

UTILIZAÇÃO DE TÉCNICAS DE BUSINESS INTELLIGENCE NA BASE DE CONSULTAS ESPECIALIZADAS DO SISTEMA ÚNICO DE SAÚDE.

UTILIZATION OF TECHNIQUES OF BUSINESS INTELLIGENCE IN THE BASE OF SPECIALIZED QUERIES OF UNIQUE SYSTEM OF HEALTH.

JOSÉ ARAÚJO DAMASCENO¹
PAULO VITOR DE CAMPOS SOUSA²

Abstract- This work explores the Business Intelligence techniques applied in the base of specialized queries of SUS (Unique System of Health) where classifications of the data were made and found equations that predict, from the crossing of information, the value of medical exams in a determinate space of time, becoming a work that make possible a better control of the money spend by the Health Ministry, because it shows with the results obtained through references found and with the support of the WEKA tool that it is possible to create a better strategic planning of spending the public money with the health area.

Keywords- Business Intelligence, Data Mining, WEKA, Medical Examinations By Specialties

Resumo- Este trabalho visa explorar técnicas de Business Intelligence aplicadas na base de consultas especializadas do SUS (Sistema Único de Saúde) onde foram feitas as classificações dos dados e encontradas equações capazes de predizer através do cruzamento das informações o valor de um exame médico especializado em um determinado tempo, tornando-se assim um trabalho que possibilitará um melhor controle dos gastos efetuados pelo Ministério da Saúde, pois o mesmo mostra com base nos resultados obtidos através das referências encontradas e com o auxílio da ferramenta WEKA que é possível um melhor planejamento estratégico a respeito dos gastos públicos voltados para a área da saúde.

Palavras-chave- Business Intelligence, Weka, Mineração de Dados, Exames Médicos por Especialidades

¹ Faculdade Única-Contagem -E-mail: joaraujotec@hotmail.com

² Programa De Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais – E-mail: golden-paul@informatica.esp.ufmg.br

Faculdade Única-Contagem - E-mail: paulo.vitor@unicacontagem.com.br.

1 Introdução

O ato de analisar dados e transformá-los em informações para as organizações, informações estas que se tornam o principal ativo da empresa para alcançar suas metas, torna-se cada dia mais necessário o investimento em técnicas que possibilitem a tomada de decisões. *Business Intelligence* (BI) que é a inteligência dos negócios torna cada vez mais simples tomar decisões diante de situações complexas e uma vasta gama de informações. Diante desta necessidade existe no mercado ferramentas que auxiliam a efetuar análises de maneira organizada e coerente, entre estas ferramentas encontra-se o software WEKA que possui recursos e tarefas que são capazes de definir uma linha de pensamento baseada em aprendizado supervisionados que busca definir conceitos a partir de exemplos já pré-classificados e não supervisionados, onde pela ausência da classificação usa métodos probabilísticos para simular uma experiência ocorrida. Dentro deste cenário nota-se a existência da realidade do Governo Federal Brasileiro que através do Sistema Único de Saúde (SUS) coordena dentro de sua jurisdição a saúde pública e seus respectivos exames médicos especializados. E é neste ponto que esse artigo busca através do banco de dados sobre exames médicos especializados, fornecido pelo próprio governo, analisar o cruzamento dos dados referentes a um determinado período, especialidade médica, quantidade de exames realizados e seus respectivos valores para gerar informações que sejam capazes de auxiliar na gestão da saúde pública através de, por exemplo, a estimativa de quanto será valor de um exame médico daqui a 30 anos a partir da análise dos dados atuais, podendo assim melhor organizar-se para enfrentar situações adversas tendo conhecimento que diante do cenário atual torna-se imprescindível um planejamento estratégico para todas as organizações. O restante do artigo esta organizado da seguinte forma. A seção 2 apresenta os conceitos teóricos de *Business Intelligence*, ferramentas de BI, ETL, *Data Warehouse*, *Data Mining* e exames médicos por especialidades. Na seção 3 é descrita a metodologia fornecida pela ferramenta WEKA, as formas de avaliação da base, bem como as ações que serão tomadas. Na seção 4 resultados de experimentos numéricos de avaliação de técnicas de mineração de dados são apresentados. Finalmente na seção 5 são apresentadas as conclusões.

