Inteligência estatística na tomada de decisão médica: um estudo de caso em pacientes traumatizados

Marcelo Garcia

Dissertação de Mestrado do Programa de Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria (MECAI)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Marcelo Garcia

Inteligência estatística na tomada de decisão médica: um estudo de caso em pacientes traumatizados

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria.
VERSÃO REVISADA

Área de Concentração: Matemática, Estatística e Computação

Orientador: Prof. Dr. Francisco Louzada Neto

USP – São Carlos
Março de 2019

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

G216i Garcia, Marcelo
 Inteligência estatística na tomada de decisão
 médica: um estudo de caso em pacientes
 traumatizados / Marcelo Garcia; orientador
 Francisco Louzada Neto. -- São Carlos, 2019.
 82 p.

 Dissertação (Mestrado - Programa de Pós-Graduação
 em Mestrado Profissional em Matemática, Estatística
 e Computação Aplicadas à Indústria) -- Instituto de
 Ciências Matemáticas e de Computação, Universidade
 de São Paulo, 2019.

 1. Aprendizado estatístico. 2. Índice de
 gravidade. 3. Risco de vida. 4. Tomada de decisão.
 5. Trauma. I. Neto, Francisco Louzada, orient. II.
 Título.

Marcelo Garcia

**Statistical intelligence in medical decision making: a case
study in traumatized patients**

Master dissertation submitted to the Institute of
Mathematics and Computer Sciences – ICMC-USP, in
partial fulfillment of the requirements for the degree of
the Master – Professional Masters in Mathematics,
Statistics and Computing Applied to Industry. *FINAL
VERSION*

Concentration Area: Mathematics, Statistics and
Computing

Advisor: Prof. Dr. Francisco Louzada Neto

USP – São Carlos
March 2019

À minha família.

É o Senhor quem nos dá toda a capacidade para aprender e ter sabedoria.

AGRADECIMENTOS

À Deus por me fortalecer todos os dias na busca de mais uma vitória em minha vida.

À minha família, que não mediu esforços pra me dar amor e força para superar os obstáculos da estrada da vida.

À minha mãe e meu pai (*in memoriam*), que na sua simplicidade me ensinou a ser o homem que sou, forte, íntegro e humano.

Ao orientador Professor Dr. Francisco Louzada Neto que teve paciência e confiança depositado no meu trabalho e na minha pessoa.

Aos meus amigos que diretamente ou indiretamente colaboraram para a realização deste trabalho.

Em especial ao amigo Diego Nascimento, por todo empenho, sua força e perseverança foi fundamental para juntos realizarmos os resultados aqui apresentados.

Aos professores que ao longo do meu mestrado contribuíram para a minha formação profissional.

À Pesquisadora Dra. Taiza Elaine Grespan dos Santos que disponibilizou os dados para que este trabalho obtivesse forma, gratidão pela sua solicitude.

“Olhe para as estrelas e não para os seus pés.”
(*Stephen Hawking*)

RESUMO

GARCIA, M. **Inteligência estatística na tomada de decisão médica: um estudo de caso em pacientes traumatizados**. 2019. 82 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2019.

O principal objetivo do estudo foi utilizar informações de ocorrência do Traumatismo Crânio Encefálico (TCE) que possam inferir/gerar descobertas associadas ao risco de gravidade do paciente, bem como auxiliar na tomada de decisão médica ao definir o melhor prognóstico, indicando quais as possíveis medidas que podem ser escolhidas para a gravidade na lesão sofrida pela vítima. Inicialmente, foram analisadas as estatísticas descritivas dos dados dos pacientes de TCE de um hospital do interior de São Paulo. Participaram desse estudo 50 pacientes. Os resultados mostraram que a maior frequência do trauma é por acidentes de trânsito (62%), seguidos de acidentes por queda (24%). Traumas em pacientes do sexo masculino (88%) são muito mais frequentes do que em pacientes do sexo feminino. Para modelagem, transformou-se a variável resposta "*Abbreviated Injury Scale (AIS)*" em dicotômica, considerando 0 (zero) aos pacientes fora de risco e 1 (um) aos que apresentaram algum tipo de risco. Em seguida, técnicas de aprendizado estatístico foram utilizadas de modo a comparar o desempenho dos classificadores Regressão Logística sendo um caso do *Generalized Linear Model (GLM)*, *Random Forest (RF)*, *Support Vector Machine (SVM)* e redes probabilísticas *Naïve Bayes (NB)*. O modelo com melhor desempenho (RF) combinou os índices *Accuracy (ACC)*, *Area Under ROC Curve (AUC)*, *Sensitivity (SEN)*, *Specificity (SPE)* e *Matthews Correlation Coefficient (MCC)*, que apresentaram os resultados mais favoráveis no quesito de apoio no auxílio da tomada de decisão médica, possibilitando escolher o estudo clínico mais adequado das vítimas traumatizadas ao considerar o risco de vida do indivíduo. Conforme o modelo selecionado foi possível gerar um *ranking* para estimar a probabilidade de risco de vida do paciente. Em seguida foi realizado uma comparação de desempenho entre o modelo RF (novo classificador) e os índices *Revisited Trauma Score (RTS)*, *Injury Severity Score (ISS)*, Índice de Barthel (IB) referente à classificação de risco dos pacientes.

