

PROCESSO DE DESCOBERTA DE CONHECIMENTO EM BASES DE DADOS: UMA NOVA ABORDAGEM SOBRE CLASSIFICAÇÃO DE RISCO EM UNIDADES DE PRONTO ATENDIMENTO

João Paulo Funchal¹; Diana Francisca Adamatti²; Cleo Zanella Billa³.

Resumo

O presente trabalho tem como objetivo apresentar um estudo sobre mineração de dados no contexto da classificação de risco em unidades de pronto atendimento. Este trabalho é a continuidade de outros dois, iniciados ainda em 2014, sendo assim, foi realizado no Hospital Universitário Dr. Miguel Riet Corrêa Júnior, em Rio Grande (RS), com dados coletados de pacientes no período entre o ano de 2012 e 2013. Utilizou-se a técnica de árvores de decisão, tendo em vista sua ampla utilização em problemas de classificação e também com o intuito de tornar-se uma ferramenta para um sistema de apoio à decisão mais alinhado com o conhecimento do profissional de saúde. O resultado obtido neste trabalho é relevante, considerando a taxa de instancias classificadas corretamente em torno de 70%, as regras obtidas tornam os resultados mais precisos e alinhados com o conhecimento do profissional.

Palavras-chave: Mineração de dados, Classificação de risco, Descoberta de conhecimento.

Abstract

The present study aims to present a study on data mining in the context of risk classification in emergency care units. This work is a continuation of the other two, which began in 2014, and was conducted at the University Hospital Dr. Miguel Riet Corrêa Júnior, in Rio Grande (RS), with data collected from patients in the period between 2012 and 2013. The decision tree technique was used, considering its wide use in classification problems and also with the intention of becoming a tool for a decision support system more in line with the knowledge of the health professional. The result obtained in this work is relevant, considering the rate of instances correctly classified around 70%, the rules obtained make the results more accurate and in line with the professional's knowledge. Keywords: Data mining, Risk classification, Knowledge discovery.

Keywords: Data mining, Risk classification, Knowledge discovery.

Introdução

A utilização de Inteligência Artificial, mais especificamente de sistemas especialistas ou de apoio a decisão, na área de saúde não é recente. Ao longo dos anos, diversos trabalhos abordaram esse tema. Todavia, estes normalmente focam na questão do diagnóstico, tanto no âmbito da medicina como da enfermagem (TALON, 2013), (FARIAS, 2013), (TEIXEIRA, 2012), (SELLMER, 2013), (LICHTENSTEIN, 2011), (MEDEIROS, 2014), (TENÓRIO, 2011). No contexto do pronto atendimento, que é a etapa anterior ao diagnóstico, ou seja, o

¹ Mestrando em Engenharia de Computação pela Universidade Federal do Rio Grande - FURG; E-mail: joaofunchal@furg.br.

² Profa. Dra. do Centro de Ciências Computacionais - C3. Universidade Federal do Rio Grande - FURG; E-mail: dianaadamatti@furg.br.

³ Prof. Dr. do Centro de Ciências Computacionais - C3 pela Universidade Federal do Rio Grande - FURG; E-mail: cleo.billa@gmail.com.

processo de acolhimento e classificação de risco dos pacientes, foi encontrado apenas um trabalho relacionado a esta área (Maciel et al., 2015), onde foi utilizado para mineração a técnica de classificação árvores de decisão com o algoritmo j48 (QUINLAN, 1993), também utilizados neste trabalho. Porém, com algumas diferenças em relação as técnicas de pré-processamento dos dados e principalmente o número mínimo de objetos por folha definido no software Weka (WEKA, 2015).

Ao encontro deste fato, a técnica conhecida como Árvores de decisão se destaca por ser amplamente utilizada em sistemas de tomada de decisão aplicados a saúde, tendo em vista o seu rápido aprendizado de conceitos e facilidade de implementação (MEDEIROS, 2014), (TENÓRIO, 2011).