2 Referencial Bibliográfico

Neste referencial foram levantados aspectos relevantes sobre *Business Intelligence*, ferramentas de BI, ETL e *Data Warehouse*, *Data Mining* e exames médicos por especialidades.

2.1 Business Intelligence

O conceito de *Business Intelligence* interage com a relação entre inteligência de negócios e empresarial sendo composta por um grupo de técnicas de gestão praticadas por meio de ferramentas de software que facilitam a tomadas de decisões em meio às organizações, reunindo todos os conhecimentos imprescindíveis para tais conclusões (Antonelli, 2010 apud Angeloni & Reis, 2006).

Segundo Barbieri (2001), *Business Intelligence* exemplifica a capacidade de moldar a estrutura, ter acesso e procurar informações comumente armazenadas em *Data Warehouses* e *Data Marts*.

O glossário da Gartner (Gartner Group, 2013) fundada em 1979 por Gideon Gartner, define *Business Intelligence* (BI) como um termo abrangente que inclui as aplicações, infraestrutura e ferramentas, e as melhores práticas que permitem o acesso e análise de informações para melhorar e aperfeiçoar decisões e desempenho. A partir disso pode-se dizer que *Business Intelligence* é um conjunto de ferramentas que auxiliam na aquisição de estratégias competitivas a fim de melhorar as tomadas de decisões nos negócios de uma organização.

Na figura 1 podemos observar uma imagem representativa do *Business Intelligence*.



Figura 1. Representação do Business Intelligence (Fonte: <http://blog.esfera.com.br/vantagens-business-intelligence>)

2.2 Ferramentas de Business Intelligence

No contexto atual os conceitos de dados, informação e conhecimento fazem-se necessário serem esclarecidos após a definição e importâncias do BI.

De acordo com Antonelli (2010) apud Alter et al (1996) dados são fatos, imagens ou sons que podem ou não ser relacionadas ou uteis para um serviço reservado, lembrando que um dado sozinho geralmente não tem utilidade relevante.

Já seguindo o conceito de Romney e Steinbart (2000, p.13) informações são “dados que foram preparados e processados de maneira que se tornem ex-

pressivos”, ou seja, conjunto de dados colhidos, de maneira pré-definida transformando assim dados brutos em informação plausível na tomada de decisões.

E para Alter (1996, apud Leite, 2002, p.27) conhecimento “é uma combinação de instintos, ideias, regras e procedimentos que guiam ações e decisões”. Com isso, o conhecimento auxilia a tomada de decisão.

2.3 Data Warehouse e ETL

Data Warehouse é uma coleção de dados, orientados a um assunto, integrado, tempo-variante e não volátil, para suporte ao gerenciamento dos processos de tomada de decisão (Inmon, 1997). *Data Warehouse* (DW) consiste em organizar os dados corporativos de maneira integrada, com uma única versão da verdade, histórico, variável com o tempo e gerando uma única fonte de dados, que será usada para abastecer os *Data Marts* (DM) (Cielo, 2002). Já para Bezerra et al, 2014 *Data Mart / Data Warehouse* é o local onde ficam armazenados todos os dados extraídos dos sistemas em operação. A vantagem de ter um repositório de dados à parte e a possibilidade de armazenar informações históricas e agregadas, dando suporte melhor para as análises posteriores.

Modulo de ETL (*Extract, Transform and Load*) - Componente dedicado à extração, transformação e carregamento de dados é a parte responsável pela coleta das informações nas mais diversas fontes Bezerra et al, 2014.

ETL são ferramentas fundamentais para o desenvolvimento do BI responsáveis pela elaboração dos dados a serem guardados Antonelli (2001).

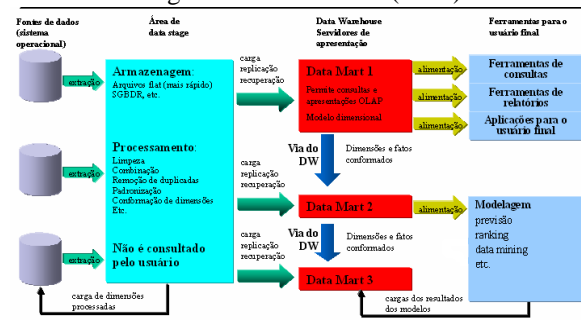


Figura 2. Elementos básicos que compõem as arquiteturas de um Data Warehouse

Fonte: <http://www.devmedia.com.br/data-warehouse/12609>

2.4 Data Mining

Data Mining ou mineração de dados são ferramentas que ajudam a detectar tendências de comportamentos dentro de uma base de dados que auxiliam em projeções futuras como a regressão (Bezerra et al 2014, apud Linoff & Berry 1997).

