

## **Análise Comparativa entre Árvores de Decisão e TRISS na Predição de Sobrevida de Pacientes Traumatizados**

**Patrícia Miranda Fugimoto<sup>1,2,3</sup>, Luciana Domene Furlan Sales<sup>1,2,3</sup>,  
Gerson Alves Pereira Júnior<sup>3</sup>, Afonso Dinis Costa Passos<sup>2</sup>, Domingos Alves<sup>2</sup>,  
José Augusto Baranauskas<sup>1</sup>**

<sup>1</sup>Departamento de Física e Matemática  
Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto  
Universidade de São Paulo (USP) – Ribeirão Preto, SP – Brasil

<sup>2</sup>Departamento de Medicina Social, <sup>3</sup>Departamento de Cirurgia e Anatomia  
Faculdade de Medicina de Ribeirão Preto  
Universidade de São Paulo (USP) – Ribeirão Preto, SP – Brasil

{patriciafugimoto, lucianadomene, gersonapj}@gmail.com,  
{apassos, quiron}@fmrp.usp.br, augusto@usp.br

**Abstract.** *This study focuses on the comparison of two classifying systems that predict the survival rate of patients that have suffered some sort of trauma. A decision tree was induced, a symbolic model that allows human interpretation and validation, using data from “Hospital das Clínicas” located at Ribeirão Preto, Brazil. Decision tree allow predicting traumatized patients release status and their results were compared with a standard score index system based on the severity of injury, the Trauma and Injury Severity Score (TRISS), which is based on regression logistics, utilized by physicians to calculate the probability of survival of traumatized patients.*

**Resumo.** *Neste estudo é efetuada uma comparação entre dois sistemas de classificação que predizem a probabilidade de sobrevida de pacientes que sofreram algum tipo de trauma. Uma árvore de decisão foi induzida, um modelo simbólico que permite interpretação e validação por especialistas humanos, utilizando dados do Hospital das Clínicas de Ribeirão Preto. Esta árvore permite classificar e prever a condição de alta dos pacientes traumatizados. Seus resultados foram comparados aos de um sistema padrão de pontuação de índice de gravidade, o Trauma and Injury Severity Score (TRISS), que é baseado em regressão logística, muito utilizado por médicos para calcular a probabilidade de sobrevida de pacientes traumatizados.*

### **1. Introdução**

O trauma representa um dos principais problemas de saúde e, segundo dados da Organização Mundial de Saúde (OMS), está entre as principais causas de morte e morbidade do mundo [Krug, Sharma and Lozano 2000]. A Vigilância Epidemiológica do Departamento de Medicina Social, do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, da Universidade de São Paulo (HC-FMRP-USP) recebeu o total de 7.062 notificações de trauma, no período de 2005 a 2007.

Sistemas de pontuação de trauma foram desenvolvidos para a avaliação das alterações fisiológicas, da gravidade das lesões anatômicas e da probabilidade de

sobrevida dos pacientes politraumatizados. Um sistema de pontuação muito utilizado é o *TRauma and Injury Severity Score* (TRISS), que oferece um padrão para avaliar o resultado dos cuidados com trauma [Boyd, Tolson and Copes 1987]. Esse sistema possibilita o planejamento de sistemas de cuidados de emergência, a documentação das características epidemiológicas do trauma e o controle de qualidade da assistência prestada, além da avaliação e comparação dos resultados de instituições [Domingues 2008].

O objetivo deste trabalho consiste em comparar o modelo TRISS com o modelo de árvores de decisão na predição da condição de alta dos pacientes traumatizados que deram entrada na Unidade de Emergência (UE) do HC-FMRP-USP. O modelo TRISS prediz a probabilidade de sobrevida de um paciente por meio de diversos parâmetros, usando uma combinação linear dos mesmos aplicada a uma função sigmóide. Por outro lado, uma árvore de decisão mostra quais os parâmetros necessários para que o paciente venha a óbito ou não na forma de testes envolvendo esses parâmetros. Dessa forma, este estudo permite comparar se outros parâmetros que não são, atualmente, considerados no cálculo do TRISS, são também importantes para prever a probabilidade de sobrevida dos pacientes. Assim, esta pesquisa pode colaborar para uma maior compreensão dos fatores que levam um paciente traumatizado a óbito ou não, permitindo melhorar o processo de gestão hospitalar na UE do HC-FMRP-USP, refletindo melhor a realidade deste hospital.

Este estudo está organizado da seguinte forma: na Seção 2 descreve-se o sistema de pontuação TRISS, e em seguida árvores de decisão na Seção 3. Na Seção 4, a metodologia utilizada neste estudo é explicada. Os resultados são expostos e discutidos na Seção 5 e as conclusões encontram-se na Seção 6.

