

Um Estudo Sobre a Classificação de Risco na Área da Saúde Utilizando Árvores de Decisão

João Paulo S. Funchal¹, Diana F. Adamatti¹

¹Centro de Ciências Computacionais –Universidade Federal do Rio Grande (FURG)
Rio Grande – RS – Brasil

funchaljoaopaulo@hotmail.com, dianaada@gmail.com

Abstract. *This paper presents a study on data mining in the context of risk rating in emergency units. This work was done at Dr. Miguel Riet Corrêa Júnior University Hospital, in Rio Grande (RS), with data collected between 2012 and 2013. We have used the decision tree technique, given its wide use in classification problems as well as to become a tool to be a support decision system closer to the knowledge of health professionals. However, it is essential to emphasize that the decision to take the risk of the patient's life come from the technical knowledge and experience of these professionals. The results this work, there were tests with four case studies in the database, where the extracted knowledge has shown that health professionals (in this case, nurses) do not have a standard risk classification for emergency care patients ready.*

Resumo. *O presente artigo tem como objetivo apresentar um estudo sobre mineração de dados no contexto da classificação de risco em unidades de pronto atendimento. Este trabalho 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. Foi utilizada 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. Todavia, é imprescindível ressaltar que a tomada de decisão do risco de vida do paciente vem do conhecimento técnico e experiência deste profissional. Como resultados desse trabalho, realizaram-se testes com quatro estudos de caso na base de dados, onde o conhecimento extraído mostrou que os profissionais de saúde (no caso, enfermeiros) não tem um padrão de classificação de risco para os pacientes em pronto atendimentos.*

1.INTRODUÇÃO

No decorrer dos anos, é cada vez mais expressiva a quantidade de dados que as organizações estão acumulando, e isso só foi possível devido aos avanços na tecnologia de coleta e armazenamento de dados. Todavia, se o conjunto dos dados for muito grande, as ferramentas e as técnicas tradicionais de análise desses dados muitas vezes não podem ser usadas. Sendo assim, se faz necessário desenvolver novos métodos de mineração de dados, a qual consiste em uma área de pesquisa da Inteligência Artificial.

“A mineração de dados é uma tecnologia que combina métodos tradicionais de análise de dados com algoritmos sofisticados para processar grandes volumes de

dados”, como afirma [Tan et al. 2009]. A mineração de dados constitui um processo de descoberta de informações em grandes depósitos de dados, contudo, nem todo o processo de descoberta de dados é considerado mineração de dados.

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 et al. 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 processo de acolhimento e classificação de risco dos pacientes, foi encontrado apenas um trabalho relacionado a esta área [Maciel et al. 2015], onde foram aplicadas técnicas similares de mineração como árvores de decisão e o algoritmo j48 [Quinlan 1993], também utilizados neste trabalho. Porém, com algumas diferenças em relação aos filtros utilizados 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. Esta etapa de classificação, muitas vezes torna-se demorada devido as muitas informações que são coletadas do paciente para poder definir sua classificação e isto afeta diretamente o ambiente do hospital, gerando nervosismo a quem ainda aguarda pela classificação de risco.

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.

Para atingir o objetivo proposto, foi necessário coletar os dados da base de dados do hospital, identificar quais eram os melhores atributos desta base para então utilizar estes registros. O software escolhido para mineração de dados foi o WEKA [WEKA 2015], que possui uma coleção de algoritmos específicos para mineração de dados. Neste contexto, foi utilizada a técnica de Árvores de decisão, mais especificamente o algoritmo J48 [Quinlan 1993]. Após a utilização da técnica, foram obtidos resultados em diferentes cenários, com diferentes percentuais de acerto.

2.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 [Servin 2014, dos Santos 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.

Neste entendimento, o acolhimento com avaliação e classificação de risco configura-se como uma das intervenções potencialmente decisivas na reorganização e realização da promoção da saúde em rede, pois se faz a partir da análise, problematização e proposição da própria equipe, que se constitui como sujeito do seu processo de trabalho. Em sua implementação, o acolhimento, extrapola o espaço de gestão local afirmando, no cotidiano das práticas em saúde, a coexistência das macro e micropolíticas.[Ministério da Saúde 2004]

O sistema de acolhimento com classificação de risco foi desenvolvido na Austrália por volta da década de 90, onde foram utilizados cinco níveis de classificação dos pacientes e o tempo de espera é variado [Júnior 2012]. No Brasil, um dos hospitais pioneiros a adotar essa forma de atendimento foi o Hospital Municipal Dr. Mário Gatti, em Campinas (SP), o qual implantou o sistema no ano de 2000, após receber convite do Ministério da Saúde, que possuía como objetivo implantar um programa de humanização nos hospitais brasileiros.

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].

2.1. 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. Por exemplo, atualmente o sintoma Diabetes está configurado de acordo com a Tabela 1.

Tabela 1. Exemplo de qualificadores e seus classificadores para o sintoma Diabetes.

Sintoma	Qualificador	Classificador
Diabetes	Sudorese profusa (hipoglicemia)	VERMELHO
	Alteração do estado mental (letargia, confusão mental, agitação, coma)	VERMELHO
	Dados vitais alterados	VERMELHO
	Glicemia >250 mg/dl e sinais de desidratação	AMARELO
	Dados vitais normais	AMARELO
	Glicemia > 250mg/dl e assintomático	VERDE
	Glicemia <= 250mg/dl e assintomático	Azul
	História de diabetes e precisando de medicação (receita)	Azul

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.

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 a software interface with three tabs: 'Dados do paciente', 'Dados vitais', and 'Classificação'. The 'Dados vitais' tab is active, displaying input fields for various vital signs: PA: 100 / 60 mmHg, FC: 97 bpm, FR: 24 mrpm, SPO2: 100 %, TAX: 35,5 °C, HGT: mg/dl, and Dor: . Below the inputs is a horizontal risk scale from 0 to 10. The scale is divided into three zones: 'LEVE' (0-2), 'MODERADA' (3-5), and 'INTENSA' (6-10). Each zone contains a corresponding smiley face icon. Below the scale is a 'Glasgow' section with three dropdown menus: 'Abertura ocular:' set to 'Espontânea', 'Resposta verbal:' set to 'Orientada', and 'Resposta motora:' set to 'Obedece comandos'.