Atualmente, ao ingressar no pronto atendimento do Hospital Universitário Dr. Miguel Riet Corrêa Jr, situado na cidade de Rio Grande (RS) e uma das unidades da Universidade Federal do Rio Grande (FURG), o paciente passa por um processo de triagem de risco, no qual, através de um sistema informatizado, o profissional de saúde define qual a prioridade para o seu atendimento. Esse sistema tem por objetivo registrar os dados vitais e sintomas do paciente, deixando totalmente a cargo de quem o acolhe definir esta prioridade. Inserido nesse escopo, o presente trabalho possui como objetivo principal melhorar a avaliação dos dados inseridos, diminuindo as etapas para a classificação e garantindo ao profissional de saúde um apoio na sua tomada de decisão.

1 Classificação de Risco

A classificação de risco, ou triagem, tem por objetivo a regulação da demanda do atendimento nos serviços de pronto atendimento, visando identificar o atendimento médico imediato e o mediato, organizando assim o fluxo de pacientes que procuram estas unidades (DOS SANTOS, 2014), (SERVIN, 2014). Apesar do excesso de demanda que sofrem esse tipo de unidades hospitalares, utilizando deste processo de triagem são minimizados os riscos para os pacientes que as procuram (ALBINO, 2007). Nesse sentido, a avaliação com a classificação de risco visa a agilidade no atendimento dos pacientes, de acordo com um protocolo e o grau da necessidade do indivíduo, não somente considerando a ordem de chegada.

A implantação da classificação de risco em todas as unidades de pronto atendimento é proposta pela portaria 2048/2009 do Ministério da Saúde, onde esse processo de classificação deve ser realizado por profissional de saúde, de nível superior, via de regra um enfermeiro, com

treinamento específico e se valendo de protocolos de acolhimento previamente estabelecidos (MINISTÉRIO DA SAÚDE, 2002).

No protocolo proposto pelo SUS (Sistema Único de Saúde), utilizado neste trabalho, mediante o julgamento crítico e experiência do enfermeiro, o paciente pode ser classificado nas seguintes cores (DOS SANTOS, 2014):

- VERMELHO: emergência, o atendimento será realizado imediatamente na sala de emergências;
- AMARELO: urgência terá o atendimento priorizado sobre os pacientes classificados como VERDE, no consultório ou leito da sala de observação;
- VERDE: sem risco de morte imediato, tendo o atendimento realizado depois que todos os pacientes classificados como VERMELHO e AMARELO forem atendidos;
- AZUL: quadro crônico sem sofrimento agudo ou caso social, deverá ser preferencialmente encaminhado para atendimento em Unidade Básica de Saúde ou atendido pelo Serviço Social.

Por fim, é importante salientar que essa prática não se caracteriza pelo diagnóstico da doença, mas sim pela determinação da prioridade de atendimento, de acordo com a gravidade do paciente (SERVIN, 2014).

1.1 Sistema do Hospital Universitário da FURG

O presente sistema de classificação de risco foi implantado em Julho de 2012 no Serviço de Pronto Atendimento (SPA) do Hospital Universitário Dr. Miguel Riet Corrêa Jr da FURG, sendo inicialmente baseado no protocolo de acolhimento do SUS (DOS SANTOS, 2014). Todavia, o sistema permite que os enfermeiros responsáveis pelo serviço de pronto atendimento cadastrem novos sintomas, os relacionem a qualificadores. Por fim, os enfermeiros podem definir sua classificação, permitindo assim que o mesmo se adapte a realidade local.

Neste sistema, a interface de classificação de risco é dividida em quatro etapas distintas: inicialmente, o enfermeiro registra os dados básicos do paciente, conforme ilustrado na Figura 1.