## **2. Pontuação de Gravidade de Lesão e Trauma**

A pontuação de gravidade de lesão e trauma TRISS consiste no cálculo da probabilidade de sobrevida ( $P_s$ ), obtido por meio da equação  $P_s = 1 / (1 + e^{-b})$ , onde  $b$  é uma variável que depende do resultado de outros sistemas de pontuação e parâmetros: (i) a Pontuação de Gravidade de Lesões (*Injury Severity Score* - ISS), (ii) a Pontuação de Trauma Revisada (*Revised Trauma Score* - RTS), (iii) idade e (iv) tipo de trauma (contuso ou penetrante). Por se tratar de um cálculo de probabilidade, o resultado encontra-se num intervalo de 0% a 100%, com um limiar em 50% de forma que conforme decresce esse valor, menor é a probabilidade de sobrevida, e vice-versa. Portanto, o modelo TRISS assume que pacientes com  $P_s < 50\%$  têm pouca probabilidade de sobrevida, devendo ir a óbito e pacientes com  $P_s \geq 50\%$  devem sobreviver. No restante deste documento os termos TRISS e  $P_s$  são usados de forma equivalente.

A variável  $b$  é calculada por meio da combinação linear desses resultados, onde  $b = b_0 + b_1(RTS) + b_2(ISS) + b_3(Idade)$ . Os coeficientes  $b_0$ ,  $b_1$ ,  $b_2$ ,  $b_3$  são derivados de análise de regressão logística, baseados em um estudo feito para avaliar os resultados da assistência prestada aos pacientes traumatizados, o *Major Trauma Outcome Study* (MTOS) [Boyd, Tolson and Copes 1987]. Esses coeficientes possuem valores diferentes dependendo do tipo de trauma e são mostrados na Tabela 1 [Champion, Sacco and Copes 1995].

**Tabela 1. Valores dos coeficientes em cada tipo de trauma.**

Coeficientes	Contuso	Penetrante
$b_0$	-0,4499	-2,5355
$b_1$	0,8085	0,9934
$b_2$	-0,0835	-0,0651
$b_3$	-1,7430	-1,1360

O RTS é um sistema de pontuação fisiológico, que avalia a resposta orgânica ao trauma. É medido pelos sinais vitais: Escala de Coma Glasgow (ECG), pressão arterial sistólica (PAS) e frequência respiratória (FR). Sua pontuação varia de 0 a 7,84 e é calculado como:  $RTS = 0,9368 \times ECG + 0,7326 \times PAS + 0,2908 \times FR$ . Esses sinais são determinados no momento de admissão do paciente no hospital, e podem ser alterados se o paciente foi intubado, anestesiado, ou se estava sob efeito de álcool ou drogas. Em geral, o RTS está correlacionado com a mortalidade precoce [Pereira Junior, Scarpelini, Basile-Filho, Andrade 1999].

O ISS é um sistema de pontuação anatômico, baseado no local da lesão. Mede a gravidade das lesões em cada uma das seis regiões do corpo humano, baseado na Escala de Lesão Abreviada (*Abbreviated Injury Scale* - AIS). Sua pontuação varia de 1 a 75. Seu cálculo é efetuado da seguinte forma: os valores máximos, ou seja, os níveis de severidade das três regiões anatômicas mais severamente lesadas são elevados ao quadrado e então somados; por definição, pacientes com alguma lesão de nível de severidade 6 recebem a pontuação máxima de 75. As medidas são determinadas durante toda a internação do paciente, pois a extensão total das lesões pode não ser totalmente determinada na admissão do paciente no hospital e em caso de óbito estende-se ao Instituto Médico Legal. Dessa forma, o ISS está correlacionado com a mortalidade tardia [Pereira Junior, Scarpelini, Basile-Filho, Andrade 1999]. Na Tabela 2 são mostrados as divisões das regiões anatômicas do corpo e os níveis de severidade.

**Tabela 2. Regiões anatômicas do corpo e níveis de severidade utilizados na AIS [Boyd, Tolson and Copes 1987]**

Regiões Anatômicas do Corpo	Níveis de Severidade
Cabeça/pescoço	1 – Leve
Face	2 – Moderado
Tórax	3 – Grave, sem risco iminente de vida
Abdome/Conteúdo pélvico	4 – Grave, com risco iminente de vida
Extremidades/Ossos da pelve	5 – Crítica, de sobrevida duvidosa
Geral ou externo	6 – Quase sempre fatal

O parâmetro idade recebe o valor 1 (um) se o paciente tiver mais de 54 anos, ou 0 (zero) se o paciente tiver 54 anos ou menos [Boyd, Tolson and Copes 1987].