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 the 'Classificação' tab of the software interface. It is divided into two main panels. The left panel, titled 'Sintomas / Queixas / Evento:', contains a list of symptoms with checkboxes. Selected items include 'Choque' and 'Diabetes'. The right panel, titled 'Qualificadores:', contains a list of qualifiers with checkboxes. Selected items include 'Alteração do estado mental (letargia, confusão mental, agitação, coma)', 'Dados vitais alterados', and 'Taquicardia'.

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.

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.

O sistema foi modificado recentemente e adaptado para tratar os casos de pacientes

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

Classificar

VERMELHO (3)

AMARELO (0)

VERDE (0)

AZUL (0)

Justificativa:

Encaminhamento:

Registrar Classificação

gestantes já que são classificadas separadamente, surgiu a necessidade de ser adaptado uma nova forma de classificar essas pacientes.

Um dos problemas do sistema atual, está no número de passos necessários para o enfermeiro tomar a decisão sobre a classificação do paciente, isto nos remete a outro possível problema em relação a falta de padrão dos enfermeiros sobre a decisão de classificar os pacientes.

3. MINERAÇÃO DE DADOS

"A mineração de dados é o processo de descoberta automática de informações úteis em grandes depósitos de dados" [Tan et al. 2009]. Suas técnicas agem em expressivas quantidades de bancos de dados para localizar padrões úteis, os quais poderiam ser imperceptíveis.

Segundo [Tan et al. 2009], 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.

3.1. 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. Conforme [Tan et al. 2009], são formados por dupla(x,y), no qual o x caracteriza o conjunto de atributos e y o atributo especial, conhecido como rótulo da classificação e atributo alvo ou de categorização. "Classificação é a tarefa de aprender uma função alvo f que mapeie cada conjunto de atributos x para um dos rótulos de classes y pré-determinados" [Tan et al. 2009].

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 et al. 2009].

3.2. 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 et al. 2009].

"Uma árvore de decisão toma como entrada um objeto ou situação descritos por um conjunto de atributos e retorna uma 'decisão', o valor de saída previsto, de acordo com a entrada. Os atributos de entrada podem ser discretos ou contínuos. No momento, supomos entradas discretas. O valor de saída também pode ser discreto ou contínuo; a aprendizagem de uma função de valores discretos é chamada aprendizagem de classificação; a aprendizagem de uma função contínua é chamada de regressão. Vamos nos concentrar na classificação booleana, em que cada exemplo é classificado como verdadeiro (positivo) ou falso (negativo)"
[Russell and Norvig 2004]

A decisão, na árvore de decisão, ocorre devido a uma sequência de testes que são executados. Na árvore, cada nó diz respeito a um teste do valor de uma das propriedades, e os valores possíveis do teste correspondem às ramificações do nó. "Cada nós folha na árvore especifica o valor a ser retornado se aquela folha for alcançada." [Russell and Norvig 2004]. 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 Hunt é um exemplo desses algoritmos e constitui o eixo de muitos algoritmos existentes no processo de induzir árvores de decisão.

3.3. Matriz de confusão

"A avaliação do desempenho de um modelo de classificação é baseada nas contagens de registros de testes previstos corretamente e incorretamente pelo modelo" [Tan et al. 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 et al. 2009]. A Figura 5 apresenta um exemplo de matriz de

confusão. Os valores classificados corretamente se encontram na diagonal principal da matriz, através desta diagonal é que pode-se observar quão precisa foi a avaliação do modelo.

Figura 5. Matriz de confusão

```

a b c <-- classified as
50 0 0 | a = Iris-setosa
0 49 1 | b = Iris-versicolor
0 5 45 | c = Iris-virginica
  
```

4.RESULTADOS OBTIDOS

Nessa seção são apresentados os resultados obtidos ao longo do trabalho. Para todos os resultados foram aplicados 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. O conjunto de atributos utilizado é descrito na Tabela 2.

Tabela 2. 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
glasgow_ocular	Abertura Ocular	1	4
glasgow_verbal	Resposta verbal	1	5
glasgow_motora	Resposta motora	1	6
vl_temp_axila	Temperatura	31	42
id_classificador_registrado	Classificador registrado para o paciente	-	-

Nas seguintes subseções, para um melhor entendimento dos resultados, serão detalhados os experimentos e esclarecidas as melhores regras obtidas nas árvores de decisão geradas.