Figura 1 - Primeira etapa da classificação, informações básicas

The screenshot shows a web interface with three tabs: 'Dados do paciente', 'Dados vitais', and 'Classificação'. The 'Dados do paciente' tab is active. It contains the following fields:

- Número de registro: 112106
- Nome: MARIA DA SILVA
- Sexo: Masculino Feminino
- Nascimento: 02/01/2001
- Atend. Anteriores: 2
- Procedência: Espontânea
- Peso: []
- Prontuário: []
- Queixa: DOR, EDEMA, PRURIDO E SECREÇÃO PURULENTA NOS OLHOS
- Histórico: []
- Obs. do enfermeiro: []
- Hist.de alergias: NÃO
- Medicações em uso: LAVAGEM COM S.F.
- Pessoa para contato: []
- Telefone / email: []

Fonte: Autores

Em seguida, de acordo com a Figura 2, são informados ao sistema os dados vitais do paciente, sua escala de dor e de coma (escala de Glasgow).

Figura 2 - Segunda etapa da classificação, dados vitais

The screenshot shows the 'Dados vitais' tab active. It displays the following vital signs:

PA: 100 / 60 mmHg FC: 97 bpm FR: 24 mrpm SPO2: 100 % TAX: 35,5 °C HGT: [] mg/dl Dor: []

Below the vital signs is a pain scale from 0 to 10. The scale is divided into three levels: LEVE (0-2), MODERADA (3-5), and INTENSA (6-10). Each level has corresponding smiley face icons.

Below the pain scale is the Glasgow scale with three dropdown menus:

- Abertura ocular: Espontânea
- Resposta verbal: Orientada
- Resposta motora: Obedece comandos

Fonte: Autores

Na sequência, como apresentado na Figura 3, o profissional pode escolher os sintomas que ele identifica no paciente (quadro azul da esquerda) e seus respectivos qualificadores (quadro verde da direita). Nessa etapa é possível marcar diversos sintomas e qualificadores.

Figura 3 - Terceira etapa da classificação, definição de sintomas e qualificadores.

The screenshot shows a software interface with three tabs: 'Dados do paciente', 'Dados vitais', and 'Classificação'. The 'Classificação' tab is active. It is divided into two main sections: 'Sintomas / Queixas / Evento:' and 'Qualificadores:'. The 'Sintomas' section has a blue header and contains a list of symptoms with checkboxes. The 'Qualificadores' section has a green header and contains a list of qualifiers with checkboxes. In the 'Sintomas' list, 'Choque' and 'Diabetes' are checked. In the 'Qualificadores' list, 'Alteração do estado mental (letargia, confusão mental, agitação, coma)', 'Dados vitais alterados', and 'Taquicardia' are checked.

Sintomas / Queixas / Evento:	Qualificadores:
<input type="checkbox"/> Afecções de pele e subcutâneo	<input type="checkbox"/> Alteração do estado de consciência
<input type="checkbox"/> Alteração aguda do estado neurológico e relato de convulsão, desmaio ou síncope	<input checked="" type="checkbox"/> Alteração do estado mental (letargia, confusão mental, agitação, coma)
<input type="checkbox"/> Cefaléia	<input type="checkbox"/> Bradicardia
<input checked="" type="checkbox"/> Choque	<input checked="" type="checkbox"/> Dados vitais alterados
<input type="checkbox"/> Coma	<input type="checkbox"/> Dados vitais normais
<input type="checkbox"/> Dados vitais alterados com sintomas	<input type="checkbox"/> Glicemia <= 250mg/dl e assintomático
<input checked="" type="checkbox"/> Diabetes	<input type="checkbox"/> Glicemia > 250mg/dl e assintomático
<input type="checkbox"/> Distúrbios psiquiátricos e abstinência de álcool e drogas	<input type="checkbox"/> Glicemia >250 mg/dl e sinais de desidratação
<input type="checkbox"/> Dor cervical, dorsal, lombar ou em extremidades, sem história de trauma	<input type="checkbox"/> Hipotensão
<input type="checkbox"/> Dor Torácica	<input type="checkbox"/> História de diabetes e precisando de medicação (receita)
<input type="checkbox"/> Feridas, abscessos, mordeduras e acidentes com animais peçonhentos	<input type="checkbox"/> Sudorese profusa (hipoglicemia)
<input type="checkbox"/> Hipertensão	<input checked="" type="checkbox"/> Taquicardia
<input type="checkbox"/> Insuficiência Respiratória	
<input type="checkbox"/> Intoxicações Agudas (via dérmica)	