O tipo de trauma pode ser dividido em *leve*, *moderado* ou *grave*, de acordo com o resultado do ISS. É considerado leve quando apresenta um ISS menor ou igual a 9; moderado, quando apresenta um ISS entre 10 e 15; e é considerado grave quando apresenta um ISS maior ou igual a 16 [Pereira Junior, Scarpelini, Aquino, Santiago, Negrini, Passos 2009].

### 3. Árvores de Decisão

A análise de grandes volumes de dados requer automação. Ferramentas de mineração de dados mostraram-se úteis em uma variedade de domínios. Classificação, a separação de

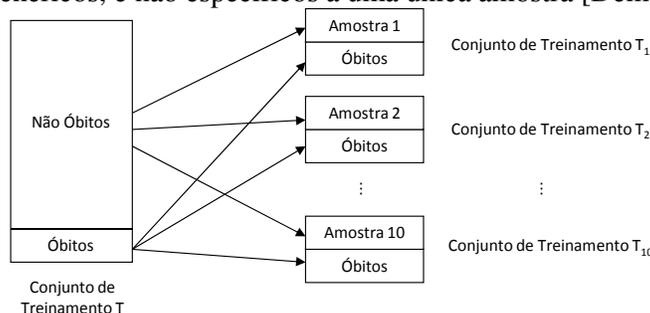
dados em classes distintas é, aparentemente, a tarefa de mineração de dados mais comum. Pesquisas científicas mostram que classificação pode ser utilizada para analisar o efeito de fatores genômicos, clínicos, ambientais e demográficos nas doenças, resposta ao tratamento e risco de efeitos colaterais [Nisbet et al. 2009, Killie et al. 2007]. Um modelo de grande importância principalmente em domínios nos quais os especialistas humanos precisam confrontar e entender o modelo obtido, tais como aqueles ligados à área médica ou biológica são os classificadores simbólicos. Neste estudo, um classificador simbólico é um modelo cuja linguagem de descrição é equivalente a um conjunto de regras, ou seja, o classificador pode ser representado em linguagem lógica proposicional ou relacional [Monard and Baranauskas 2003a]. Um dos classificadores mais populares são, provavelmente, as árvores de decisão [Kingsford and Salzberg 2008]. Uma árvore de decisão é constituída por dois tipos de nós: (i) nós de decisão, que contêm um teste sobre o valor do atributo ou característica de interesse, que leva a uma sub-árvore; (ii) nós-folha, que indicam a classe correspondente. Novos exemplos são classificados a partir da raiz (o primeiro teste da árvore), descendo através dos nós de decisão até chegar a um nó-folha, que corresponde à classe deste novo exemplo [Breiman et al. 1984, Quinlan 1993]. Árvores de decisão de tamanho moderado oferecem uma fácil interpretabilidade de seus resultados para o usuário, característica muito relevante quando se trata de um sistema para auxílio à tomada de decisão médica [Rosenfeld et al. 2008].

#### **4. Metodologia Experimental**

Para a elaboração deste estudo foi utilizada uma base de dados composta pelas notificações dos pacientes traumatizados, disponibilizada pela Vigilância Epidemiológica do Departamento de Medicina Social do HC-FMRP-USP, referentes ao período de 2005 a 2007. Essas notificações são compostas desde dados pessoais dos pacientes até a condição de alta deles. Destes dados, foram pré-selecionados 27 atributos que foram utilizados na indução das árvores de decisão, que são: idade, mecanismo do trauma, código CID, classificação AIS (das 6 regiões anatômicas do corpo, conforme Tabela 2), resultado do cálculo do ISS, assim como sua estratificação em leve, moderado e grave, medida da pressão arterial, escala de coma de Glasgow, frequência respiratória, resultado do cálculo do RTS, cirurgia, número de cirurgias especificadas em ortopedia, clínica cirúrgica, neurocirurgia, cirurgia cabeça/pescoço, oftalmológica ou outros, número de dias de internação, número de dias na CTI, patologias, possíveis complicações e o resultado do cálculo do TRISS. Os demais atributos foram desconsiderados por corresponderem a dados pessoais dos pacientes, como nome, número de registro, estado civil, entre outros, e também atributos com a maioria dos campos incompletos, ou seja, com valores desconhecidos. A condição de alta do paciente, óbito ou não-óbito, foi definida como classe.

Do total de 7.062 notificações de trauma, os registros de pacientes cuja saída constava como evasão, transferência ou ignorado foram removidos da análise, por não indicarem a verdadeira condição de alta do paciente. Também foram descartados da análise os registros de pacientes com campos de interesse que estavam incompletos, resultando em um total de 6.731 (95,31%) registros para o estudo. Destes, 6.437 (95,63%) registros possuem a classe (majoritária) não-óbito, e 294 (4,37%), a classe (minoritária) óbito.

