Universidade Federal de Ouro Preto - UFOP

Instituto de Ciências Exatas e Biológicas - ICEB

Departamento de Computação - DECOM

MINERAÇÃO DE DADOS PARA PADRÕES DE SEQUENCIA

Aluna: Cecília Henriques Devêza
Matricula: 07.1.4121

Orientador: Luiz Henrique de Campos Merschmann

Ouro Preto
20 de novembro de 2010

Universidade Federal de Ouro Preto - UFOP

Instituto de Ciências Exatas e Biológicas - ICEB

Departamento de Computação - DECOM

MINERAÇÃO DE DADOS PARA PADRÕES DE SEQUENCIA

Proposta de monografia apresentada ao curso de Bacharelado em Ciência da Computação, Universidade Federal de Ouro Preto, como requisito parcial para a conclusão da disciplina Monografia I (BCC390).

Aluna: Cecília Henriques Devêza
Matricula: 07.1.4121

Orientador: Luiz Henrique de Campos Merschmann

Ouro Preto
20 de novembro de 2010

Sumário

1 Introdução **1**

2 Justificativa **3**
2.1 Proposta 3

3 Objetivos **4**
3.1 Objetivo geral 4
3.2 Objetivos específicos 4

4 Metodologia **5**

5 Atividades Desenvolvidas **7**
5.1 Apriori 7
5.2 AprioriAll 8
5.3 GSP 9
5.4 Pré-processamento dos dados 10

6 Trabalhos Futuros **11**

7 Cronograma de atividades **11**

Lista de Figuras

1 Etapas do KDD 2

Lista de Tabelas

1 Exemplo de Base de Dados. 2
2 Cronograma de Atividades. 11

1 Introdução

O constante crescimento de informações decorrentes do desenvolvimento tecnológico tem trazido às organizações um número abundante de dados, aumentando a importância das ferramentas que tem por objetivo extrair informações úteis destes dados. O grande desafio dessas organizações é exatamente transformar os dados em conhecimento. Sendo uma organização comercial, este conhecimento oriundo dos dados históricos pode direcionar melhor campanhas de marketing, evidenciar formas mais lucrativas de exibição de produtos, bem como mostrar os clientes mais propícios à compra dos mesmos. Sendo uma organização acadêmica, o conhecimento pode esclarecer questões cujos resultados são impossíveis de serem observados "a olho nu" por pesquisadores frente a um volume tão grande de dados. Além do que, pode encontrar justificativas sobre dúvidas acerca da Medicina, Biologia ou qualquer outra ciência que tem a necessidade de prever resultados com base em dados previamente cadastrados. A técnica de extração de informação mais indicada para este tipo de processo, é a chamada Mineração de Dados.

Mineração de Dados é um ramo da computação que teve início nos anos 80, quando os profissionais das empresas e organizações começaram a se preocupar com os grandes volumes de dados informáticos estocados e inutilizados dentro da empresa. Nesta época, Data Mining consistia essencialmente em extrair informação de gigantescas bases de dados da maneira mais automatizada possível. Atualmente, Data Mining consiste sobretudo na análise dos dados após a extração, buscando-se por exemplo levantar as necessidades reais e hipotéticas de cada cliente para realizar campanhas de marketing.[3].

A descoberta de conhecimento, entretanto, não pode ser resumida à Mineração de Dados. Esta, é apenas uma etapa de todo o processo, conhecido como KDD (*Knowledge Discovery in Database*). O mesmo pode ser dividido em:

- Pré-processamento de Dados
  Os dados muitas vezes precisam de uma limpeza antes de passar para a etapa de Mineração. Como as bases geralmente são muito grandes, é necessário remover delas tudo que não vai ser utilizado na próxima etapa, como dados redundantes ou inconsistentes. A qualidade dos dados é que determina a eficiência dos algoritmos de Mineração.

- Mineração de Dados
  É a técnica que será abordada neste trabalho, mais precisamente a área de Padrões de Sequência, onde se busca conhecimento em uma base de dados que segue uma ordem temporal, ou seja, onde os dados estão datatos. Essa base possibilita a descoberta de regras do tipo "Se um determinado usuário comprou um produto X, é provável que ele volte e compre o produto Y".