Fonte: Autores

Por fim, como ilustrado na Figura 4, o sistema contabiliza o número de classificadores relacionados aos qualificadores selecionados (número entre parênteses) e dependendo do maior número, sugere uma classificação. No entanto, a decisão final fica a cargo do profissional de saúde, que tem a possibilidade de escolher a classificação que considere mais relevante para o caso

Figura 4 - Quarta etapa da classificação, definição do classificador e registro.

The screenshot shows a window titled 'Classificar'. It features four radio buttons for color-coded classifications: 'VERMELHO (3)' (red), 'AMARELO (0)' (yellow), 'VERDE (0)' (green), and 'AZUL (0)' (blue). The 'AMARELO (0)' option is selected. Below the radio buttons is a text input field labeled 'Justificativa:'. Underneath that is a dropdown menu labeled 'Encaminhamento:' with the selected option 'Clínico Geral (acima de 12 de idade)'. At the bottom of the window is a button labeled 'Registrar Classificação'.

Fonte: Autores

O sistema de classificação de riscos do SPA vem sendo utilizado desde 27/07/2012, já tendo sido registradas 74.075 atendimentos, com uma média de um atendimento registrado a cada 15 minutos.

2 Mineração de Dados

A mineração de dados é o processo de descoberta automática de informações úteis em grandes depósitos de dados (TAN, 2009). Segundo o autor, há alguns desafios específicos que motivaram a origem e o desenvolvimento da mineração de dados, entre os quais estão: escalabilidade, alta dimensionalidade, dados complexos e heterogêneos, propriedade e distribuição de dados e análises não tradicionais.

As tarefas de mineração de dados são divididas em duas categorias: tarefas de previsão e tarefas descritivas. As tarefas de previsão têm como objetivo prever o valor de um atributo baseado em valores de outros atributos. O atributo que será previsto é denominado de variável dependente ou alvo, enquanto as variáveis independentes ou explicativas são as denominações usadas para os atributos utilizados para a previsão. As tarefas descritivas são, por vezes, de natureza exploratória e necessitam de técnicas de pós-processamento para explicar os resultados.

2.1 Classificação

A classificação abarca inúmeras aplicações e consiste em organizar objetos em categorias pré-definidas. A tarefa de classificação possui dados de entrada que constituem um conjunto de registros, onde cada registro pode ser denominado como instância ou exemplo. Modelos de classificação são necessários para modelagem descritiva, nas quais seria possível distinguir objetos e classes diferentes e modelagem preditiva o qual poderia prever rótulo da classe de registros desconhecidos. Essas técnicas de classificação são muito utilizadas para categorias nominais ou binárias, por não considerarem a ordem entre as categorias.

As técnicas de classificação constituem uma sistemática para elaborar modelos de classificação originados de um conjunto de dados de entrada. Podem servir como exemplos, classificadores baseados em regras, redes neurais, classificadores de árvores de decisão, entre outros. Cada técnica utiliza um algoritmo de aprendizagem, o qual é utilizado para construção de modelos que saibam prever rótulos de classes de registros desconhecidos (TAN, 2009).

2.2 Árvores de decisão

A árvore de decisão é um classificador simples, contudo muito utilizado. Ela possui uma estrutura hierárquica, constituída por nós e arestas. Um desses nós é o nó raiz, no qual não há a presença de arestas que chegam. Além disso, a árvore possui nós internos, nos quais chegam

uma aresta somente e duas ou mais arestas saem. Há também a presença na árvore dos nós folha ou terminais, que possuem somente uma aresta que chega.

Na técnica de árvore de decisão “cada nós folha recebe um rótulo de classe. Os nós não terminais, que incluem o nós raiz e outros nós internos, contêm condições de testes de atributos para separar registros que possuam características diferentes” (TAN, 2009).