Como o objetivo do estudo consiste em distinguir pacientes que foram a óbito ou não, um balanceamento foi realizado nos dados, pois classificadores induzidos a partir de classes balanceadas artificialmente, alocando 50% dos exemplos de treinamento para a classe minoritária, geralmente, apresentam resultados melhores do que aqueles com distribuição natural das classes [Batista 2003]. Assim, foram definidos 10 conjuntos de treinamento ( $T_1, T_2, \dots, T_{10}$ ), cada um contendo todos os 294 registros da classe minoritária; além disso, 294 registros foram selecionados, de forma aleatória dentre os 6.437 da classe majoritária, compondo assim 10 conjuntos de treinamento contendo 588 registros de pacientes cada um, conforme é mostrado na Figura 1. A justificativa para esta abordagem pode ser encontrada em [Batista 2003]. A idéia em definir 10 conjuntos de treinamento, ao invés de um único, foi para garantir que os resultados obtidos neste estudo fossem genéricos, e não específicos a uma única amostra [Demšar 2006].



**Figura 1. Definição dos conjuntos de treinamento utilizados**

Para a indução das árvores de decisão foi utilizado o algoritmo J48, da biblioteca de Weka [Witten and Frank 2008]. Como o objetivo é tentar encontrar uma árvore de decisão que explique adequadamente os dados (baixa taxa de erro) e que também permita sua compreensão pelo especialista humano (árvore com poucas folhas), foram induzidas árvores variando-se dois parâmetros do algoritmo J48: fator de poda e número mínimos de exemplos nas folhas. Seus valores *default* são, respectivamente, 0,25 e 2, definidos pelo autor do algoritmo [Quinlan 1993]. Em um estudo preliminar, verificou-se que as árvores geradas com fator de poda 0,3 e número mínimo de exemplos nas folhas igual a três não apresentavam diferenças significativas. Assim, os fatores de poda utilizados neste estudo foram 0,1, 0,3, 0,5 e 0,7 e, para cada um desses valores, também se variou o número mínimo de exemplos nas folhas em 3, 6, 9 e 12. Dessa forma, a primeira árvore teve como parâmetros fator de poda 0,1 e número mínimo de exemplos 3; a segunda árvore teve como parâmetros 0,1 e 6 e assim sucessivamente. Portanto, para cada um dos 10 conjuntos de treinamento foram induzidas 16 árvores de decisão, totalizando 160 árvores analisadas neste estudo.

Como não seria prático mostrar todas as 160 árvores para o especialista, optou-se por selecionar e mostrar somente as melhores, já que os especialistas ficam confusos e perdem a confiança em modelos que sofrem mudanças radicais, a partir de diferentes amostras de um mesmo conjunto de exemplos [Turney 1995, Dietterich 1996]. Para tanto, esta escolha foi baseada na estimativa de desempenho obtida por validação cruzada utilizando 10 partições (*folds*) [Kohavi and Li 1995]. Com base na estimativa de desempenho foram selecionadas as árvores que apresentaram menores taxas de erro, mas que também fossem de fácil entendimento. Dentre as árvores com as menores taxas de erro, como mencionado, foi utilizado o número de folhas como métrica de facilidade de entendimento: quanto menor a árvore (menos folhas), de entendimento mais simples

ela foi considerada. Para isso, em ambas as situações foi usado o teste *t*-pareado com nível de confiança em 95% para determinar se uma árvore é estatisticamente diferente das demais [Moses 1986]. Os resultados encontram-se na próxima seção.

## 5. Resultados & Discussão

Ao observar os resultados do TRISS, deve-se levar em consideração a classificação das mortes que atualmente é utilizada na Unidade de Emergência do HC-FMRP-USP [Shackford, Fridlund, Mcardle and Eastman 1987]:

- Inevitáveis: Lesão ou lesões consideradas de sobrevivência impossível, mesmo com tratamento a tempo e adequado. Geralmente correspondem a uma probabilidade de sobrevida menor que 25%;
- Potencialmente salváveis: Lesão ou lesões consideradas muito graves, mas com sobrevivência possível dentro de ótimas condições de atendimento. Geralmente correspondem a uma probabilidade de sobrevida entre 25% e 50% e
- Francamente evitáveis: Lesão ou lesões consideradas de sobrevida possível. Geralmente correspondem a uma probabilidade de sobrevida maior que 50%.