- Pós-Processamento de Resultados
  Após a extração das regras de conhecimento, é preciso verificar o que saiu como "novidade" dessas regras, ou seja, qual conhecimento estava escondido nos dados que alguém não seria capaz de descobrir sem passar pelo processo automatizado. É recomendado que esta etapa seja realizada por alguém que

conhece o processo sob os quais os dados foram extraídos e saiba diferenciar as regras que são ou não são aproveitáveis.

A figura a seguir ilustra as etapas do KDD:

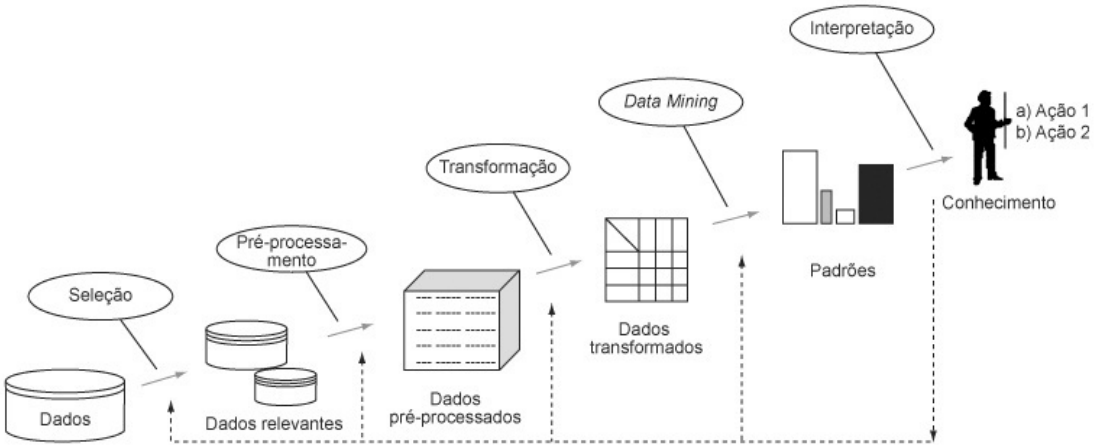

Figura 1: Etapas do KDD

Este projeto irá englobar muitas das etapas exibidas, desde o pré-processamento dos dados até a análise dos mesmos, tendo como ênfase a Extração de Regras de Associação, presente na etapa de *Data Mining*. A definição de Padrões de Sequência é uma parte mais específica do processo de descoberta de Regras de Associação, que visa evidenciar sequências de ações/acontecimentos presentes em uma base de dados organizada de forma temporal, ou seja, onde os dados estão datados ou seguem um ordem cronológica. Além disso, é preciso que cada transação da base esteja relacionada a um agente para que as ligações entre as transações possa ser realizada de forma coerente.

A tabela a seguir exemplifica uma base de Dados que pode ser utilizada para descobrir padrões de sequência:

ID do Usuário	**Sequências de Itens**	**Data**
1	3, 6, 7, 1	06/01/2010
2	1, 2	10/01/2010
1	5, 9, 13	03/02/2010
3	2, 5	11/02/2010
3	8	23/03/2010

Tabela 1: Exemplo de Base de Dados.

2 Justificativa

A utilidade deste projeto justifica-se pela crescente necessidade de se encontrar informações úteis de grandes bases de dados. Com a constante automatização de processos das empresas, cresce também o armazenamento de dados enviados e recebidos nestes processos. Entretanto, este dados precisam de um tratamento para que sejam úteis à lucratividade das organizações.

Partindo desde princípio, a empresa GerenciaNet Tecnologia em Pagamentos ofereceu parte de sua base dados que estão relacionados à visualização de produtos em lojas virtuais, sob a condição de que estes dados sejam utilizados única e exclusivamente para fins acadêmicos. A fim de assegurar os direitos dos clientes pela empresa, não foram divulgados: nomes das lojas envolvidas; dados pessoais de clientes que visualizaram produtos nas lojas. Estas informações foram previamente criptografadas.