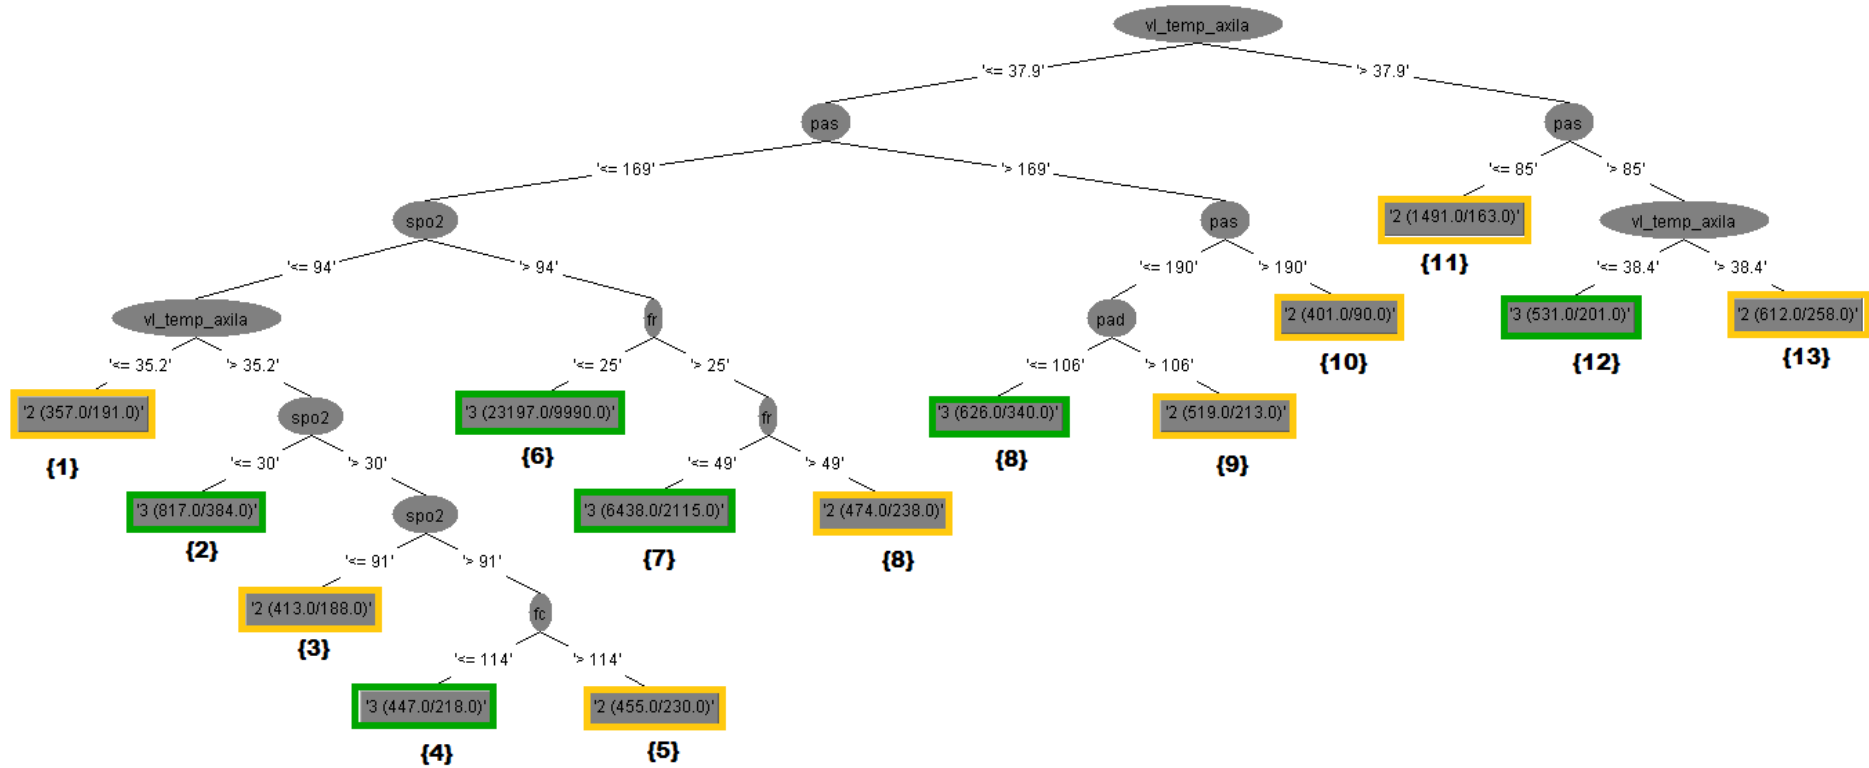
4.1. Estudo de caso 1: Utilizando todos registros, com um total de 55.167 pacientes

Tabela 3. Relação de registros por classificadores com todos registros.

Classificador	Nº registros	%
VERMELHO	577	1
AMARELO	12.600	22.8
VERDE	30.024	54.4
AZUL	11.966	21.7
TOTAL	55.167	100

A árvore de decisão gerada utilizando todos registros da base é apresentada na Figura 7, seguido pelo seu resultado e sua matriz de confusão, que são apresentados na Figura 6. Em sua configuração no Weka, foi definido o número mínimo de objetos por folha para 500, que é a quantidade mínima de separação de dados por ramificação.

Figura 6. Árvore de decisão gerada com todos registros.



Pode-se observar que a árvore é construída apenas classificando os pacientes como Verdes e Amarelos. Nesta árvore, não foi encontrando o padrão de maior prioridade (Vermelho) e tão pouco o padrão de menor prioridade (Azul). Como esta representação é feita a partir dos dados treinados e testados com todas instâncias, possivelmente se notará alguma diferença nos valores com a matriz de confusão gerada. Seguindo o caminho 11 da árvore, pode-se observar que a árvore parte do nó raiz valor da temperatura do paciente sendo maior que 37,9, pressão arterial sistólica menor ou igual a 85 e classifica como prioridade Amarelo, com menor precedência apenas que os pacientes vermelhos. Nota-se que foram 1491 instancias relacionadas a esta folha da árvore, sendo 163 relacionados de forma errada.

Figura 7. Matriz de confusão geral

```

=== Summary ===

Correctly Classified Instances      32812      59.4776 %
Incorrectly Classified Instances    22355      40.5224 %
Kappa statistic                    0.1818
Mean absolute error                 0.2722
Root mean squared error             0.3692
Relative absolute error              90.0751 %
Root relative squared error          94.975 %
Total Number of Instances          55167

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
                -----  -----  -
                0.94    0.797    0.585     0.94    0.721     0.611     3
                0      0         0         0         0         0.729     1
                0.002  0.001    0.446     0.002    0.005     0.646     4
                0.361  0.054    0.666     0.361    0.468     0.709     2
Weighted Avg.   0.595    0.446    0.567     0.595    0.501     0.642

=== Confusion Matrix ===

  a  b  c  d  <-- classified as
28233  0  32 1759 |  a = 3
  312   0  0  265 |  b = 1
11682  0  29  255 |  c = 4
 8046  0  4  4550 |  d = 2

```

Na matriz de confusão é possível observar que apesar de acertar 59.4776%, não se encontra o classificador de maior prioridade, pois a diagonal principal da matriz de confusão não possui os maiores valores de suas colunas, demonstrando que a árvore não encontrou o melhor padrão.