Palavras-chave: Aprendizado estatístico, Índice de gravidade, Risco de vida, Tomada de decisão, Trauma.

ABSTRACT

GARCIA, M. **Statistical intelligence in medical decision making: a case study in traumatized patients**. 2019. 82 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2019.

The main objective of this study was to consider the information related to the occurrence of traumatic brain injury (TBI) that can infer new results associated with the patient's risk of severity as well as assisting in the medical decision in order to find the best prognosis; this can lead to indicate possible measures that can be chosen for severity in the injury suffered by the victim. Initially, we have presented descriptive statistics from the patients with TBI from a hospital located in the heartland of São Paulo. Fifty patients were recruited for this study. Descriptive analyzes showed that the highest frequency of trauma is due to traffic accidents (62 %) followed by crashes per accident (24 %). The causes related to trauma occur much more often in male patients (88 %) than in female patients. To order model, the response variable Abbreviated Injury Scale (AIS) was considered as dichotomous, where 0 (zero) was to out-of-risk patients and 1 (one) to those who presented some type of risk. Further, statistical learning techniques were used in order to compare the performance of the Logistic Regression as a Generalized Linear Model (GLM), Random Forest (RF), Support Vector Machine (SVM) and Naive Bayes (NB) model. The best performing (RF) model combined the Accuracy (ACC) , Area Under ROC Curve (AUC) , Sensitivity (SEN), Specificity (SPE) e Matthews Correlation Coefficient (MCC), which presented the most favorable results in terms of support in medical decision, making it possible to choose the most appropriate clinical study of traumatized victims based on the individual life risk. According to the selected model it was possible to generate a rank to estimate the probability of life risk of the patient. Then a performance comparison was performed between the RF model (proposed classifier) and the Revisited Trauma Score (RTS), Injury Severity Score (ISS), Barthel index (IB) referring to the risk classification of patients.

Keywords: Decision making, Lifetime risk, Risk index, Statistical learning, Trauma.

LISTA DE ILUSTRAÇÕES

Figura 2.1 – Divisão das escalas de gravidade	19
Figura 2.2 – Regiões corporais para efeito do cálculo ISS	23
Figura 2.3 – Representação gráfica do modelo de classificação RF, sendo x os dados de entrada que são classificados por todas as árvores	33
Figura 2.4 – Um hiperplano para a classificação de exemplos das classes 1 e 2	36
Figura 2.5 – Matriz de confusão para um problema de duas classes	38
Figura 2.6 – Exemplo de Espaço ROC com três classificadores	40
Figura 3.7 – Percentual de mortes por CE no Brasil em 2015	41
Figura 3.8 – Distribuição das ocorrências de óbitos por acidentes de transporte dividido por categorias em diferentes regiões brasileiras	42
Figura 3.9 – Processo de descoberta do <i>Insight</i>	44
Figura 4.10–Função de sobrevivência empírica para admissão dos pacientes considerando diferentes tipos de ocorrência	47
Figura 4.11–Distribuição da idade de pacientes que sofreram trauma	49
Figura 4.12–Tempo de internação hospitalar	51
Figura 4.13–Tempo de internação na Enfermaria Neurológica	51
Figura 4.14–Distribuição da gravidade do TCE em relação ao GCS inicial	52
Figura 4.15–Tempo de internação em relação ao ISS, RTS e índice de Barthel	53
Figura 4.16– <i>Boxplot</i> RTS e ISS em relação ao alto e baixo risco de vida	54
Figura 4.17–Curva ROC - Comparação de desempenho dos modelos	55
Figura 4.18–Comparação dos desempenhos dos índices sob a classificação de risco dos pacientes	58