De acordo com Antonelli, (2010) qualquer modo que se utilize de *Data Warehouse* e *Data Marts* apenas passa a ser viável com a implementação destes

recursos de pesquisa deixando claro que a mineração de dados se dá através das seguintes fases:

Primeira fase – Preparação ou seleção: Conjunto de atividade que auxiliam na criação da base de dados;

Segunda fase – Mineração: é onde são elaborados os modelos de *Data Mining*, definindo as amostras demais dados a serem treinados no modelo;

Terceira fase – Análise: Onde são feitas as análises das informações definindo os previsores ou atributos necessários para o negócio, tendo como base para esta fase os modelos de agregação, classificação, padrões sequenciais e regras de associação.

Quarta fase – Aplicação: é quando são aplicados e acertados os algoritmos e são por fim implantados no sistema Antonelli, 2010.

Dentro da mineração de dados a figura 3 representa o processo de descoberta de conhecimento em base de dados.

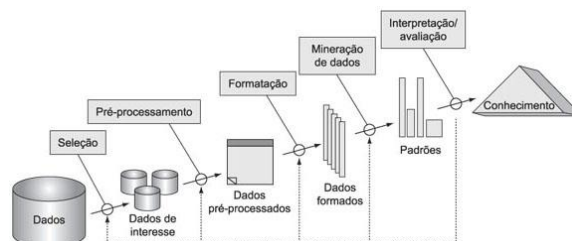


Figura 3. Representação do Processo de descoberta de conhecimento em base de dados (Fonte:

http://www.scielo.br/scielo.php?pid=S0104-530X2010000400007&script=sci_arttext)

2.5 Exames Médicos por Especialidades.

Tendo como base para estudo o relatório sobre exames médicos periciais por especialidades, disponibilizado pelo Ministério da Previdência tendo como autor o Instituto Nacional de Seguro Social (INSS) com informações sobre os principais exames médicos periciais classificados por suas variáveis como o ano, a especialidade, a quantidade de exames complementares e valor dos exames complementares. Levando em consideração que estes foram dados colhidos no período de 1988 a 2012, servindo como base para uma análise bem elaborada sobre os gastos do governo na área da saúde através do SUS (dados.gov).

A relevância deste trabalho se dá através da importância do assunto em questão tanto para o governo que pode antecipar determinado gasto futuro quanto para a população, pois os valores são pagos através dos tributos que a mesma paga, não esquecendo que o Brasil é um dos países que possui o pior retorno de valores coletados com impostos em qualidade de vida para a população (Folha, 2014). Apesar do investimento feito na área da saúde, de acordo com o Portal Brasil o Ministério da Saúde em 2013 ampliou em sete vezes os investimentos para pesquisas na área em relação ao ano de 2011 e mesmo assim, devido ao grande numero populacional, não chega a ser suficiente, pois a situação da saúde no Brasil passa por grandes dificuldades, ressaltando que não somente

nesta área, mas também na educação, segurança e economia entre outras crises que o Brasil vem enfrentando.

3 Desenvolvimento do trabalho

O desenvolvimento deste artigo esta baseado na utilização do *software* WEKA que é um conjunto de algoritmos de aprendizado de máquina para tarefas de mineração de dados sendo aplicados diretamente para um conjunto de dados ou chamado a partir de seu próprio código Java (Linguagem de programação orientada a objeto desenvolvida nos anos 90 pela *Sun Microsystems*) Luckow & Melo 2010.

O WEKA possui ferramentas para pré-processamento de dados como: classificação, regressão, *clustering* (agrupamento), regras de associação e visualização. Sendo estas ferramentas também adequadas para o desenvolvimento de novos sistemas de aprendizagem máquina, que é um desenvolvimento interessante e potencialmente de longo alcance em ciência da computação, pois permite que um programa de computador analise automaticamente uma grande massa de dados e decida quais informações são mais relevantes. Estas informações podem então ser utilizadas para fazer previsões ou para ajudar nas tomadas de decisões com rapidez e precisão. O WEKA por ser um software regido pelas diretrizes GNU (*General Public Licence*) que é a licença para software livre, possuindo assim seu código fonte aberto. Na figura 3 podemos conhecer melhor a interface do *software* Weka 2011.