A base de dados recebida, possui o seguinte formato:

idTransação, idCliente, Produto Visualizado, Loja, Data
idTransação, idCliente, Produto Visualizado, Loja, Data
⋮
idTransação, idCliente, Produto Visualizado, Loja, Data

Onde IdTransação é um valor inteiro que cresce de um a cada tupla, começando por 1. IdCliente é um valor criptografado que representa o cliente que realizou a transação, este valor pode se repetir na base. Produto Visualizado é o nome do produto que foi visto pelo cliente naquela transação (cada tupla mostra a visualização de um único produto). E por fim, Data é o dia, mês e ano que o produto foi visualizado, ou seja, quando a transação ocorreu.

2.1 Proposta

A proposta deste projeto é construir um software capaz de receber uma base de dados como a descrita anteriormente, e gerar como saída as sequências de itens frequentes nessa base.

Primeiramente, a base deverá passar por um pré-processamento automático, que vai prepará-la para ser utilizada pelo algoritmo GSP implantado na ferrramenta WEKA. Este pré-processamento deve gerar um arquivo no formato ARFF, onde os produtos e os identificadores dos clientes são mapeados para valores numéricos. Toda a conversão de dados para possibilitar a leitura pelo WEKA e posteriormente a tradução dos resultados gerados, caberão ao software. A geração dos candidatos frequentes a partir do arquivo ARFF caberá ao WEKA. Detalhes sobre o algoritmo GSP podem ser vistos em [2].

3 Objetivos

3.1 Objetivo geral

Este trabalho tem como principal objetivo, a obtenção de padrões de sequência a partir de dados reais de uma loja virtual, para melhor gerenciar campanhas de marketing e promocionais, utilizar de estratégias para fidelizar usuários, e outras ferramentas que visa a lucratividade de uma organização e satisfação de seus clientes.

3.2 Objetivos específicos

- Conhecer os algoritmos de Padrões de Sequência e Mineração de Dados em geral;
- Aprimorar o conhecimento da linguagem de programação utilizando diversos recursos para processamento de dados;
- Descobrir regras de sequência a partir de uma base de dados real.

4 Metodologia

Inicialmente será realizado um trabalho de levantamento e revisão de literatura, com o objetivo de fixar os conceitos de Mineração de Dados acerca da resolução de padrões de sequência. Um algoritmo bastante eficiente utilizado para este fim é o GSP (*Generalized Sequential Patterns*). A idéia é construir um software que utiliza este algoritmo na etapa de geração de regras, de forma que a base de entrada será aquela fornecida pela empresa, e a saída será o arquivo de regras de padrões de sequência contidas nesta base.

O arquivo de entrada, entretanto, precisa ser previamente processado. Existem neste arquivo informações desnecessárias à uma mesma pesquisa por padrões de sequência, já que visualizações de produtos de 5 lojas distintas estão misturados. Baseando-se nos produtos (que não encontram-se criptografados), é possível verificar que não existe uma co-relação lógica entre essas lojas, portanto, é recomendável que sejam escolhidos os dados de uma loja por vez. Após a divisão de dados das 5 lojas, a sequência de uma delas será escolhida para os primeiros testes. É também parte deste processamento, a transformação tanto dos nomes dos produtos quanto dos identificadores de clientes em valores númericos, visto que os dados precisam estar adaptados ao formato que o WEKA determina. Além disso, as datas não aparecerão de forma direta neste arquivo, mas é preciso ressaltar que os produtos listados no mesmo devem seguir a ordem cronológica definida por elas na base.

Feito o processamento, um arquivo ARFF é gerado pelo software. Este arquivo será lido pela ferramenta WEKA, que por sua vez, irá gerar um arquivo de saída com a lista de itens frequentes.

O Weka é uma coleção de algoritmos de aprendizado de máquina para tarefas de Mineração de Dados. Os algoritmos podes ser aplicados diretamente a um conjunto de dados, ou chamados a partir do seu código Java. Weka contém ferramentas para os dados de pré-processamento, classificação, regressão, clusterização, regras de associação e visualização. É também ideal para o desenvolvimento de novos modelos de aprendizagem de máquina.[1].

Um mês será gasto apenas na realização de testes e possíveis correções do código. Neste passo, serão utilizadas bases de dados diferentes para comparar a análise de execução e dados de saída do algoritmo.