LISTA DE QUADROS

Quadro 2.1 – Valores atribuídos para o cálculo do RTS	20
Quadro 2.2 – Probabilidade de sobrevivência, conforme valores do RTS	21
Quadro 2.3 – Classificação das lesões decorrentes do trauma de acordo com a escala AIS	21
Quadro 2.4 – Facetas do <i>WHOQOL-BREF</i>	26
Quadro 2.5 – Resumo das fórmulas dos índices	27
Quadro 2.6 – Resumo das descrições dos índices	27
Quadro 4.7 – Importância das covariáveis para o modelo	57

LISTA DE TABELAS

Tabela 4.1 – Percentual de pacientes vítimas de trauma, conforme faixa etária.	48
Tabela 4.2 – Número de áreas afetadas pelo trauma.	50
Tabela 4.3 – Número de pacientes hospitalizados conforme pontuação do ISS	53
Tabela 4.4 – Tabela referente ao teste de Kruskal-Wallis	54
Tabela 4.5 – Estatísticas de desempenho dos modelos ajustados	56
Tabela 4.6 – <i>Score</i> segundo o melhor modelo	57

LISTA DE ABREVIATURAS E SIGLAS

AAAM	<i>Association for the Advancement of Automotive Medicine</i>
ACC	<i>Accuracy</i>
ACS	<i>American College of Surgeons</i>
AIS	<i>Abbreviated Injury Scale</i>
ANEP	Associação Nacional de Empresas de Pesquisa
AUC	<i>Area Under ROC Curve</i>
CE	Causas Externas
COT	<i>Committee on Trauma</i>
CROSS	Central de Regulação e Oferta de Serviços de Saúde
DATASUS	Departamento de Informática do Sistema Único de Saúde
FR	Frequência Respiratória
GCS	<i>Glasgow Coma Scale</i>
GLM	<i>Generalized Linear Model</i>
IB	Índice de Barthel
IOT	Intubação Orotraqueal
ISS	<i>Injury Severity Score</i>
MCC	<i>Matthews Correlation Coefficient</i>
MTOS	<i>Major Trauma Outcome Study</i>
NB	<i>Naïve Bayes</i>
NHE	Núcleo Hospitalar de Epidemiologia
NISS	<i>New Injury Severity Score</i>
NTRISS	<i>New Trauma and Injury Severity Score</i>
ONU	Organização Mundial das Nações Unidas
PAS	Pressão Arterial Sistólica
RF	<i>Random Forest</i>
ROC	<i>Receiver Operating Characteristic</i>
RTS	<i>Revisited Trauma Score</i>
SAMU	Serviço de Atendimento Móvel de Urgência
SEN	<i>Sensitivity</i>
SPE	<i>Specificity</i>
SUS	Sistema Único de Saúde

SVM	<i>Support Vector Machine</i>
TCE	Traumatismo Crânio Encefálico
TFP	Taxa de Falsos Positivos
TRISS	<i>Trauma and Injury Severity Score</i>
TVP	Taxa de Verdadeiros Positivos
UE	Unidade de Emergência
WHOQOL-BREF	<i>World Health Organization Quality of Life</i>

SUMÁRIO

1	INTRODUÇÃO	15
2	REFERENCIAL TEÓRICO	18
2.1	Descrição dos Índices de Traumas	18
2.2	Avaliação Funcional	24
2.3	Qualidade de Vida	24
2.4	Aprendizado Estatístico	28
2.4.1	<i>Generalized Linear Model (GLM)</i>	29
2.4.2	<i>Random Forest (RF)</i>	31
2.4.3	<i>Support Vector Machine (SVM)</i>	34
2.4.4	<i>Redes Probabilísticas (Naïve Bayes)</i>	36
2.4.5	<i>Métricas de Desempenho para Problemas de Duas Classes</i>	37
2.4.5.1	<i>Matriz de Confusão</i>	37
2.4.5.2	<i>Curva ROC</i>	39
3	MATERIAL E MÉTODOS	41
3.1	Material	42
3.2	Banco de Dados	43
3.3	Métodos	43
4	RESULTADOS E DISCUSSÃO	45
5	CONSIDERAÇÕES FINAIS	59
5.1	Limitações do Trabalho	60
5.2	Sugestões para Trabalhos Futuros	60
	REFERÊNCIAS	61
APÊNDICE A	SUMÁRIO DESCRITIVO DAS COVARIÁVEIS	75
APÊNDICE B	CÓDIGO EM R SCRIPT	77