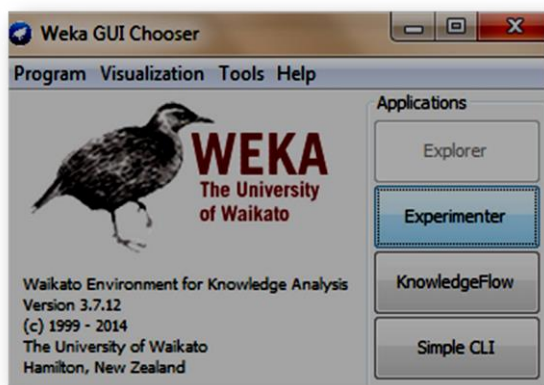


Figura 3. Tela inicial do WEKA
Fonte: Camilo, et al (2009, p 27)

O nome dado faz referência a um pássaro típico da Nova Zelândia, uma ave de natureza inquisitiva, ou seja, um *software* que busca novas informações e assim gera resultados produtivos a partir da análise efetuada em determinada base de dados.

Na figura 4, temos a tela principal onde podemos efetuar as análises referentes à nossa base.

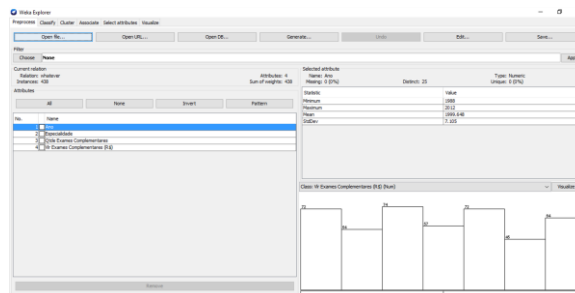


Figura 4. Tela principal do WEKA

Na figura 4, podemos observar as principais funções que são oferecidas. Para contexto do artigo presente foram abordados os processos, onde podemos observar visualmente através da equação de regressão M5Rules que será descrita nos resultados obtidos, agrupamentos (Clusters) dos dados, as principais características e valores dos atributos presentes na base. A Classificação que é a tarefa mais popular em um *Data Mining*, visa identificar a qual classe um determinado registro pertence através da verificação dos registros de outras classes já existentes, para poder classificar o novo registro através das características comparadas e assim através destas comparações conseguir gerar equações capazes de criar estimativas de várias possibilidades.

4 Resultados Obtidos

A classificação dentre muitas outras tarefas disponíveis no WEKA, o que melhor obteve resultados positivos quanto à determinação do tipo de exame a ser executado foi o *Random Tree* (Cutler & Zhao, 2001) que consiste em um algoritmo capaz de receber informações de um ano, a quantidade de exames a serem executadas neste ano e o valor total de exames pagos no respectivo ano e informar a qual tipo de especialidade esses valores pertencem.

A figura 5 mostra o resultado da análise onde o percentual de chance de acerto para os tipos de exame foi definido. Após o teste com todos os classificadores disponibilizados pelo WEKA o *Random Tree* obteve 83.3826% de acurácia para encontrar o referido fato.

```

=== Evaluation on training set ===

Time taken to test model on training data: 0 seconds

=== Summary ===

Correctly Classified Instances      369      84.2466 %
Incorrectly Classified Instances    69       15.7534 %
Kappa statistic                    0.8337
Mean absolute error                 0.0137
Root mean squared error             0.0828
Relative absolute error             16.6174 %
Root relative squared error         40.7736 %
Coverage of cases (0.95 level)     100 %
Mean rel. region size (0.95 level)  9.5493 %
Total Number of Instances          438
    
```

Figura 5. Resultado do classificador RandomTree com a melhor chance de acertos

Após um teste com todos os algoritmos de regressão disponibilizados pelo WEKA, buscando o que apresentasse o menor erro relativo absoluto encontrou-se o M5Rules (Holmes & Prank, 1999) encontrou um modelo capaz de determinar com 76,5943% de acurácia a característica quantidade de exames da base avaliada. Significa que se for informado o ano, a especialidade e o valor total dos exames será possível encontrar com 76% de chance de acertos a quantidade de consultas que serão realizadas.