Após todas as modificações necessárias, será feita uma análise sobre os dados retornados. A regra de padrão de sequência, deve seguir o seguinte formato:

$$<\{5\}, \{2,7\}>$$

Onde os valores que estão entre chaves pertecem à uma mesma transação - ou seja, a um mesmo acesso à loja virtual. Cada transação separada por vírgula indica que foi realizada em uma data diferente, seguindo uma ordem cronológica da esquerda para a direita. Este exemplo indica que: "Um cliente que visualiza o produto 5, posteriormente retorna à loja e visualiza os produtos 2 e 7". Este conjunto de transações, por seguir uma ordem temporal, não é comutativo, ou seja, não é possível afirmar a partir do exemplo, que a regra $<\{2, 7\}, \{5\}>$ é verdadeira também.

Os dados nesta forma, entretanto, não trazem muita informação ainda, já que os produtos foram previamente mapeados em valores numéricos. O software deve ser capaz de fazer a tradução destes valores numéricos novamente para os nomes originais do produto, para então dar início à análise das regras.

Com as regras retornadas pelo algoritmo, será possível verificar os produtos que, se visualizados, geram uma probabilidade maior de outros determinados produtos serem visualizados também posteriormente, o que pode ser utilizado no marketing da empresa afim de direcionar propagandas a clientes específicos, como criar promoções de produtos Y que provavelmente são adquiridos após produtos X, para aqueles que já visualizaram este último. Enfim, este é o primeiro passo para uma melhor campanha publicitária de uma loja virtual, na qual a propaganda é realmente direcionada a clientes que a esperam, evitando desperdício de gastos da empresa, fidelizando clientes e evitando a imagem de *spammer* daqueles que não desejam receber determinadas promoções por não se interessarem pelo produto divulgado.

5 Atividades Desenvolvidas

Durante os primeiros meses do projeto, foram realizados estudos sobre algoritmos de extração de padrões de sequência. O algoritmo que será utilizado neste projeto será o GSP, entretanto, para entendê-lo, é necessário primeiramente entender o algoritmo AprioriAll, que por sua vez, é baseado na técnica Apriori.

5.1 Apriori

O Apriori é um algoritmo que encontra regras de associação, sem se preocupar com a ordem temporal dos itens destas regras - o que foi posteriormente resolvido no AprioriAll. Pra encontrar as regras, é realizado um procedimento iterativo, onde cada iteração executa duas ações: geração de candidatos possivelmente frequentes, e definição dos padrões frequentes. Ao final da execução, possuímos regras de itens frequentes na forma X $\Rightarrow$ Y.

Para avaliar se uma regra deve ou não ser considerada, são utilizadas duas medidas: suporte e confiança. O suporte é a probabilidade do antecedente da regra estar presente na base em relação a quantidade total de registros na base. Ou seja:

$$S = \frac{Xq}{T}$$

Onde Xq é a quantidade de vezes que o item X aparece na base, e T é o total de itens diferentes da base.

Já a confiança, é a probabilidade de o consequente e antecedente estarem presentes juntos relativo aos registros em que aparece o antecedente. Ou seja:

$$\mathrm{S} = \frac{XYq}{Xq}$$

Onde XYq é a quantidade de tuplas em que os itens X e Y aparecem na base, e Xq é a quantidade de vezes que o item X aparece.

Tendo estas duas medidas definidas, o algoritmo começa verificando os itens que atendem ao suporte mínimo. Ou seja, para um suporte mínimo de 0.5, os itens que aparecerem em pelo menos a metade das tuplas na base de dados, serão considerados candidatos frequentes e passarão para a próxima fase.

Propriedade Apriori
Sejam I e J dois itemsets tais que I está contido em J. Se J é frequente então I também é frequente.

Sendo assim, os itens que são "podados" em uma iteração, impedem que uma gama de candidatos certamente infrequentes sejam criados, o que determina que, para que um itemset seja frequente, é necessário que todos os itemsets contidos nele também sejam. Se existir pelo menos um que não satisfaça ao suporte mínimo, então sabemos de antemão que qualquer candidato a partir dele não precisa ter suporte calculado, pois certamente não será frequente (evitando nova verredura no banco).