INTRODUÇÃO

Pesquisas apontam que, em todo o mundo, milhões de pessoas falecem anualmente por algum tipo de trauma (OMS, 2015). No Brasil, as Causas Externas (CE), acidentes de trânsito, homicídios e suicídios, representam um problema de saúde pública, sendo um agravamento da mortalidade na população jovem (JORGE; KOIZUMI *et al.*, 2008; GONSAGA *et al.*, 2012; IBGE, 2015). Nos anos 90, o trauma físico foi responsável por 90 mil mortes anuais e deixou, por ano, mais de 200 mil vítimas com alguma sequela (RASSLAN; BIROLINI, 1998; JORGE; KOIZUMI, 2004). Entre 1980 e 2006, foram registradas oficialmente no Brasil 2.824.093 mortes por CE (BRASIL, 2007). Em 2009, a taxa de mortalidade por CE foi registrada em 52 para cada 100.000 habitantes. Na região Sudeste mais de 44 por 100.000 habitantes e no estado de São Paulo mais de 38 por 100.000 habitantes. Já no ano de 2013, faleceram 151.683 pessoas no Brasil, com uma taxa de mortalidade de 75,5 óbitos por 100 mil habitantes. Ainda nesse mesmo ano, foram registradas um milhão de hospitalizações pagas pelo Sistema Único de Saúde (SUS), sendo o intervalo de idade de 20 a 39 anos aquele com o maior percentual de internação (36,2%). A taxa de internação chegou a mais de 52 por 10 mil habitantes (BRASIL, 2015). Um estudo realizado para verificar a evolução das internações no sistema público de saúde no Brasil, durante o período de 2002 a 2011, confirma o aumento crescente de internações hospitalares por CE nos últimos anos (MASCARENHAS; BARROS, 2015).

Em 2013, o SUS gastou cerca de 230 milhões com internações por acidentes de trânsito (BRASIL, 2018). A hospitalização e a recuperação dos pacientes envolvem altos custos, tanto diretos (diagnóstico, tratamento, recuperação, reabilitação, médicos), quanto indiretos (perda da produção e produtividade), impactando na economia do país (RASSLAN; BIROLINI, 1998; JORGE; KOIZUMI, 2004; ORGANIZATION, 2014; PARREIRA *et al.*, 2017). A Organização Mundial das Nações Unidas (ONU), por anos, relata que acidentes de trânsito promovem sérios problemas à saúde pública em todo o mundo, provocando sérios danos à população por causa dos altos índices de morbidade (MACIEL *et al.*, 2009; MENDONÇA; SILVA; CASTRO, 2017). Em países desenvolvidos, a taxa de acidentes de trânsito e agressões está caindo, enquanto no

Brasil, um país em desenvolvimento, os acidentes de transporte e as agressões, particularmente o homicídio, se mantêm entre os primeiros lugares em morte (MATOS; MARTINS, 2013). No ano de 2015, conforme as estatísticas do DATASUS, ocorreram mais de 152 mil mortes por causas externas no Brasil, sendo a região Sudeste a responsável por mais de 54 mil delas, número maior do que os apresentados pelas demais regiões brasileiras.

A doença (trauma) ainda é negligenciada pela sociedade e está diretamente ligada às características sociais, econômicas e culturais do país (FRAGA; MANSO; STARLING, 2012). Para medir a gravidade de traumas existem diversos índices, cujos valores podem variar de acordo com a intensidade e os tipos de lesões. Tais índices são fundamentais para a tomada de decisão do especialista responsável pelo atendimento e tratamento do paciente, principalmente de pacientes politraumáticos (CHAMPION *et al.*, 1989; LOPES; WHITAKER, 2014). São utilizados desde a década de 70 e revisados constantemente, constituindo instrumentos de medição importantes para o atendimento adequado de pacientes (GABBE; CAMERON; FINCH, 2003; RESTREPO-ÁLVAREZ *et al.*, 2016). Os índices de gravidade são divididos em fisiológicos (RTS e *Glasgow Coma Scale* (GCS)), anatômicos (AIS, ISS e *New Injury Severity Score* (NISS)) e combinados (*Trauma and Injury Severity Score* (TRISS) e *New Trauma and Injury Severity Score* (NTRISS)).