Existem alguns algoritmos desenvolvidos para a indução de árvores de decisão de precisão razoável, os quais aplicam estratégias do melhor atributo para dividir os dados. O algoritmo de ID3 (Quinlan, 1986) é um exemplo desses algoritmos e constitui o eixo de muitos algoritmos existentes no processo de induzir árvores de decisão.

2.3 Matriz de confusão

“A avaliação do desempenho de um modelo de classificação é baseada nas contagens de registros de testes previstos correta e incorretamente pelo modelo” (TAN, 2009). Esta contagem é informada em forma de tabela conhecida como matriz de confusão. Uma matriz de confusão fornece informações necessárias para definir se um modelo de classificação é válido (TAN, 2009). Os valores classificados corretamente se encontram na diagonal principal da matriz, através desta diagonal é que se pode observar quão precisa foi a avaliação do modelo.

3 Resultados

Nessa seção será apresentado o resultado obtido ao longo do trabalho. Para o resultado encontrado foi aplicado a técnica de árvores de decisão com o algoritmo j48 (QUINLAN, 1993), utilizando como configuração de teste o *cross-validation* com 9 grupos para treinamento e 1 para validação, com o número mínimo de objetos por folha de 500, esta a quantidade mínima de separação de dados por ramificação. O conjunto de atributos utilizado é descrito na Tabela 1 abaixo.

Tabela 1 - Atributos escolhidos para classificação

Atributo	Descrição	Menor valor	Maior valor
dt nascimento	Idade do paciente	0	109
cd sexo	Sexo do paciente	-	-
pas	Pressão arterial sistólica	0	300
pad	Pressão arterial diastólica	0	220
fc	Frequência cardíaca	1	210
fr	Frequência respiratória	1	80
spo2	Saturação parcial de oxigênio	8	200
vl temp axila	Temperatura	31	41
sintoma	Sintomas informado e/ou obtidos do	-	-
classificador registrado	Classificador registrado para o paciente	-	-

Fonte: Elaborada pelos autores.

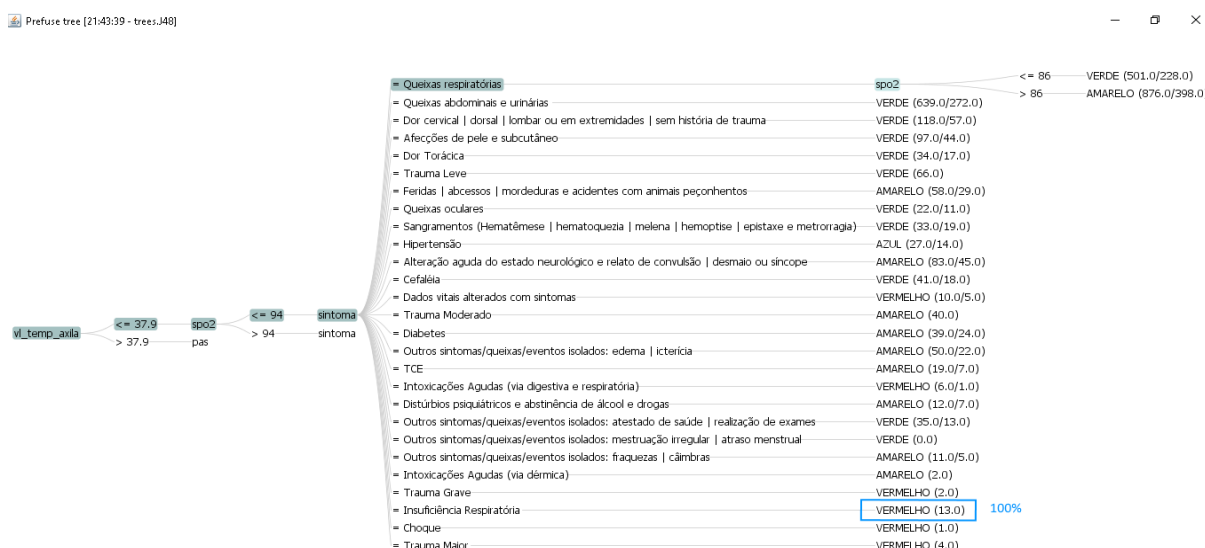
Tabela 2 - Relação de registros por classificadores com todos os registros