Na Tabela 3 estão representados todos os pacientes traumatizados no período 2005-2007 (conjunto T), conforme a classificação de mortes acima descrita em intervalos TRISS. Observa-se que a maioria dos não-óbitos (99.81%) encontra-se no intervalo  $TRISS \geq 50\%$ , indicando que suas mortes são francamente evitáveis. Entretanto, a maioria dos óbitos (63.27%) também se encontra no mesmo intervalo, indicando erroneamente que as mortes eram francamente evitáveis. Isso pode mostrar imprecisões no cálculo do TRISS, pois, deve-se levar em consideração o momento do óbito do paciente, o que interfere no cálculo do TRISS.

**Tabela 3: Distribuição dos valores TRISS para óbito e não-óbito. As porcentagens são em relação à soma de cada linha da tabela.**

	TRISS<25%	25%≤TRISS<50%	TRISS≥50%
<b>Óbitos</b>	74 (25.17%)	34 (11.56%)	186 (63.27%)
<b>Não-óbitos</b>	2 (0.03%)	10 (0.16%)	6425 (99.81%)

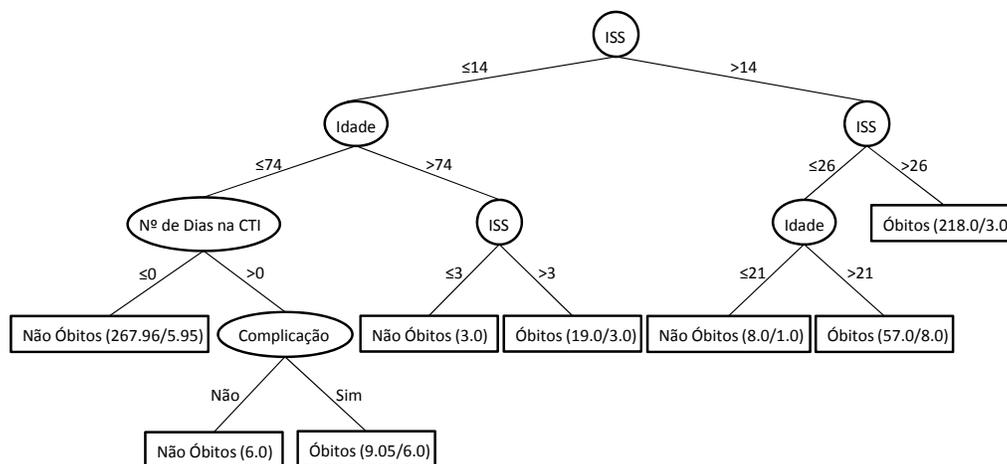
Na Tabela 4 são mostradas as quinze árvores com melhores resultados para cada conjunto de treinamento  $T_i$  ( $i=1, 2, \dots, 10$ ), fator de poda e número mínimo de exemplos nas folhas; os valores da taxa de erro e do número de folhas correspondem à média  $\pm$  desvio padrão dos 10 *folds* obtidos por validação cruzada. Para a escolha das árvores, dentre as 160 analisadas neste estudo, inicialmente foram comparadas entre si as taxas de erro e, subsequentemente, o número de folhas das 16 árvores geradas a partir de cada um dos 10 conjuntos de treinamento. Isso resultou em 60 árvores significativamente superiores às demais. Para diminuir esse número, procurou-se pelas menores taxas de erro, utilizando um limiar de 7%, o que resultou em 32 árvores. Dentre elas, em alguns casos, geraram-se árvores idênticas, sendo que apenas 15 delas são diferentes entre si. Nestas, as taxas de erro não são estatisticamente diferentes (nível de confiança de 95%), portanto todas podem ser consideradas igualmente satisfatórias para a separação das classes óbito e não-óbito. Dessa forma, essas 15 árvores foram então analisadas pelo

especialista que considerou duas como sendo as mais representativas  $A_7$  e  $A_{11}$ , mostradas nas Figuras 3 e 4, respectivamente.