4.2. Estudo de caso 2: Resultados com registros balanceados

Percebendo que havia uma diferença muito grande em relação a classificação dos pacientes, onde existiam poucos casos graves comparado aos demais casos, optou-se por balancear os registros com o objetivo de obter a mesma quantidade de classificadores. Este balanceamento foi feito diretamente no banco de dados, via comando SQL. Após gerado o arquivo já com os registros, foram selecionados manualmente o mesmo número de registros para todos os casos, ordenados de forma aleatória, e utilizando o comando

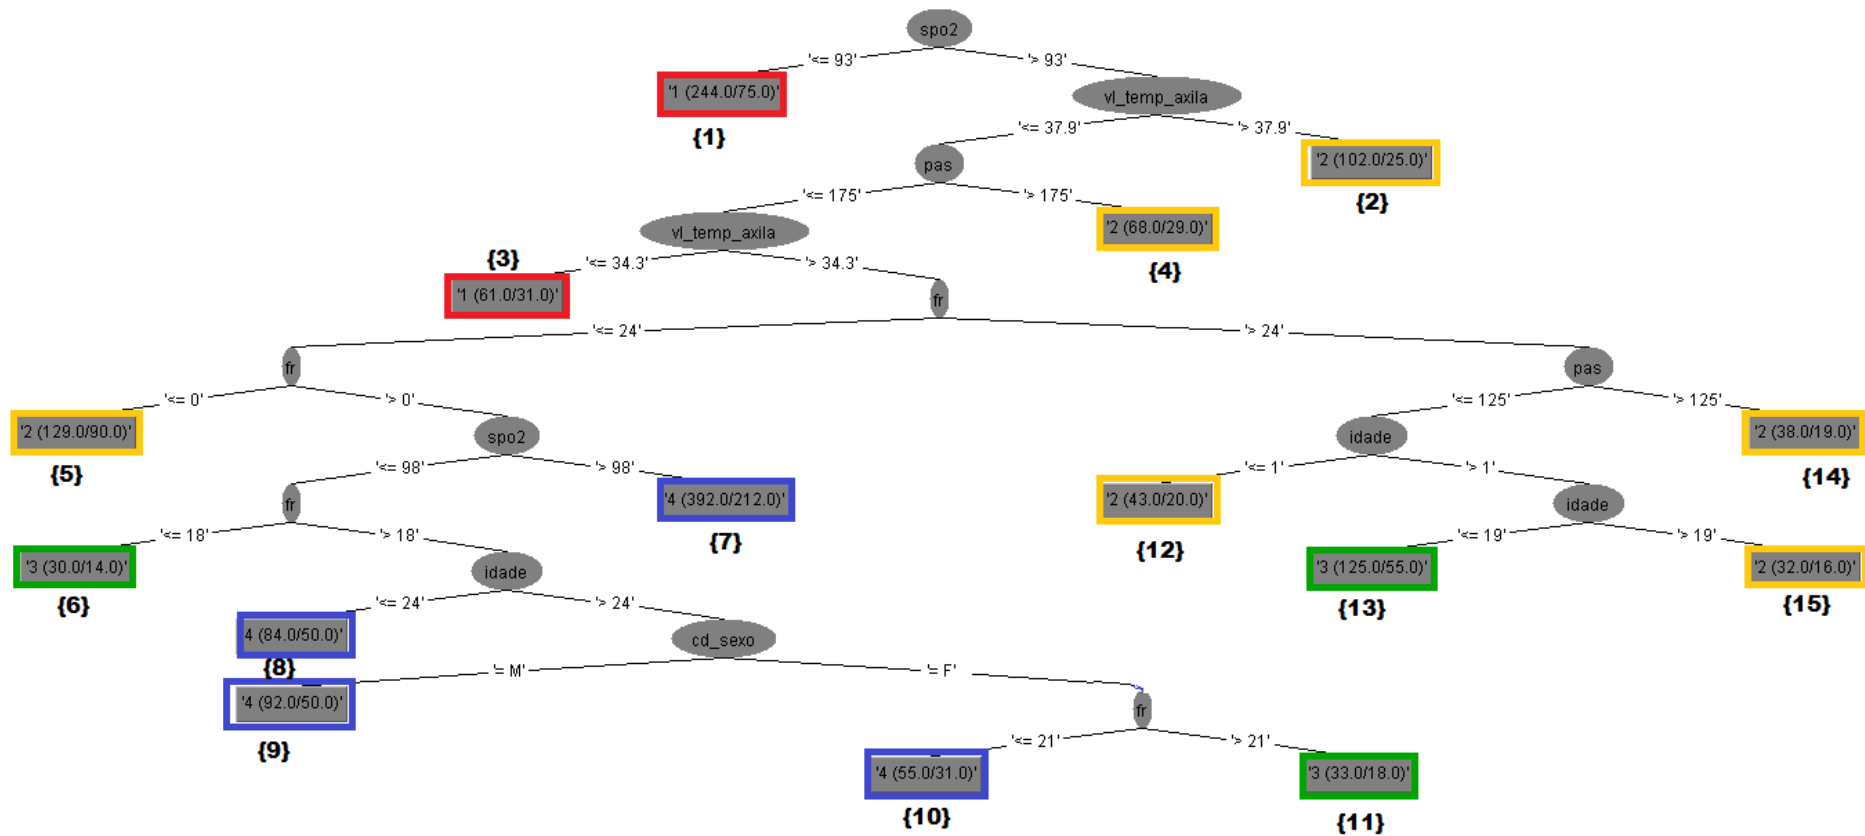
"union" para cada conjunto dos classificadores.

Tabela 4. Relação de registros por classificadores com registros balanceados.

Classificador	Nº registros	%
VERMELHO	577	25
AMARELO	577	25
VERDE	577	25
AZUL	577	25
TOTAL	2.308	100

Os resultados são apresentados nas Figuras 8 e 9. O total de registros balanceados foram de 2.308 e número mínimo de objetos por folha foi de 30. Na Figura 8, onde está representada a árvore de decisão, pode-se observar um comportamento bem diferente da árvore com todos registros, sendo possível encontrar todos os casos de classificação. Nota-se no caminho 2, por exemplo, que ao invés de partir o nó raiz da temperatura, a árvore inicia com a saturação parcial de oxigênio como nó mais relevante e que contém maior valor de informação para árvore, classificando no caminho 2 como amarelo o paciente que estiver com a saturação parcial de oxigênio maior que 93 e uma temperatura maior que 37,9. Nesse caminho, foram classificados 102 registros, sendo 25 classificados de forma errada.