Classificador	Nº registros	%
Vermelho	551	1,00
Amarelo	8.791	20,60
Verde	2.7859	65,36
Azul	5.422	12,72
Total	42.623	100,00

Fonte: Elaborada pelos autores.

A árvore de decisão gerada utilizando todos os registros da base é apresentada nas Figuras 5,6, 7, seguido pelo seu resultado e sua matriz de confusão, que são apresentados na Figura 8. Na Figura 5, é destacado a regra que classifica o paciente com prioridade máxima (vermelho), onde o mesmo tendo dado entrada no pronto atendimento com as seguintes informações obtidas no atendimento, temperatura menor ou igual a 37,9, saturação parcial de oxigênio menor ou igual a 94, e o sintoma apresentado sendo de insuficiência respiratória.

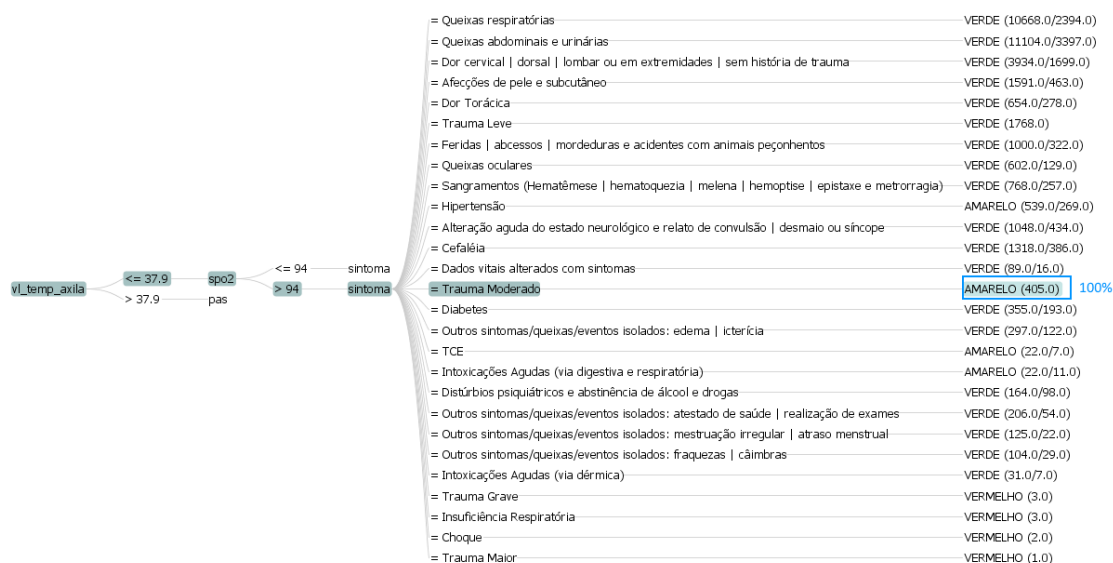
Figura 5 - Árvore de decisão a esquerda do nó raiz



Fonte: Autores

Na Figura 6, destacamos a regra que classifica o paciente com o segundo maior grau de prioridade (amarelo), onde o mesmo tendo dado entrada no pronto atendimento com as seguintes informações obtidas no atendimento, temperatura menor ou igual a 37,9, saturação parcial de oxigênio superior a 94, e o sintoma apresentado de trauma moderado.