**Tabela 4: Quinze melhores árvores obtidas para cada valor de fator de poda e número mínimo de exemplos**

Árvore	Conjunto de Treinamento	Fator de Poda	Número mínimo de exemplos	Taxa de Erro	Número de folhas
$A_1$	$T_9$	0,1	3	$4,97 \pm 2,98$	$7,50 \pm 1,41$
$A_2$	$T_9$	0,3	3	$5,08 \pm 2,93$	$8,80 \pm 1,50$
$A_3$	$T_3$	0,1	3	$5,38 \pm 3,10$	$5,55 \pm 1,66$
$A_4$	$T_3$	0,3	3	$5,50 \pm 3,24$	$7,21 \pm 2,16$
$A_5$	$T_9$	0,3	6	$5,83 \pm 3,47$	$6,17 \pm 0,97$
$A_6$	$T_6$	0,5	6	$5,95 \pm 3,16$	$7,68 \pm 1,52$
$A_7$	$T_2$	0,5	6	$6,34 \pm 3,03$	$8,18 \pm 1,49$
$A_8$	$T_7$	0,1	3	$6,38 \pm 2,93$	$6,39 \pm 1,51$
$A_9$	$T_2$	0,3	3	$6,53 \pm 3,18$	$9,89 \pm 2,08$
$A_{10}$	$T_7$	0,1	6	$6,58 \pm 2,78$	$5,38 \pm 1,06$
$A_{11}$	$T_6$	0,5	3	$6,67 \pm 3,76$	$10,38 \pm 3,53$
$A_{12}$	$T_1$	0,3	6	$6,77 \pm 3,50$	$8,64 \pm 1,74$
$A_{13}$	$T_1$	0,5	6	$6,79 \pm 3,38$	$9,40 \pm 1,87$
$A_{14}$	$T_{10}$	0,1	3	$6,87 \pm 3,28$	$7,19 \pm 1,68$
$A_{15}$	$T_6$	0,1	3	$6,99 \pm 3,74$	$5,51 \pm 2,00$

De acordo com os critérios adotados, pode-se observar na árvore  $A_7$  da Figura 3, que foram utilizados os atributos ISS e idade, que também são utilizados no cálculo do TRISS, mas também a árvore utilizou atributos não utilizados pelo TRISS, como número de dias na CTI e se ocorreu alguma complicação durante a internação. Além disso, é possível observar que os principais óbitos apareceram do lado direito da árvore, a partir da raiz, e foram devidos a um valor de ISS alto ( $ISS > 14$ ), ou seja, pessoas que sofreram um trauma grave e, portanto, apresentam menor probabilidade de sobrevivência, como é esperado. Entretanto, as pessoas que vieram a óbito, mostradas do lado esquerdo da árvore ( $ISS \leq 14$ ), embora tenham sofrido um trauma de leve a moderado, são idosos com mais de 74 anos de idade ou são pessoas que tiveram complicações e foram internadas na CTI. Além disso, também é possível observar que o parâmetro idade apresentou um limiar de 74 na árvore, maior do que aquele utilizado pelo TRISS.



**Figura 3: Primeira árvore selecionada pela análise ( $A_7$ )**

Na árvore  $A_{11}$  representada na Figura 4, nota-se que a mesma utilizou o atributo ISS, assim como no cálculo do TRISS e outros atributos não utilizados pelo TRISS: complicação, número de dias de internação, número de dias na CTI, o ISS estratificado (leve, moderado ou grave) e o próprio valor do TRISS, que se encontra como raiz da árvore. Nota-se, portanto, que o valor do TRISS sozinho não foi capaz de separar os pacientes que foram a óbito ou não (as subárvores esquerda e direita não são folhas) e, portanto, parâmetros adicionais foram necessários para realizar essa separação. Aliado a este fato, o valor do TRISS na raiz da árvore (97,4%) é muito diferente daquele que seria esperado para separar óbito (TRISS < 50%) de não-óbito (TRISS  $\geq$  50%). No lado esquerdo da árvore (TRISS  $\leq$  97,4%), observam-se os principais óbitos, também devido ao ISS que indica um trauma grave (ISS  $\geq$  16). Também é possível observar o caso de pessoas que embora tenham apresentado trauma moderado, tiveram complicações e posteriormente vieram a óbito. No entanto, apareceram dois casos de óbitos com trauma leve; analisando a respectiva amostra ( $T_6$ ), observou-se que a mesma continha os dois únicos casos isolados de trauma leve que foram a óbito dentro de todo conjunto T. Além disso, também há o caso de pacientes com trauma moderado sem complicação, que apesar de não possuírem TRISS baixo, também vieram a óbito, pois se deve levar em consideração o momento do óbito do paciente que pode ter causado imprecisão no cálculo do TRISS. Já no lado direito da árvore (TRISS > 97,4%), nota-se novamente casos de óbitos de pacientes com trauma leve a moderado, que tiveram complicações e foram internados na CTI. Também se observam pacientes que vieram a óbito com trauma grave, apesar do TRISS alto, encaixando-se nos casos de imprecisões do cálculo do TRISS.