Figura 8. Árvore de decisão com dados balanceados.



Pode-se perceber na Figura 9, onde está representada a matriz de confusão dos dados balanceados, que o percentual de acerto foi inferior aos resultados com todos registros. Também nota-se que o número total de registros é inferior ao informado, visto que na seleção e limpeza dos dados utilizando a ferramenta desenvolvida para geração de arquivos arff é feito um pré-processamento, onde são removidos registros que possuam valores com anomalias (valores fora do padrão ou com muitos valores faltantes). Portanto, o total de registros utilizados para mineração no WEKA, neste estudo de caso, foram de 2.295 instâncias, com uma taxa de acerto de 46.6231%. Nota-se que a diagonal principal da matriz possui os maiores valores de sua coluna, porém é alto o número de erros.

Figura 9. Matriz de confusão dados balanceados.

```

=== Summary ===

Correctly Classified Instances      1070      46.6231 %
Incorrectly Classified Instances    1225      53.3769 %
Kappa statistic                    0.2881
Mean absolute error                 0.3198
Root mean squared error             0.4065
Relative absolute error              85.2727 %
Root relative squared error          93.8829 %
Total Number of Instances          2295

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
                -----  -----  -
                0.512    0.113    0.597     0.512    0.552     0.743     1
                0.688    0.336    0.407     0.688    0.512     0.731     4
                0.459    0.164    0.485     0.459    0.472     0.688     2
                0.206    0.1     0.41      0.206    0.275     0.632     3
Weighted Avg.   0.466    0.178    0.474     0.466    0.452     0.698

=== Confusion Matrix ===

  a  b  c  d  <-- classified as
289 129 112 34 | a = 1
 33 397  63 84 | b = 4
104 155 265 53 | c = 2
 58 294 106 119 | d = 3

```

4.3. Estudo de caso 3: Registros separados por turnos

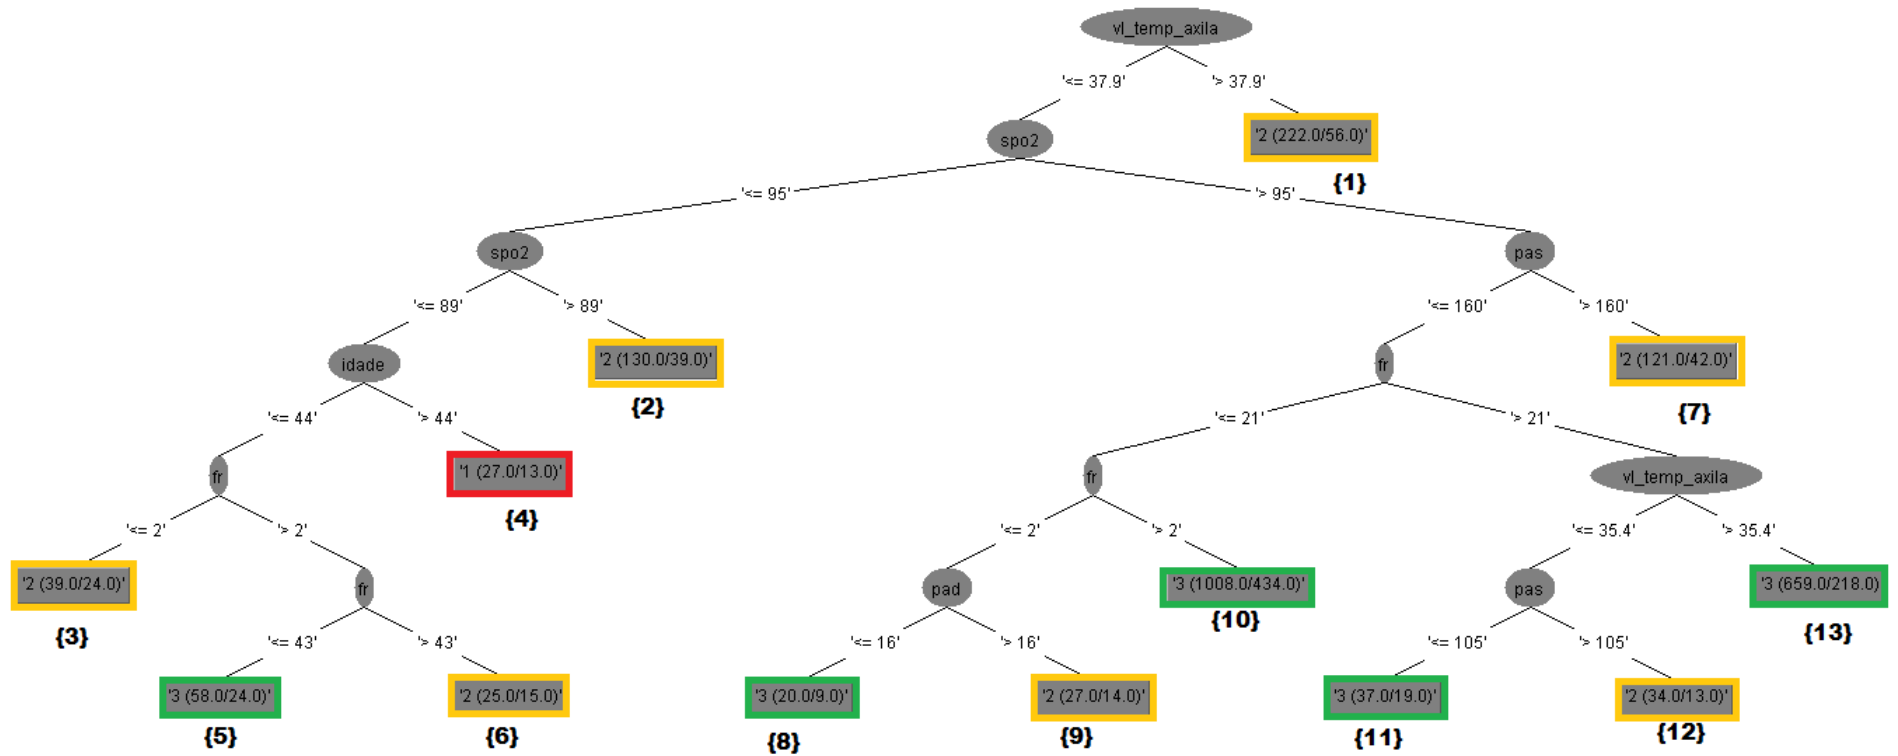
Nesta etapa, foram divididos os registros em turnos, sendo que a maior motivação para este estudo de caso foi a suspeita de que a maioria de casos graves registrados eram classificados durante o período da madrugada, onde a procura pelo pronto atendimento também era relativamente menor do que durante o dia. Durante a divisão dos turnos, ficou definido sendo o turno da manhã os registros inseridos entre as 06h00min até 11h59min; turno da tarde com registros entre 12h00min até 17h59min; turno da noite entre 18h00min até 23h59min; e turno da madrugada entre 00h00min até 05h59min. Neste estudo de caso, é apresentado o melhor resultado obtido, para o turno da Madrugada. Pode-se observar que o número total de registros é inferior ao informado, visto que na seleção e na limpeza dos dados, como informado anteriormente, foram removidos registros que estivessem fora dos padrões.