As pontuações de gravidade começam a ser elaboradas na fase pré-hospitalar e começam a ser aplicadas mais tarde nos cuidados intensivos com o paciente, discriminando ao especialista a natureza e a extensão da lesão e, com isso, auxiliando a tomada de decisão do melhor prognóstico, oferecendo um tratamento adequado para o paciente (FERNÁNDEZ, 2003; SOLER; BENÍTEZ; GREGORIO, 2010). Essas pontuações são aplicadas há mais de três décadas em países desenvolvidos, como, por exemplo, o banco de dados do *Major Trauma Outcome Study* (MTOS) dos Estados Unidos da América, apresentado como referência nos estudos para estimativas de probabilidade de sobrevivência de pacientes de trauma (CHAMPION *et al.*, 1990; OSPINA *et al.*, 1993, 1993; FERNÁNDEZ, 2003). Espera-se que a decisão do especialista acerca da escolha do tratamento seja a menos impactante possível na vida das vítimas, minimizando as chances de sequelas ou, ainda, prevenindo a mortalidade (FRAGA, 2007; ARRUDA *et al.*, 2016). Dessa forma, as escalas podem intervir e conseguir contrariar essa cadeia que ocorre em pacientes traumatizados.

Outros índices que contribuem para uma melhor avaliação dos pacientes são os índices de capacidade funcional e de qualidade de vida. Para avaliar as atividades cotidianas do paciente, o índice de Barthel realiza uma análise importante da vida diária do paciente, como, por exemplo: comer, higiene pessoal, uso dos sanitários, tomar banho, vestir e despir, controle de esfínteres, deambular, transferência da cadeira para a cama e subir e descer escadas (BARTHEL, 1965; ARAÚJO *et al.*, 2007; FONSECA; PENNA, 2008). Para medir o estado de bem-estar físico, mental e cognitivo, pode-se considerar o indicador WHOQOL-BREF, utilizado mundialmente por ser fácil de aplicar e de compreender (FLECK *et al.*, 2000).

A classificação é um dos instrumentos mais importantes para o estudo de dados, pois

consiste na identificação de padrões e regularidades associados a uma variável resposta (HAN; PEI; KAMBER, 2011). Estudos demonstram diferentes métodos de aprendizado estatístico, aplicados na análise desses dados, que podem apresentar melhor desempenho, constituindo-se um modelo preditivo para acurácia de dados de pacientes traumatizados (ARA; LOUZADA; MILAN, 2018). Destes têm-se GLM, RF, SVM e redes probabilísticas NB.

Este trabalho teve como objetivo utilizar informações de ocorrência de traumas que possam inferir/gerar descobertas associadas ao risco de gravidade, mas também auxiliar na tomada de decisão do especialista ao estimar o risco de vida do paciente. Assim, técnicas estatísticas foram utilizadas para analisar dados médicos, particularmente, dados de pacientes que tiveram TCE, associando variáveis, índices de gravidade corporais, índice da capacidade funcional e índices de qualidade de vida para elaborar um *score* que estimasse a probabilidade de risco do paciente. Entre os métodos citados acima, iremos demonstrar que o método RF, que utiliza técnicas de aprendizagem de máquina para classificação e descobertas de padrões, apresentou a melhor combinação das ações resultantes das estatísticas de desempenho. Levando em consideração a necessidade médica, a escolha do modelo priorizou um equilíbrio entre as estatísticas Sensibilidade e Especificidade associadas a estatísticas de desempenho e de coeficientes de correlação, possibilitando, portanto, discriminar o paciente em risco.

A fim de elucidar o trabalho proposto, as informações encontram-se organizadas da seguinte maneira: no Capítulo 2 será descrita, de forma concatenada, a construção dos índices de trauma adotados para análise, bem como o embasamento teórico das técnicas estatísticas utilizadas nas análises. Posteriormente, no Capítulo 3, serão descritos os procedimentos metodológicos adotados, apresentando uma breve descrição acerca da motivação sobre o tópico no cenário brasileiro e descrevendo o banco de dados analisado, bem como a sequência metodológica das técnicas e suas implicações. No Capítulo 4, serão apresentados os resultados e as discussões em consonância com os achados presentes na literatura e, por fim, no Capítulo 5 serão apontadas as considerações finais deste trabalho.