Como resultados, podemos evidenciar através da equação de regressão M5Rules descrita abaixo:

=== Run information ===

Schema: weka.classifiers.rules.M5Rules -M 4.0

Relation: whatever

Instances: 438

Attributes: 4

Ano

Especialidade

Qtde Exames Complementares

Vlr Exames Complementares (R\$)

Test mode: evaluate on training data

=== Classifier model (full training set) ===

M5 pruned model rules

(using smoothed linear models) :

Number of Rules : 7

Rule: 1

IF

Especialidade=Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologia
 a Clínica,Ignorado - Perícias Médicas (Credenciadas) <= 0.5

Especialidade=Prova de Função Respirató-
 ria,Eletroencefalografia,Ecocardiograma,Tisio Pneumolo-
 gia,Otorrinolaringologia,Cicloergometria,Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas) > 0.5

Ano <= 2006.5

THEN

Qtde Exames Complementares =

-162.7909 * Ano

+ 32.764 * Especialidade=Prova de Função Respirató-
 ria,Eletroencefalografia,Ecocardiograma,Tisio Pneumolo-
 gia,Otorrinolaringologia,Cicloergometria,Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

+ 821.0713 * Especialida-

de=Eletroencefalografia,Ecocardiograma,Tisio Pneumolo-
 gia,Otorrinolaringologia,Cicloergometria,Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

- 808.784 * Especialidade=Ecocardiograma,Tisio Pneumolo-

gia,Otorrinolaringologia,Cicloergometria,Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

+ 1209.4812 * Especialida-

de=Otorrinolaringologia,Cicloergometria,Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

- 522.0683 * Especialidade=Cicloergometria,Patologia Clíni-

ca,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

+ 431.2019 * Especialidade=Patologia Clínica,Neurologia,-

,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

+ 890.4785 * Especialida-

de=Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologia Clíni-
 ca,Ignorado - Perícias Médicas (Credenciadas)

+ 896.0292 * Especialidade=Radiologia Clínica,Ignorado -
 Perícias Médicas (Credenciadas)

+ 0.0208 * Vlr Exames Complementares (R\$)

+ 325583.6756 [114/3.548%]

Rule: 2

IF

Especialidade=Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas) <= 0.5

THEN

Qtde Exames Complementares =

-143.3646 * Ano

+ 516.6061 * Especialidade=Patologia Clínica,Neurologia,-
 ,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

+ 1626.0422 * Especialida-

de=Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologia Clíni-
 ca,Ignorado - Perícias Médicas (Credenciadas)

+ 1663.2704 * Especialidade=Radiologia Clínica,Ignorado -

Perícias Médicas (Credenciadas)

+ 0.0038 * Vlr Exames Complementares (R\$)

+ 286974.787 [122/0.421%]

Rule: 3

IF

Especialida-
 de=Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologia Clíni-
 ca,Ignorado - Perícias Médicas (Credenciadas) <= 0.5

THEN

Qtde Exames Complementares =

-1034.3963 * Ano

+ 2035.5245 * Especialidade=

,Cardiologia,Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologi
 a Clínica,Ignorado - Perícias Médicas (Credenciadas)

+ 2477.8068 * Especialida-

de=Oftalmologia,Eletrocardiografia,Psiquiatria,Ortopedia,Radiologia Clíni-
 ca,Ignorado - Perícias Médicas (Credenciadas)

+ 2650.231 * Especialidade=Radiologia Clínica,Ignorado -

Perícias Médicas (Credenciadas)

+ 0.0315 * Vlr Exames Complementares (R\$)

+ 2074901.4838 [75/16.818%]

Rule: 4

IF

Ano > 2000.5

Vlr Exames Complementares (R\$) <= 38501.5

THEN

Qtde Exames Complementares =

-566.6302 * Ano

+ 3222.7997 * Especialidade=Radiologia Clínica,Ignorado -
 Perícias Médicas (Credenciadas)

+ 0.0192 * Vlr Exames Complementares (R\$)

+ 1137737.4539 [34/1.589%]

Rule: 5

IF

Especialidade=Radiologia Clínica,Ignorado - Perícias Médicas
 (Credenciadas) <= 0.5