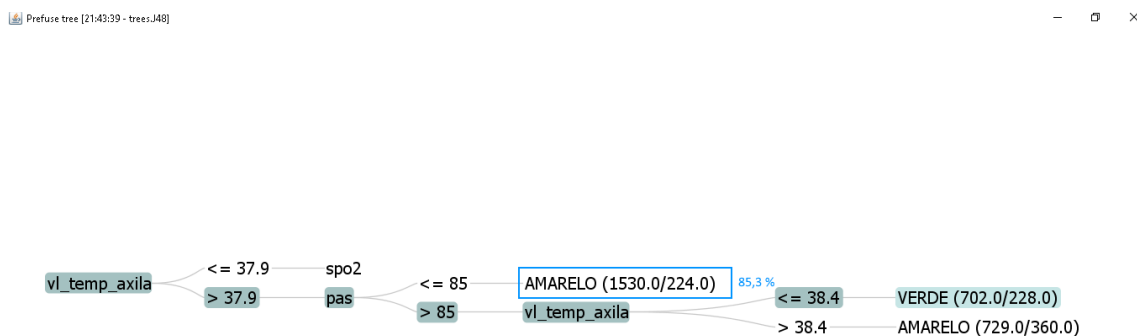
Figura 6 - Árvore de decisão a esquerda do nó raiz



Fonte: Autores

Na Figura 7, a regra que classifica o paciente também com o segundo maior grau de prioridade (amarelo), onde o mesmo tendo dado entrada no pronto atendimento com as seguintes informações obtidas no atendimento, temperatura superior a 37,9, pressão arterial sistólica inferior ou igual a 85, com 85,3% de acertos na classificação.

Figura 7 - Árvore de decisão a direita do nó raiz.



Fonte: Autores

Na Figura 8, podemos observar que o número de instâncias classificadas corretamente na árvore, atinge pouco mais de 70% e também apresenta a diagonal principal na matriz de confusão os maiores valores de suas respectivas colunas para cada atributo, sendo esta uma boa métrica de avaliação deste modelo. Também se percebe na avaliação da matriz de decisão, que os registros classificados com maior prioridade em vermelho, são classificados de modo

errôneo em casos menos graves como amarelo em apenas 9 registros (primeira linha - a, última coluna - d). Em relação as medidas de precisão, neste primeiro momento estamos considerando apenas as medidas de “*precision*”, “*recall*” e “*F-Measure*” para avaliação do nosso modelo.

A medida de precision se refere ao número amostras positivas classificadas corretamente sobre o total de amostras positivas, e a medida de recall representa amostras positivas classificadas corretamente sobre o total de amostras **classificadas** como positivas, a medida F-measure corresponde a média harmônica entre as medidas precision e recall. Considerando a média de precisão em 67,9%, e um recall médio de 70,2%, com a F-measure em 62,7%, sabendo que se pode melhorar estes índices, estas medidas nos dão suporte para afirmar que o sistema pode se tornar mais qualificado na proporção em que as mesmas forem melhorando ao longo da pesquisa.

Figura 8 - Árvore de decisão a direita do nó raiz.

```

Correctly Classified Instances      29925      70.2086 %
Incorrectly Classified Instances    12698      29.7914 %
Kappa statistic                    0.2398
Mean absolute error                0.2174
Root mean squared error            0.3299
Relative absolute error            84.5904 %
Root relative squared error        92.041 %
Total Number of Instances          42623

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
      0,332   0,039   0,689     0,332   0,448     0,396   0,760    0,542    AMARELO
      0,002   0,000   0,529     0,002   0,003     0,024   0,700    0,242    AZUL
      0,968   0,769   0,704     0,968   0,815     0,313   0,694    0,795    VERDE
      0,069   0,000   0,776     0,069   0,127     0,229   0,857    0,198    VERMELHO
Weighted Avg.  0,702   0,511   0,679     0,702   0,627     0,292   0,711    0,665

=== Confusion Matrix ===

  a    b    c    d  <-- classified as
2922  5  5855  9 |  a = AMARELO
 295  9  5118  0 |  b = AZUL
 901  0  26956  2 |  c = VERDE
 125  3   385  38 |  d = VERMELHO

```

Fonte: Autores

4 Conclusão

A análise da classificação de risco é muito importante para a otimização do sistema de saúde, pois com ela pode-se agilizar os processos, tornar mais justo e mais eficiente o atendimento ao paciente.