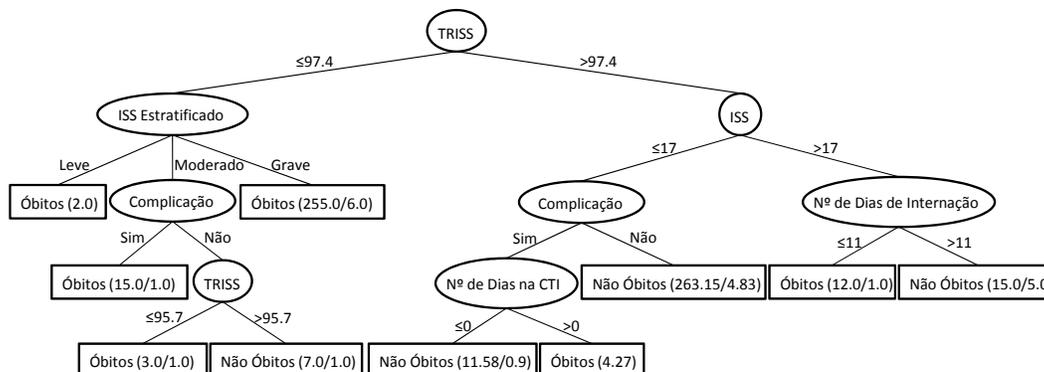


Figura 4: Segunda árvore selecionada pela análise ( $A_{11}$ )

## 6. Conclusões

Um dos objetivos desta pesquisa foi determinar por meio da indução de árvores de decisão, se outros parâmetros poderiam estar relacionados com o fato do paciente vir a óbito ou não, além daqueles utilizados pelo modelo TRISS. Um estudo efetuado no *The Johns Hopkins University School of Medicine*, mostrou que o parâmetro “complicação” também é importante para indicar a qualidade de cuidados do trauma, o que também pode ser observado nas duas árvores de decisão discutidas neste estudo [Kardooni, et al. 2007]. Além disso, as árvores de decisão mostraram que o “número de dias de internação” no hospital e o “número de dias na CTI” parecem ser também importantes para separar óbitos de não-óbitos.

Segundo opinião do especialista, um fator importante que motivou esse estudo é que os coeficientes utilizados na pontuação feita pelo TRISS são totalmente baseados em registros de pacientes atendidos nos Estados Unidos; logo, se a população de estudo diferir significativamente dessa população, a predição do TRISS pode não ser próxima da esperada. Portanto, é importante pesquisar e avaliar modelos que possam refletir melhor a realidade da população de Ribeirão Preto e região. Outro fator que deve ser observado no cálculo do TRISS é que o momento do óbito do paciente, como já mencionado, interfere nos resultados. Por exemplo, um paciente que chega morto no hospital, ou seja, sem pressão arterial, sem ou com baixa frequência respiratória, que provavelmente estará intubado e/ou sedado, irá apresentar um RTS muito baixo, o que implicaria em um valor do TRISS alto. Um segundo exemplo são pacientes que vêm a óbito antes de 24 horas, que geralmente chegam ao hospital sedados e/ou intubados, implicando na Escala de Coma Glasgow baixa, também apresentarão um RTS baixo, e um TRISS alto. Esses casos, se não bem analisados poderiam indicar falhas no atendimento do paciente, ao invés de imprecisões do cálculo do TRISS.

Outro fator que merece atenção são os coeficientes  $b_0$ ,  $b_1$ ,  $b_2$  e  $b_3$ , que no modelo TRISS, são calculados utilizando todos os pacientes no banco de dados do MTOS. Devido à melhoria do atendimento nos serviços de traumatologia, há um número maior de pacientes que sobrevivem. Assim, uma regressão efetuada nessa situação tende a ajustar melhor a parte superior da curva sigmóide ( $\text{TRISS} \geq 50\%$ ), ficando a parte inferior da curva ( $\text{TRISS} < 50\%$ ) com um ajuste muito ruim. Isso implica que o limiar de 50% do TRISS não é suficiente para separar os óbitos de não-óbitos, no qual a sensibilidade é alta, enquanto a especificidade é baixa. Em continuidade a este trabalho, estão sendo efetuados estudos adicionais nos quais já se observou que um corte muito maior do que 50% no TRISS é capaz de separar melhor óbitos de não-óbitos, apresentando maior especificidade sem diminuir significativamente a sensibilidade.

**Agradecimentos:** Os autores gostariam de agradecer a colaboração de Lincoln Tadeu do Nascimento Silva por idéias e comentários que ajudaram na elaboração deste documento.

## Referências

- Batista, G. E. A. P. A. (2003) “Pré-processamento de dados em aprendizado de máquina supervisionado”, Tese de Doutorado, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, Brasil.
- Boyd, C. R., Tolson, M. A. and Copes W. S. (1987) “Evaluating Trauma Care: The TRISS Method”, *Journal of Trauma*, v. 27, n. 4, p. 370-378.
- Breiman, L., Friedman, J., Olshen, R. and Stone, C. (1984) “Classification and Regression Trees”, Pacific Grove, CA: Wadsworth & Books.
- Champion, H. R., Sacco, W. J. and Copes, W. S. (1995) “Injury Severity Scoring Again”, *Journal of Trauma*, v. 38, p. 94-95.
- Demšar, J. (2006) “Statistical comparison of classifiers over multiple data sets”. *Journal of Machine Learning Research* 7(1), 1-30.
- Dietterich, T. G. (1996). Editorial. *Machine Learning* v. 22, n. 1–3, p. 5–6.
- Domingues, C. A. (2008) “Probabilidade de Sobrevida: Comparação dos Resultados de Trauma and Injury Severity Score (TRISS) com sua nova versão (NTRISS)”, Dissertação (Mestrado), Escola de Enfermagem, Universidade de São Paulo, Brasil.