Ano > 2000.5

THEN

Qtde Exames Complementares =

-1499.698 * Ano

+ 3871.8294 * Especialidade=Radiologia Clínica,Ignorado -
 Perícias Médicas (Credenciadas)

+ 0.0388 * Vlr Exames Complementares (R\$)

+ 3010903.2372 [22/6.713%]

Rule: 6

IF

Especialidade=Radiologia Clínica,Ignorado - Perícias Médicas
 (Credenciadas) <= 0.5

Vlr Exames Complementares (R\$) > 10.5

Vlr Exames Complementares (R\$) <= 632937

Ano <= 1995.5

THEN

Qtde Exames Complementares =

-1401.7733 * Ano

- 6373.1841 * Especialidade=Psiquiatria,Ortopedia,Radiologia
 Clínica,Ignorado - Perícias Médicas (Credenciadas)

- 2283.4019 * Especialidade=Ortopedia,Radiologia Clíni-

ca,Ignorado - Perícias Médicas (Credenciadas)

+ 5525.8423 * Especialidade=Radiologia Clínica,Ignorado -

Perícias Médicas (Credenciadas)

+ 0.0035 * Vlr Exames Complementares (R\$)

+ 2848921.4947 [21/22.059%]

Rule: 7

Qtde Exames Complementares =

-4077.5061 * Ano

+ 34901.5663 * Especialidade=Radiologia Clínica,Ignorado -
 Perícias Médicas (Credenciadas)

+ 0.048 * Vlr Exames Complementares (R\$)

+ 8153131.6871 [50/67.766%]
 Time taken to build model: 0.53 seconds
 === Evaluation on training set ===
 Time taken to test model on training data: 0.02 seconds
 === Summary ===
 Correlation coefficient 0.9301
 Mean absolute error 3803.8652
 Root mean squared error 8660.684
 Relative absolute error 23.4057 %
 Root relative squared error 36.808 %
 Total Number of Instances 438

Fonte: Dados da própria pesquisa

Além dessa equação conseguiu-se encontrar uma equação de regressão que representa o modelo para se encontrar o ano e outra para encontrar o valor total dos exames. Mostradas no quadro abaixo:

Algoritmo	Fato	Acurácia
Lazy. IBK(Aha & Albert 1991)	Ano	89.64%
Trees.S5P (Quinlan et al 1992)	Valor Total dos exames	79.8497%

Já para a tarefa de seleção de características (*select attributes*) Foram utilizados os seletores CfsSubsetEval (Hall Smith, 1998) e BestFirst (Korf, 1993) que informa o grau de características relevantes para encontrar outras características constatou que o fato mais relevante para encontrar novas características de ano, especialidade e valor de exames por especialidade o atributo quantidade de exames é quem mais influencia na obtenção de resultados relevantes sobre as demais. Sendo possível ser observado através da figura 7.

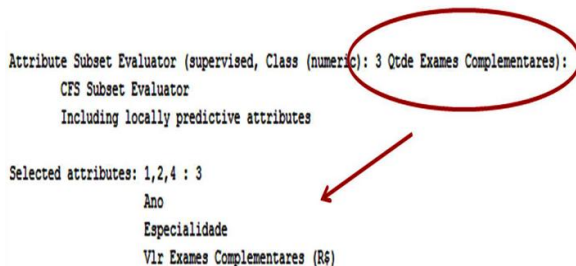


Figura 7. Representação do resultado da seleção de características.
 Fonte: Dados da própria pesquisa.

5 Conclusão

Em vista dos aspectos mencionados fica explícita a importância da *Business Intelligence* na tomada de decisões para as organizações diante de um cenário onde disputa por melhores resultados esta cada vez mais acirrada. Sendo assim, através de uma elaboração e análise eficiente de uma base de dados pode-se então chegar a uma tomada de decisão capaz de munir a organização com ferramentas e técnicas capazes de dar um suporte real e assim também sanar ou amenizar futuros riscos. A mineração de dados torna-se cada dia mais importantes no âmbito organi-

zacional em que se tem cada dia mais o aumento das bases de dados ficando inviável uma melhor análise destes sem tais recursos, a fim de tomar decisões mais acertadas. Neste primeiro contexto onde foram focados os problemas de organização e previsão de cursos do governo na área da saúde pública através das informações obtidas nas análises onde o grande impacto ocasionado foi no setor financeiro, através da contribuição fornecida pelos modelos de classificação, regressão, agrupamento e seleção de melhores características tornando assim possível a realização e obtenção destes resultados.