A figura a seguir ilustra o processo Apriori (considerando um suporte mínimo de 50%):

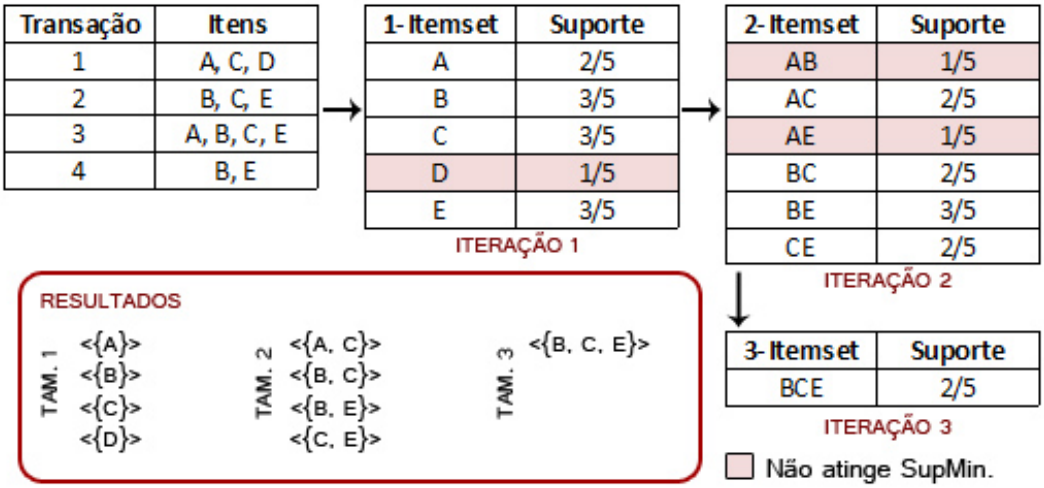

Partindo de uma base de dados onde estão listadas algumas sequencias de itens em diferentes transações, cada iteração possui como candidatos conjuntos de itens (chamados itemsets) mesclados de acordo com os considerados frequentes na transação anterior. Aqueles que não atenderem ao suporte mínimo são podados e não geram canditados na próxima iteração.

Os resultados que possuem tamanho maior ou igual a dois, se tornam as regras de associação do algoritmo. No caso destes resultados apresentados, teríamos como regras:

- A $\rightarrow$ C
- B $\rightarrow$ C
- B $\rightarrow$ E
- C $\rightarrow$ E
- B $\rightarrow$ C, E
- C $\rightarrow$ B, E
- E $\rightarrow$ B, C

Cada regra então passa por uma verificação de confiança. Aquelas que atenderem à confiança mínima, são as regras resultantes do processo. Entretando, esta verificação de confiança mínima não faz parte do algoritmo Apriori em si, o mesmo termina no momento que informa as sequencias de itens frequentes na base. Essa verificação é realizada posteriormente, a fim de garantir resultados mais fededignos.

5.2 AprioriAll

O algoritmo AprioriAll aproveita as premissas desenvolvidas no Apriori, com a diferença de que neste, a ordem com que os itens aparecem é de total importância. O objetivo aqui é encontrar os itens que costumam aparecer na base após o aparecimento de outros itens. Em nossa analogia sobre produtos em uma loja, gostaríamos de encontrar aqui os itens que tem grande probabilidade de serem adquiridos após a aquisão de outros itens.

A base de dados de um algoritmo deste tipo necessita - além da listagem dos itens - da correlação cliente X item, e a data determinante desta transação. Ou seja, se houve uma compra, é preciso saber quando e por quem. A data servirá para organizar as tuplas em ordem cronológica, e a associação com um cliente ajudará a determinar as sequencias de itens que os clientes costumam adquirir.

Para ilustrar o funcionamento deste algoritmo, o processo foi dividido em duas partes: A primeira está relacionada às transformações da base para prepará-la para o algoritmo. A segunda, é a própria execução do AprioriAll.