Tabela 5. Relação de registros por classificadores no turno da Madrugada.

Classificador	Nº registros	%
VERMELHO	128	3.55
AMARELO	1.188	32.9
VERDE	1.846	51.14
AZUL	448	12.5
TOTAL	3.610	100

A árvore gerada para este estudo de caso é apresentada na Figura 10. Para configuração desta árvore foi utilizado o número mínimo de instâncias de 20 e a taxa de acerto é igual a 60%. Nota-se pelo caminho 1, onde 222 instâncias são relacionadas a folha classificada com prioridade Amarelo, com 56 registros classificados de forma errada.

Figura 10. Árvore de decisão turno da madrugada



Observando a Figura 11, percebe-se que a matriz de confusão teve uma melhora significativa nos resultados. A diagonal principal possui os maiores valores das colunas, inclusive na coluna "d", onde a árvore erra para resultados próximos, que seriam os casos que deveriam ter sido classificados como Vermelho, e foram classificados como Amarelo. Também nota-se que nenhum registro classificado como azul (menor prioridade) foi encontrado. Uma possível explicação é o fator ambiente, já que durante a madrugada existe uma menor procura por atendimento, e conseqüentemente um maior cuidado com quem chega ao SPA.

Figura 11. Matriz de confusão turno da madrugada.

```

=== Summary ===

Correctly Classified Instances      2166
Incorrectly Classified Instances    1444
Kappa statistic                    0.2512
Mean absolute error                 0.2707
Root mean squared error            0.3703
Relative absolute error            88.2049 %
Root relative squared error        94.5521 %
Total Number of Instances          3610

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
          0.444    0.121    0.643     0.444    0.525     0.702     2
          0.881    0.642    0.589     0.881    0.706     0.651     3
          0         0         0         0         0         0.685     4
          0.102    0.005    0.406     0.102    0.163     0.718     1
Weighted Avg.   0.6     0.368    0.528     0.6     0.54     0.675

=== Confusion Matrix ===

  a  b  c  d  <-- classified as
527 649 0 12 | a = 2
216 1626 0 4 | b = 3
22 423 0 3 | c = 4
54 61 0 13 | d = 1