A utilização destas técnicas torna-se imprescindível, ficando em aberto um leque de oportunidades para trabalhos futuros onde podem ser analisados os dados a fim de atender outras possíveis demandas em relação ao controle e gerenciamento não somente na área da saúde, mas também nas demais áreas, além disso, pode-se implementar em um sistema informatizado as equações de regressão encontradas neste trabalho.

Referências Bibliográficas

- AHA, David W.; KIBLER, Dennis; ALBERT, Marc K. Instance-based learning algorithms. *Machine learning*, v. 6, n. 1, p. 37-66, 1991.
- ANTONELLI, Ricardo Adriano. *Conhecendo o Business Intelligence (BI).CAP Accounting and Management*, v. 3, n. 3, p. 79-85, 2010.
- BARBIERI, Carlos. *BI-Business Intelligence-Modelagem & Tecnologia*. Rio de, 2001.
- BEZERRA, Alessandro Augusto et al. *BUSINESS INTELLIGENCE: uma perspectiva de soluções aplicadas no contexto da Gestão da Informação*.
- CAMILO, Cássio Oliveira; SILVA, João Carlos da. *Mineração de dados: Conceitos, tarefas, métodos e ferramentas*. Goiânia: Universidade Federal de Goiás, 2009.
- CIELO, Iva Rafael. *Etl: Extração, transformação e carga de dados*. 2002.
- CUTLER, Adele; ZHAO, Guohua. *Pert-perfect random tree ensembles*. *Computing Science and Statistics*, v. 33, p. 490-497, 2001.
- DARÓS, Leandro Luís; BRASIL, Marcos Alexandre Damonin; BORGERT, Altair. *A contribuição de uma ferramenta de business intelligence na gestão de custos: a experiência do Estado de Santa Catarina*. In: *Anais do Congresso Brasileiro de Custos-ABC*. 2005.
- Exames Médicos Periciais por Especialidade. Disponível em :<<http://dados.gov.br/dataset/exames-medico-periciais-por-especialidade>>. Acessado em : 18 ago. 2015.
- Folha UOL. *Mercado/Brasil é o pior em retorno de impostos a população, aponta estudo*. Disponível em:<<http://www1.folha.uol.com.br/mercado/2014/04/1434959-brasil-e-o-pior-em-retorno-de->

- imposto-a-populacao-aponta-estudo.shtml>
Acessado em: 01 out. 2015.
- GARTNER IT Glossary. Business Intelligence (BI). Disponível em: <http://www.gartner.com/it-glossary/business-intelligence-bi/>. Acessado em: 01 out. 2015.
- HALL, Mark A.; SMITH, Lloyd A. Practical feature subset selection for machine learning. 1998.
- HOLMES, Geoffrey; HALL, Mark; PRANK, Eibe. Generating rule sets from model trees. Springer Berlin Heidelberg, 1999.
- INMON, William H. Como construir o data warehouse. Campus, 1997
- KORF, Richard E. Linear-space best-first search. Artificial Intelligence, v. 62, n. 1, p. 41-78, 1993.
- LUCKOW, Décio Heinzelmann; DE MELO, Alexandre Altair. Programação Java para a WEB. Novatec Editora, 2010.
- Scielo. Técnicas de mineração visual de dados aplicadas aos dados de instrumentação da barragem de Itaipu. Disponível em: <http://www.scielo.br/scielo.php?pid=S0104-530X2010000400007&script=sci_arttext>. Acessado em: 01 out. 2015.
- Portal Brasil. Ministério da Saúde amplia em sete vezes investimentos em pesquisas. Disponível em: <<http://www.brasil.gov.br/saude/2013/12/ministerio-da-saude-amplia-em-sete-vezes-investimentos-em-pesquisas>>. Acessado em: 01 out. 2015.
- QUINLAN, John R. et al. Learning with continuous classes. In: 5th Australian joint conference on artificial intelligence. 1992. p. 343-348.
- SGUARIO DOS REIS, E.; ANGELONI, M. T. Business intelligence 2006.
- WEKA, W. E. K. A. 3: data mining software in Java. University of Waikato, Hamilton, New Zealand (www.cs.waikato.ac.nz/ml/weka), 2011.