REFERENCIAL TEÓRICO

Este capítulo apresenta o referencial teórico que diz respeito aos índices de gravidade de traumas mais utilizados na literatura, servindo como ferramentas que quantificam em valores matemáticos o desfecho do paciente. Através de quantificadores baseados em escores numéricos, é possível validar a qualidade no atendimento de pacientes traumatizados. Em seguida, serão discutidos modelos estatísticos que poderão apresentar, em forma de função, a associação entre as variáveis observadas e a gravidade do trauma.

2.1 Descrição dos Índices de Traumas

Índices de gravidade são métodos embasados nos tipos de lesões, desenvolvidos para quantificar a intensidade do dano nas vítimas de trauma. Esses valores numéricos podem possibilitar análises que auxiliam na assistência do trauma (BARSS, 1998). Trauma é uma ação violenta de natureza física que causa danos a uma pessoa de diferentes maneiras (mecânica, elétrica, térmica, química, entre outras), seja por força externa (acidentes ou agressão) ou intencional (autoagressão) (RODRÍGUEZ; VERA, 2014; PAYAMPS *et al.*, 2016). Existem diversos tipos de escalas, com valores matemáticos ou estatísticos, que têm sido desenvolvidas para classificar a gravidade das lesões de acordo com o dano de cada trauma (CHAMPION *et al.*, 1990). Elas são nomeadas índices de trauma e têm como objetivo avaliar a gravidade do trauma, principalmente em pacientes politraumáticos, para que esses recebam tratamentos mais adequados, proporcionando a redução da morbidade e da mortalidade. As análises das escalas são muito importantes nas decisões de prognóstico do especialista (RODRÍGUEZ; VERA, 2014; PAYAMPS *et al.*, 2016). Utilizadas desde a década de 70, surgiram pela necessidade de uma avaliação mais precisa das gravidades e foram desenvolvidas e embasadas em critérios fisiológicos, anatômicos ou combinados (OSLER; BAKER; LONG, 1997).

Tais escores foram criados através de pesquisa no MTOS (CHAMPION *et al.*, 1990). O estudo, realizado pelo médico Howard S. Champion e coordenado pelo *Committee on Trauma*

(COT) of *American College of Surgeons* (ACS), teve seu início em 1982 e objetivou o aprimoramento dos instrumentos de medição da gravidade do trauma e a definição de um padrão a nível nacional para melhorar a assistência prestada às vítimas de trauma na América do Norte. Até o ano de 1989, foram utilizados para o estudo cerca de 150 hospitais (localizados nos Estados Unidos da América, Canadá, Austrália e Reino Unido), onde foram utilizadas para o estudo aproximadamente 170.000 vítimas de trauma, todas submetidas à pesquisa MTOS. A partir dos resultados alcançados, foram desenvolvidos uma metodologia para a análise da morbidade e mortalidade hospitalar, bem como testes de probabilidade de sobrevivência com parâmetros nos índices de gravidade (CHAMPION *et al.*, 1990; CAMPOS, 2001; CHAMPION, 2002). A Figura 2.1 apresenta as escalas conforme sua divisão.

Figura 2.1 – Divisão das escalas de gravidade

Fonte: autor (2018)

Os índices de gravidade desenvolvidos pela ACS em 1986 e *American College of Emergency Physicians* em 1992 são o RTS, AIS, ISS e o TRISS, sendo todos revisados e atualizados constantemente. Para comparações foram criados novos índices, o NISS e o NTRISS (DOMINGUES *et al.*, 2011; BUSTILLO *et al.*, 2018). Esses índices de gravidade têm alta significância para elaborar documentos com especificidades epidemiológicas do trauma, aferir o diagnóstico médico prestado, elaborar estratégias para o cuidado de emergência e prever custos aplicados a cada tipo de tratamento (DAVIS *et al.*, 2008; NOGUEIRA; SOUSA; DOMINGUES, 2009; PARREIRA *et al.*, 2014).

A gravidade do TCE pode ser medida pelo índice GCS/Score, uma ferramenta clínica, utilizada mundialmente, que possui valor preditivo para avaliar pacientes com mudanças no nível de consciência (RIECHERS *et al.*, 2005; OLIVEIRA; PEREIRA; FREITAS, 2014), a qual é

medida através de

$$GCS = \sum_{i=1}^3 x_i, \quad (2.1)$$

em que as pontuações x_1 corresponde à abertura ocular, x_2 corresponde à reação motora e x_3 à resposta verbal.