- Kardooni, S., Haut, E. R., Chang, D. C., Pierce, C. A., Efron, D. T., Haider, A. H., Pronovost, P. J. and Cornwell, E. E. (2007) "Hazard of Benchmarking Complications With the National Trauma Data Bank: Numerators in Search of Denominator", *Journal of Trauma*, v. 64, p. 273-279.
- Killie, M. K., Kjeldsen-Kragh, J., Husebekk, A., Skogen, B., Olsen, J. A. and Kristiansen, I.S. (2007) "Cost-effectiveness of antenatal screening for neonatal alloimmune thrombocytopenia", *BJOG: An International Journal of Obstetrics & Gynaecology*, v. 114, n. 5, p. 588-595.
- Kingsford, C. and Salzberg S. L. (2008) "What are decision trees?", *Nature Biotechnology* v. 26, n. 9, p. 1011-1013.
- Kohavi, R. and Li, C. (1995). "A study of cross-validation and bootstrap for accuracy", *In Proc.of the 14th IJCAI, Montreal, Canada*, p. 1137-1145.
- Krug, E. G., Sharma, G. K. and Lozano, R. (2000). "The global burden of injuries", *Am J Public Health*, v. 90, p. 523-526.
- Monard, M. C. and Baranauskas, J. A. (2003a) "Conceitos sobre Aprendizagem de Máquina", Chapter 4, p. 89-114. *In Rezende (2003)*.
- Moses, L. E. (1986) "Think and Explain with Statistics", Addison-Wesley.
- Nisbet, A. A., Rieder, J. M., Tran, V. Q., Williams, S. G. and Chien, G. W. (2009) "Decision Tree for Laparoscopic Partial Nephrectomy Versus Laparoscopic Renal Cryoablation for Small Renal Masses", *Journal of Endourology*, v. 23, p. 431-437.
- Pereira Junior, G. A., Scarpelini, S., Aquino, A. M. F., Santiago, R. C., Negrini, B. V. M. and Passos, A. D. C. (2009) "Caracterização dos pacientes traumatizados atendidos na Unidade de Emergência do Hospital das Clínicas de Ribeirão Preto da Universidade de São Paulo utilizando os índices de gravidade RTS, ISS e TRISS, em 2006/2007", *BEPA, Boletim Epidemiológico Paulista*, v. 6, p. 4-11.
- Pereira Junior, G. A., Scarpelini, S., Basile-Filho, A. and Andrade, J. I. (1999) "Índices de Trauma", *Medicina*, v. 32, p. 237-250.
- Quinlan, J. R. (1993) "C4.5: Programs for Machine Learning", Morgan Kaufmann.
- Rezende, S. O. (2003) "Sistemas Inteligentes - Fundamentos e Aplicações", Manole.
- Rosenfeld, N., Aharonov, R., Meiri, E., Rosenwald, S., Spector, Y., Zepeniuk, M., Benjamin, H., Shabes, N., Tabak, S., Levy, A., Lebanony, D., Goren, Y., Silberschein, E., Targan, N., Ben-Ari, A., Gilad, S., Sion-Vardy, N., Tobar, A., Feinmesser, M., Kharenko, O., Nativ, O., Nass, D., Perelman, M., Yosepovich, A., Shalmon, B., Polak-Charcon, S., Fridman, E., Avniel, A., Bentwich, I., Bentwich, Z., Cohen, D., Chajut, A. and Barshack, I. (2008) "MicroRNAs accurately identify cancer tissue origin", *Nature Biotechnology* v. 26, p. 462-469.
- Shackford, S. R., Fridlund, P. H., Mcardle, M. and Eastman, A. B. (1987) "Assuring Quality in a Trauma System – The Medical Audit Committee: Composition, Cost and Results", *Journal of Trauma*, v. 27, p. 866-875.
- Turney, P. D. (1995) "Technical note: Bias and the quantification of stability", *Machine Learning*, v. 20, p. 23-33.
- Witten, I. H. and Frank, E. (2005) "Data Mining: Practical Machine Learning Tools and Techniques", 2<sup>nd</sup> edition, Morgan Kaufmann.