```

4.4. Estudo de caso 4: Resultados de registros por enfermeiro

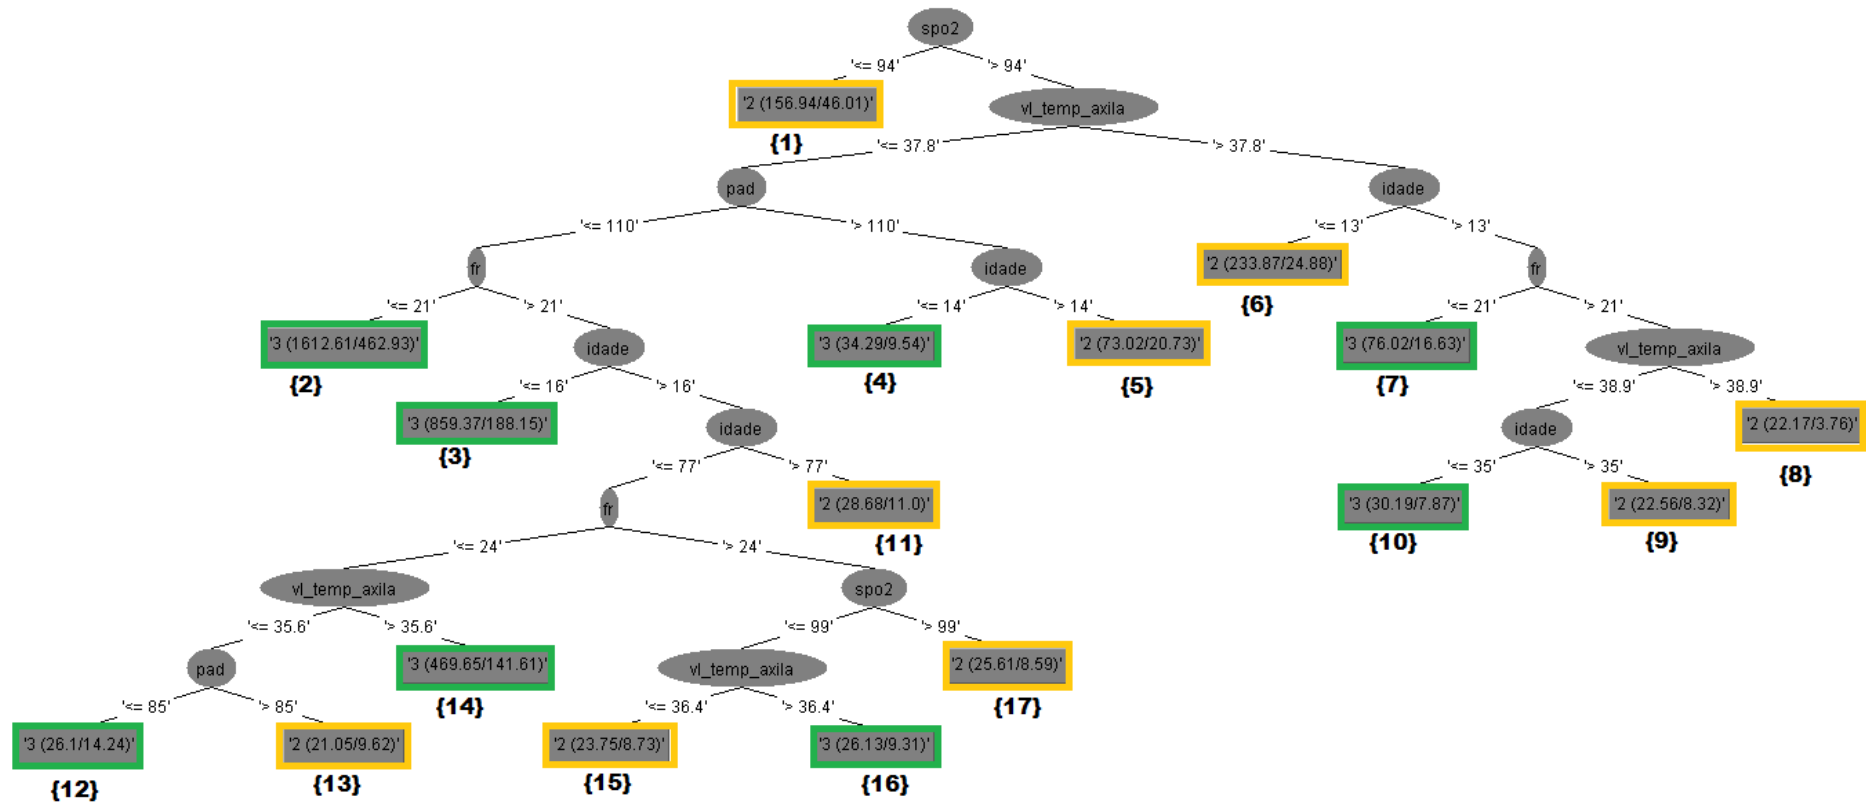
Neste estudo de caso foram separados os registros por enfermeiros que tenham classificado mais 2.000 pacientes. No total, foram 6 enfermeiros selecionados para esse estudo de caso. Este estudo tem basicamente como objetivo analisar o padrão com que os profissionais classificam os pacientes. Será apresentado o resultado com melhor percentual de acerto na matriz de confusão, ou seja, do enfermeiro identificado como 129505 (que é seu identificador no banco de dados).

Tabela 6. Relação de registros por classificadores do enfermeiro 129505.

Classificador	Nº registros	%
VERMELHO	41	1.1
AMARELO	988	26.4
VERDE	2.398	64.1
AZUL	315	8.4
TOTAL	3.742	100

Na Figura 12 apresenta a árvore de decisão gerada. Nota-se que apenas foram encontrados registros classificados como prioridade Amarelo e Verde. Os casos muito graves e com menor prioridade não são encontrados. Utilizando o caminho 6 da árvore, partindo do nó raiz sendo a saturação parcial de oxigênio sendo maior que 94, a temperatura corporal maior que 37,8 e a idade menor ou igual a 13, obtêm-se a classificação Amarelo, segunda maior prioridade, com 233.87 registros classificados nesta folha, sendo 24.88 classificados de forma errada.

Figura 12. Árvore de decisão enfermeiro identificado como 129505



A Figura 13 apresenta a matriz de confusão. Pode-se notar que a taxa de acerto é de 72.0203%, mas não foram encontrados os resultados graves (Vermelhos) e os de menor prioridade (Azuis).

Figura 13. Matriz de confusão enfermeiro 129505.

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      2695      72.0203 %
Incorrectly Classified Instances    1047      27.9797 %
Kappa statistic                    0.3259
Mean absolute error                 0.2114
Root mean squared error             0.3268
Relative absolute error             82.4597 %
Root relative squared error         91.3089 %
Total Number of Instances          3742

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
                -----  -----  -
                0         0         0           0         0           0.68      4
                0.951    0.674    0.716      0.951    0.817      0.681     3
                0.419    0.051    0.746      0.419    0.537      0.748     2
                0         0         0           0         0           0.622     1
Weighted Avg.   0.72     0.446    0.656      0.72     0.665      0.698