Sua pontuação contribui na determinação de severidade do trauma e na interpretação clínica do paciente, podendo auxiliar o especialista na escolha do melhor estudo clínico. Esse índice avalia o paciente em três etapas: abertura ocular $x_1 \in [1, 4]$, reação motora $x_2 \in [1, 5]$ e resposta verbal $x_3 \in [1, 6]$, seu cálculo é o resultado da soma dessas três etapas. Sua pontuação varia de 3 a 15, sendo o melhor valor 15. Pacientes que apresentam valores menores que 8 são considerados em coma, indicando que a vítima necessita de maior atenção e cuidados urgentes. O valor mínimo 3 é compatível com morte cerebral, necessitando de outros critérios para análise. A vítima pode ser classificada em estado leve (13 a 15), moderado (9 a 12) e grave (3 a 8), conforme a pontuação do nível de consciência obtido pela GCS (TEASDALE; JENNETT, 1974; RIECHERS *et al.*, 2005; PALMER; KNIGHT, 2006; OLIVEIRA; PEREIRA; FREITAS, 2014)

Desenvolvido por Champion *et al.* (1980), na década de 70, o RTS é um índice fisiológico muito utilizado. Sua escala tem forte estimativa na probabilidade de sobrevivência e mortalidade do paciente (CHAMPION; SACCO; HUNT, 1983; WISNER, 1992; MOORE *et al.*, 2006). O valor do RTS é dado por

$$RTS = 0,9368 * (GCS) + 0,7326 * (PAS) + 0,2908 * (FR), \quad (2.2)$$

considerando a combinação da GCS, Pressão Arterial Sistólica (PAS) e valor da Frequência Respiratória (FR).

É calculado com base nas funções vitais da vítima considerando esses três parâmetros. Os valores de cada variável são multiplicados pelos pesos, antes da somatória; os pesos podem variar de 0 (zero) a 4 (quatro), conforme Quadro 2.1.

Quadro 2.1 – Valores atribuídos para o cálculo do RTS

GCS	Valor	PAS (mmhg)	Valor	FR (ipm)	Valor
13 - 15	4	> 89	4	10 - 29	4
9 - 12	3	76 - 89	3	> 29	3
6 - 8	2	50 - 75	2	6 - 9	2
4 - 5	1	1 - 49	1	1 - 5	1
3	0	0	0	0	0

Fonte: Champion *et al.* (1990)

Sua aplicação ocorre no início do tratamento, mesmo na fase pré-hospitalar considerando a gravidade da lesão. O RTS varia de zero a cerca de 8, permitindo frações (CHAMPION *et al.*, 1989; LEFERING, 2012; PARK *et al.*, 2017). Sua pontuação é dada conforme Quadro 2.2.

Quadro 2.2 – Probabilidade de sobrevivência, conforme valores do RTS

RTS	Probabilidade de sobrevivência	Percentual de sobrevivência (%)
8	0,988	98,8
7	0,969	96,9
6	0,919	91,9
5	0,807	80,7
4	0,605	60,5
3	0,361	36,1
2	0,172	17,2
1	0,071	7,1
0	0,027	2,7

Fonte: Champion *et al.* (1990)

Quanto maior o valor do RTS, melhor será o prognóstico médico, sendo possível o conhecimento das chances de sobrevivência da vítima, auxiliando na tomada de decisão de qual o melhor Centro Hospitalar para o paciente ser direcionado ao tratamento (GENNARI, 2000; ESTUMANO *et al.*, 2015).

A AIS é um índice de base anatômica que classifica as lesões corpóreas das regiões que sofreram o trauma. O índice é uma lista de milhares de lesões que vem sendo utilizada desde a década de 70. Desenvolvidas pela *Association for the Advancement of Automotive Medicine* (AAAM), essas escalas foram atualizadas 7 vezes, sendo a última atualização em 2008 (GENNARELLI; WODZIN; BARRINGTON, 2008; RESTREPO-ÁLVAREZ *et al.*, 2016). Foi criada para avaliar o impacto das lesões resultantes de acidentes automobilísticos, cada uma com um valor de gravidade. Esses valores são agrupados em 6 regiões do corpo: cabeça e pescoço, face, tórax, abdome e conteúdo pélvico, extremidades e ossos da pelve externos, variando de 1 a 6, conforme Quadro 2.3 (COPES *et al.*, 1988; MIKHAIL; RHIT; SORENSEN, 2003). A partir dessas regiões, os valores AIS mais altos são considerados para determinação do cálculo do ISS.

