, LVS; Data Engineering, 2001. Proceedings. 17th International Conference on, 433-442.

PITONI, R. M. *Mineração de Regras de Associação nos Canais de Informação do Direto*. Trabalho de Conclusão de Curso – UFRS, 2002.

ROOS, T. J. *Fuzzy Logic with Engineering Applications*. McGraw-Hill, Inc., New. York, 1995.

SCHEINERMAN, E. R. *Matemática Discreta - Uma Introdução*. Cengage Learning Editores; 2003. ISBN 978-85-221-0291-4. p. 27.

SHAPIRO, Gregory; FRAWLEY, W. J. *Discovery, analysis, and presentation of strong rules*. In, eds., Knowledge Discovery in Databases, AAAI/MIT Press, Cambridge, MA. (1991).

SILVA, M. P. S. *Mineração de Dados - Conceitos, Aplicações e Experimentos com WEKA*. Minicurso de Mineração de Dados. UERN & INPE, 2004.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. *Introduction to Data Mining*. Pearson, 2006.

TANSCHEIT, R. *Sistemas fuzzy*, In: Intelig^encia computacional: aplicada à administração, economia e engenharia em Matlab, pp. 229–264, São Paulo, Thomson Learning, 2007.

TANSCHEIT, R. (2007). *Sistemas fuzzy*. Thomson Learning, São Paulo, pp. 229–264.

TAVALLAEE, M.; BAGHERI, E.; LU, W.; GHORBANI, A.A. *Detailed Analysis of the KDD CUP 99 Data Set In IEEE Symposium on Computational Intelligence in Security and Defense Applications* . (CISDA) (2009), pp. 1-6.

UCI - UCIrvine Machine Learning Repository. Disponível em <http://archive.ics.uci.edu/ml/index.html> Acesso em: 26/01/2014.

VERLINDE, H., De COCK, M., BOUTE, R. *Fuzzy Versus Quantitative Association Rules: A Fair Data-Driven Comparison*. IEEE Transactions on Systems, Man, and Cybernetics - Part B: Cybernetics, 36, 679-683 (2006).

WANG, Jie. Computer Network Security: Theory and Practice. Higher Education Press, Beijing and Springer-Verlag GmbH Berlin Heidelberg, 2009.

WANG, Wei; GOMBAULT, S.; GUYET, T. *Towards Fast Detecting Intrusions: Using Key Attributes of Network Traffic*. Internet Monitoring and Protection, 2008. ICIMP '08. The Third International Conference on, janeiro/2008.

WU, K. X.; HAO J.; WANG, C. *Application of Fuzzy Association Rules in Intrusion Detection*, International Conference on Internet Computing & Information Services (ICICIS), 2011, pp. 269 – 272.

YOGENDRA, K. J.; UPENDRA. Article: *Intrusion Detection using Supervised Learning with Feature Set Reduction*. International Journal of Computer Applications 33(6):22-31, November 2011.

ZADEH, L. (1965). *Fuzzy sets, Information Control* 8, 338-353. fonte: BAE.

ZAKE, M. J. *Scalable algorithms for association mining*. IEEE Transactions on Knowledge and Data Engineering, 12(3):372–390, 2000

CHOU, TS; YEN, Yen KK; LUO, J. *Network intrusion detection design using feature selection of soft computing paradigms*. International Journal of computational Intelligence 2008;4(3):196-208.