Percebe-se que ainda é imprescindível um estudo mais aprofundado do problema e da configuração da árvore de decisão, para obtenção de melhores resultados, sendo assim este objetivo pode ser considerado como uma hipótese ainda sem uma conclusão correta.

O modelo apresentando possui um ganho relativamente importante para os estudos na área, em comparação com o trabalho anterior (Funchal; Adamatti, 2015), é nítido o ganho de informação nos resultados, porém cabe salientar que o atributo sintoma ainda precisa ser melhor trabalhado para que possa tornar ainda menor o conjunto de regras sem alterar o ganho de classificação. Sendo assim acredito que este modelo ainda necessite de alguns ajustes para que então seja possível mapear o conhecimento do profissional de saúde.

Como trabalhos futuros, pretende-se utilizar outros algoritmos, incluindo não apenas técnicas de classificação como também de regressão. Além de explorar novos atributos e tabelas do banco. Reavaliar os dados utilizando os valores de sintomas e qualificadores, buscando um maior apoio dos profissionais da classificação de risco, para então poder realizar uma análise mais completa e conclusiva, auxiliando na tomada de decisão. Também se pretende utilizar dados atuais do SPA (2015 e 2016), já que atualmente o sistema se encontra mais maduro em termos de usabilidade.

Referências

- ALBINO, R. M. Classificação de risco: Uma necessidade inadiável em um serviço de emergência de qualidade. **Arquivos Catarinenses de Medicina**, 36(4), 2007.
- DOS SANTOS, É. A. **Acolhimento com classificação de risco**. 2014.
- FARIAS, E. P. **Uso de sistema especialista no auxílio ao diagnóstico por meio de escalas de apoio à enfermagem**. 2013.
- FUNCHAL, J. P.; MADSEN, C. A. C.; DAMATTI, D. F. Classificação automática de dados para descoberta de conhecimento: um estudo de caso para classificação de risco na área da saúde. **Revista Brasileira de Computação Aplicada**, 7(2):41–51, 2015.
- LICHTENSTEIN, F. Sistemas de apoio à decisão baseados em diretrizes interpretadas por computador: um breve histórico e outros tópicos. **Journal of Health Informatics**, 3(4), 2011.
- MACIEL, T. V. et al.. Mineração de dados em triagem de risco de saúde. **Revista Brasileira de Computação Aplicada**, 7(2), 2015.
- MEDEIROS, A. R. C. Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo. **Saude em debate**, 38(100), 2014.
- MINISTÉRIO DA SAÚDE. **Portaria n° 2048**, de 5 de novembro de 2002, 2002.
- QUINLAN, R. **Induction of decision trees**. *Machine Learning*, 1(1):81–106, 1986.

_____. **C4.5: Programs for Machine Learning**. Morgan Kaufmann Publishers, SanMateo, CA, 1993.

SELLMER, D. Sistema especialista para apoiar a decisão na terapia tópica de úlceras venosas. **Revista Gaúcha de Enfermagem**, 34(2), 2013.

SERVIN, S. C. N. **Protocolo de acolhimento com classificação de risco**. 2014.

TALON, A. F. **Inteligência artificial aplicada à medicina**. 2013.

TAN, P. **Introdução ao data mining**. Rio de Janeiro: Ciência Moderna, 2009.

TEIXEIRA, M. J. C. Os contributos dos sistemas de apoio à tomada de decisão para a prática de enfermagem. **Journal of Health Informatics**, 4(2), 2012.

TENÓRIO, J. M. Sistemas de apoio a decisões clínicas, inteligência artificial, gastroenterologia. **Journal of Health Informatics**, 3(1), 2011.

WEKA. **Weka 3: Data mining software in java**, 2015.