A figura a seguir ilustra a primeira parte do processo:

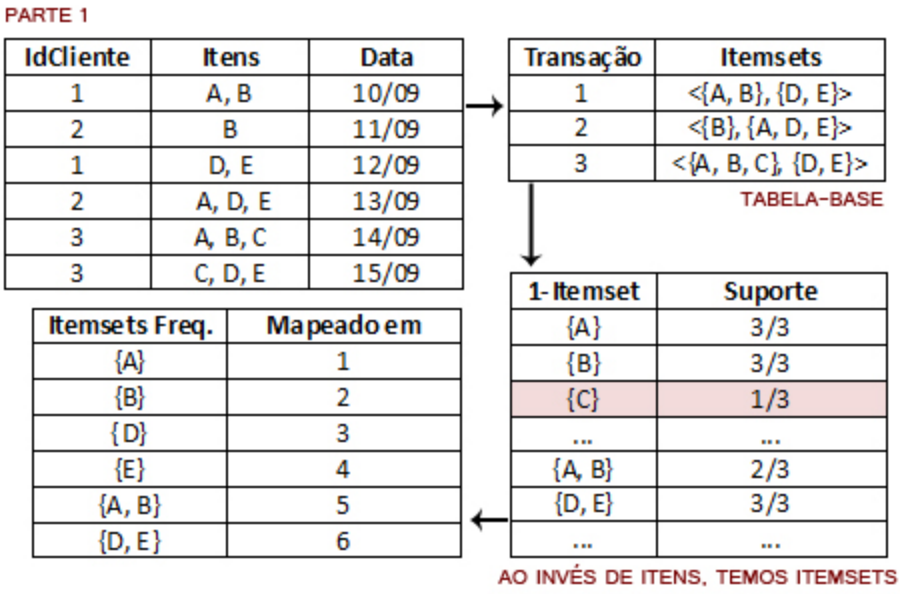

A figura a seguir ilustra a segunda parte do processo:

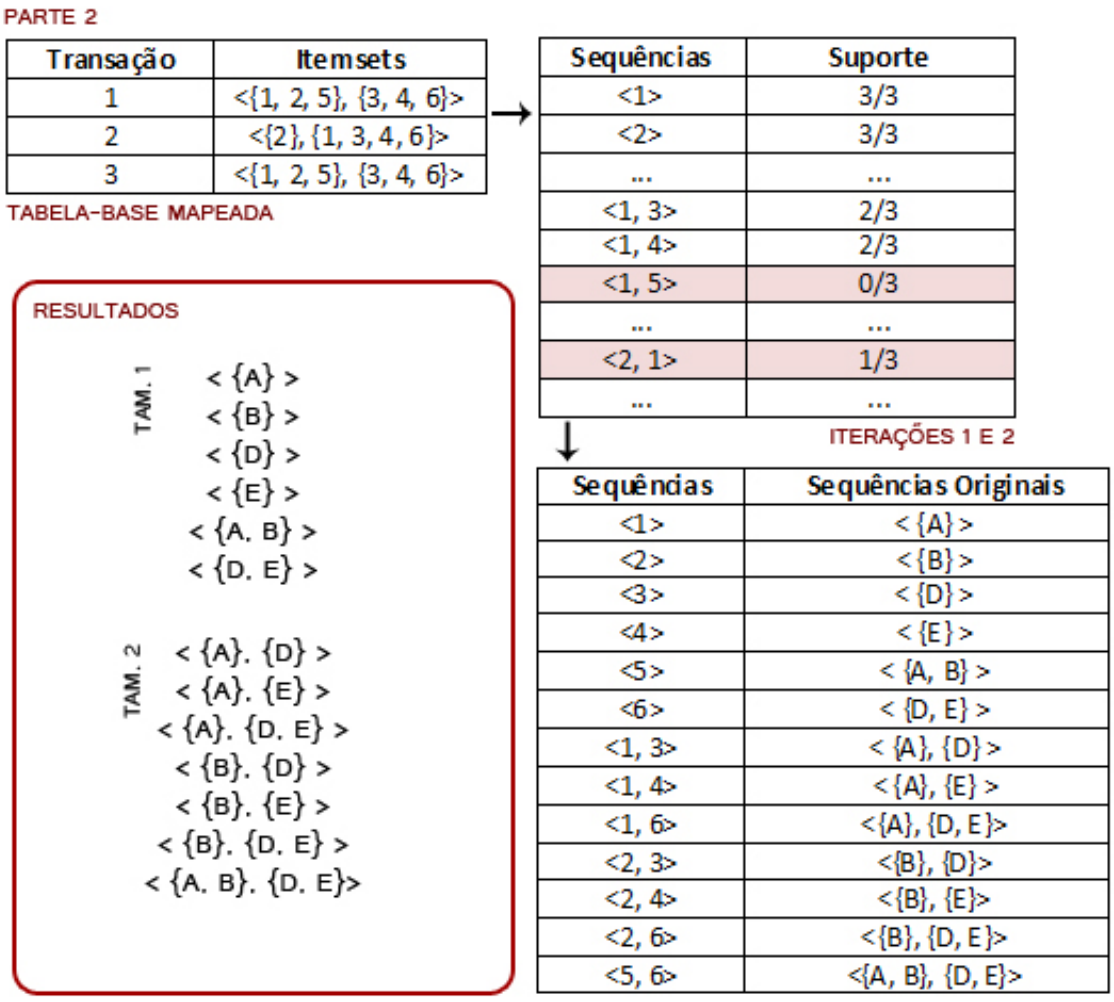

5.3 GSP

O algoritmo GSP se difere do AprioriAll principalmente nas etapas de criação de candidatos e poda de candidatos. Nesta última, são podados muito mais candidatos por iteração, devido à uma otimização na construção de seus pré-candidatos.

Na fase de geração de candidatos:

- No algoritmo AprioriAll, em cada iteração k, os conjuntos Lk e Ck (Itemsets frequentes e itemsets candidatos) são constituídos de sequências de k itemsets.
- No algoritmo GSP, em cada iteração k os conjuntos Lk e Ck (Itemsets frequentes e itemsets candidatos) são constituídos de sequencias de k itens.

Ou seja, os itemsets frequentes <A> e <B> dão origem, no AprioriAll, ao candidato <A, B>. Já no algoritmo GSP, os mesmos dão origem à dois candidatos: <A, B> e <A, B> ou seja, ao invés de derem origem a um candidato que possui dois itemsets (conjunto de itens), dá origem a dois candidatos que possuem dois itens, estejam eles em itemsets distintos ou não.

6 Trabalhos Futuros

O próximo passo deste projeto é testar a base de dados gerada (arquivo ARFF) no algoritmo GSP da ferramenta WEKA. É preciso verificar se a ferramenta tem a capacidade de trabalhar com um volume de dados muito grande, ou se será necessário dividir essa base em pequenas partes a serem processadas. A partir do momento que tivermos um resultado sobre os itens frequentes da base da loja A, é preciso analisar cada uma das regras e verificar se foi extraída uma informação relevante desta base.

Ao término deste processo, daremos início à construção do software em JAVA capaz de realizar todos os passos descritos de forma automática. Este software terá como entrada uma base de dados como a descrita na sessão 1 deste projeto, e deverá gerar um arquivo contendo nomes de produtos que são comumente visualizados / comprados após a visualização / compra de outros produtos da base.

Este software possibilitará à empresa, determinar itens com probabilidade de serem adquiridos através da análise e mineração do histórico de compras, o que pode trazer resultados positivos tanto aos donos quanto aos clientes das lojas.

7 Cronograma de atividades

A Tabela 2, mostra o cronograma com as atividades a serem realizadas, começando em Outubro de 2010, e terminando em Julho de 2011. A carga horária semanal prevista é de 20 horas.

Atividades	**Out**	**Nov**	**Dez**	**Jan**	**Fev**
- Estudo de Algoritmos de P.S.*	x				
- Levantamento de Referências		x	x		
- Pré-Processamento da Base de Dados			x	x	
- Implementação do Software				x	x
Atividades	**Mar**	**Abr**	**Mai**	**Jun**	**Jul**
- Implementação do Software	x				
- Testes e Correções		x			
- Análise de Resultados			x	x	
- Escrita do Trabalho de Conclusão de Curso				x	x
- Defesa					x

Tabela 2: Cronograma de Atividades.

*Padrões de Sequência.

Referências

[1] Weka - data mining software in java.

[2] Srikant R. Agrawal, R. Mining sequential patterns : Generalizations and performance improvements. pages 3–17, 1996.

[3] Sandra de Amo. Curso introdutório de mineração de dados - compilação de notas de aulas. 1996.