=== Confusion Matrix ===

 a  b  c  d  <-- classified as
0  310  5  0 | a = 4
0  2281 117  0 | b = 3
0  574  414  0 | c = 2
0  22  19  0 | d = 1

```

4.5. Análise dos Estudos de Caso

Nesse trabalho, foram realizados quatro estudos de caso a partir dos dados coletados no Hospital Universitário - HU vinculado a Universidade Federal do Rio Grande - FURG. A tabela 7 apresenta de forma resumida os resultados dos estudos de caso realizados.

Tabela 7. Relação de acerto nos estudos de caso

	Taxa de acerto %	Nº Registros
Estudo de caso 1	59.47%	55.167
Estudo de caso 2	46.62%	2.308
Estudo de caso 3	60%	3.610
Estudo de caso 4	72.02%	3.742

No primeiro estudo de caso, o experimento foi realizado com todos os registros da base e teve uma taxa de acerto de 59.47%. Como já apresentado anteriormente, em sua configuração no WEKA, foi definido o número mínimo de objetos por folha para 500, que é a quantidade mínima de separação de dados por ramificação.

No segundo estudo de caso, foi feito um balanceamento dos registros, ou seja, selecionando o mesmo número de registros de cada classificador, ficando em um total de 2308 registros. Neste estudo de caso, a taxa de acerto da árvore caiu para 46,62%. Em sua

configuração foi utilizado o número mínimo de objetos por folha igual a 30.

Para o terceiro estudo de caso, os registros foram separados em turnos com intervalos entre manhã (06:00hrs-11:59hrs), Tarde (12:00hrs-17:59hrs), Noite (18:00hrs-23:59hrs), Madrugada (00:00hrs-05:59hrs). Foi apresentado apenas os resultados do turno da madrugada, no total 3610 instâncias, na configuração da árvore foi utilizado 20 no número mínimo de objetos, e para estudo obtivemos uma taxa de acerto de 60%.

No quarto estudo de caso, os registros foram divididos por enfermeiros que haviam classificado acima de 2000 pacientes. Foi selecionado para apresentar neste estudo o enfermeiro que obteve o melhor resultado, com a taxa de acerto de 72.02%. Pode-se observar pelo quarto estudo de caso que há a falta de um padrão dos enfermeiros para classificação dos pacientes. Nota-se que isto influencia muito nos resultados, o que dificulta para a árvore de decisão encontrar associações.

5. CONCLUSÕES

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. Portanto, é necessário ressaltar que a questão de que sintomas e quais dos seus respectivos qualificadores foram selecionados, não são considerados neste estudo, tendo em vista que seu objetivo é verificar se uma árvore de decisão teria a capacidade de mapear o conhecimento do profissional de enfermagem, utilizando somente os dados vitais do 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.

Trabalhar em conjunto com os profissionais do pronto atendimento seria de extrema relevância para a obtenção de melhores resultados, buscando uma forma de avaliar os fatores externos que influenciam na sua tomada de decisão, procurando descobrir o porquê de não seguirem um padrão.

Foi possível perceber neste trabalho, que um dos problemas mais graves no SPA, que são as filas, estão diretamente ligados aos processos de atendimento e não ao sistema que as classifica. Tornar mais dinâmico o sistema talvez não seria suficiente, diminuir as etapas de triagem até poderá diminuir o tempo de atendimento, mas não irá garantir a melhor classificação do paciente, porque esta tem influência direta do enfermeiro, e muito provavelmente a triagem do paciente estará seguindo o padrão de classificação do profissional.

Como trabalhos futuros, pretende-se considerar outras métricas de avaliação dos resultados como o recall e precision das árvores geradas. 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 pretende-se utilizar dados mais atuais do SPA (2014 e 2015), já que atualmente o sistema se encontra mais maduro em termos de usabilidade.

Outro trabalho a ser realizado é a comparação entre as regras de classificação deste trabalho com as regras utilizadas hoje pelo sistema, e verificar se os resultados conferem com os quais atualmente são sugeridos.

Referências

- [Albino 2007] Albino, R. M. (2007). Classificação de risco: Uma necessidade inadiável em um serviço de emergência de qualidade. *Arquivos Catarinenses de Medicina*, 36(4).
- [dos Santos 2014] dos Santos, É. A. (2014). Acolhimento com classificação de risco. Disponível em: <https://goo.gl/xh4Lkh>. Acesso em: 01 fev. 2016.
- [Farias et al. 2013] Farias, E. P., Sassi, R. J., and Soares, E. D. (2013). Uso de sistema especialista no auxílio ao diagnóstico por meio de escalas de apoio à enfermagem. Disponível em: <https://goo.gl/4I5gPr>. Acesso em: 06 set. 2016.
- [Júnior 2012] Júnior, J. A. B. (2012). Implantação do sistema acolhimento com classificação e avaliação de risco e uso do fluxograma analisador. *Texto & Contexto - Enfermagem*, 21(1).
- [Lichtenstein 2011] Lichtenstein, F. (2011). Sistemas de apoio à decisão baseados em diretrizes interpretadas por computador: um breve histórico e outros tópicos. *Journal of Health Informatics*, 3(4).
- [Maciel et al. 2015] Maciel, T. V., Seus, V. R., Borges, E. N., and dos Santos Machado, K. (2015). Mineração de dados em triagem de risco de saúde. *Revista Brasileira de Computação Aplicada*, 7(2).
- [Medeiros 2014] Medeiros, A. R. C. (2014). Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo. *Saude em debate (SCIELO)*, 38(100).
- [Ministério da Saúde 2002] Ministério da Saúde (2002). Portaria nº 2048, de 5 de novembro de 2002. Disponível em : <http://goo.gl/2zkO5z>. Acesso em: 26 set. 2014.
- [Ministério da Saúde 2004] Ministério da Saúde (2004). Acolhimento com avaliação e classificação de risco: Um paradigma ético-estético no fazer em saúde. Disponível em: <http://bvsm.s.saude.gov.br/bvs/publicacoes/acolhimento.pdf>. Acesso em: 26 set. 2014.
- [Quinlan 1993] Quinlan, R. (1993). *C4.5: Programs for Machine Learning* . Morgan Kaufmann Publishers, San Mateo, CA.
- [Russell and Norvig 2004] Russell, S. and Norvig, P. (2004). *Inteligência artificial*, volume 2. Campus, Rio de Janeiro.
- [Sellmer 2013] Sellmer, D. (2013). Sistema especialista para apoiar a decisão na terapia tópica de úlceras venosas. *Revista Gaúcha de Enfermagem*, 34(2).
- [Servin 2014] Servin, S. C. N. (2014). Protocolo de acolhimento com classificação de risco. Disponível em: <https://goo.gl/N1R1JV>. Acesso em: 01 mar. 2016.
- [Talon 2013] Talon, A. F. (2013). Inteligência artificial aplicada à medicina. Disponível em: <http://www.fatecbauru.edu.br/ojs/index.php/CET/article/view/76/70>. Acesso em: 26 set. 2014.
- [Tan et al. 2009] Tan, P.-N., Steinbach, M., and Kumar, V. (2009). *Introdução ao data mining*. Ciência Moderna, Rio de Janeiro.
- [Teixeira 2012] Teixeira, M. J. C. (2012). Os contributos dos sistemas de apoio à tomada de decisão para a prática de enfermagem. *Journal of Health Informatics*, 4(2).

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

[WEKA 2015] WEKA (2015). Weka 3: Data mining software in java. Disponível em: <http://www.cs.waikato.ac.nz/ml/weka/>. Acesso em: 01 mar. 2016.