Quadro 2.3 – Classificação das lesões decorrentes do trauma de acordo com a escala AIS

Escala AIS	Gravidade
1	Leve
2	Moderada
3	Séria
4	Grave
5	Crítica
6	Máxima

Fonte: Gennarelli, Wodzin e Barrington (2008)

O ISS é um sistema anatômico de pontuação, muito utilizado para determinar a gravidade de pacientes com múltiplas lesões, que tem sido adotado como instrumento de mensuração da gravidade do trauma, por ter correlação mais favorável com a taxa de mortalidade (FARRATH *et al.*, 2013), em que o mesmo é obtido através de

$$ISS = \sum_{j=1}^3 \max AIS_j^2. \quad (2.3)$$

em que AIS_j é o maior valor classificado das seis regiões mais afetadas.

Esse índice considera as regiões mais afetadas nos vários segmentos do corpo. Para o cálculo, o ISS utiliza a escala AIS, que classifica as lesões do trauma de acordo com uma escala numérica de gravidade. Além disto, o ISS pode variar de 1 a 75 pontos. Qualquer paciente com uma lesão AIS igual a 6 tem, por definição da literatura, ISS=75. Seu resultado é a soma dos quadrados dos valores mais elevados de três regiões diferentes do corpo. (OSLER; BAKER; LONG, 1997; NOGUEIRA; SOUSA; DOMINGUES, 2009; PARREIRA *et al.*, 2017).

Estudos com pacientes traumatizados têm evidenciado que a mortalidade para grupos de pacientes com valores ISS maior ou igual a 16 foi superior ao grupo com ISS menor do que 16 (MANTOVANI; FONTELLES; FRAGA, 2002; FRAGA *et al.*, 2004; ESTUMANO *et al.*, 2015). O ISS visa avaliar a gravidade do trauma, resultando em valores que podem gerar conhecimentos estatísticos acerca da sobrevida ou mortalidade do paciente (CHAMPION; SACCO; COPES, 1995; OSLER; BAKER; LONG, 1997; AYDIN *et al.*, 2008; PARK *et al.*, 2017).

Na Figura 2.2 estão ilustrados os segmentos corpóreos com mais gravidade de acordo com a escala AIS. O cálculo do ISS é baseado nas três regiões com maiores valores numéricos (FRAGA, 2007; NOGUEIRA; SOUSA; DOMINGUES, 2009).

Figura 2.2 – Regiões corporais para efeito do cálculo ISS

Fonte: Shutterstock (2018)

O ISS tem suas limitações. De acordo com alguns estudos, apesar da sua importância no estudo clínico de vítimas traumatizadas, o mesmo pode enviesar os valores no caso de vítimas com múltiplas lesões, uma vez que considera 3 regiões diferentes do corpo com as pontuações mais altas, medindo apenas uma lesão por região. Isso implica que lesões graves com altos valores estão escondidas, visto que estão na mesma área do corpo e não são consideradas para a análise do risco de vida do paciente (RAUM *et al.*, 2009; CAMILLONI *et al.*, 2010; ROWELL *et al.*, 2011; IMHOFF *et al.*, 2014; RESTREPO-ÁLVAREZ *et al.*, 2016).

Por muitos anos o ISS foi considerado um índice muito importante para medir a gravidade do trauma e, em 1997, foi proposta uma revisão com o intuito de melhorar seu desempenho na predição da taxa de mortalidade dos pacientes (OSLER; BAKER; LONG, 1997; HUSUM; STRADA, 2002; ZHAO *et al.*, 2008). Com o surgimento do novo índice, NISS, uma nova versão do ISS, a analogia da fórmula se manteve (soma dos quadrados dos valores mais elevados) mas sem discriminação por região do corpo, possibilitando considerar as regiões mais atingidas e uma melhor estimativa da mortalidade, principalmente em pacientes politraumatizados (CHAMPION, 2002; MOORE *et al.*, 2008; DOMINGUES, 2013).

Os índices de gravidade RTS e ISS são muito utilizados para estimativa de sobrevivência do paciente (AYDIN *et al.*, 2008). Seus cálculos são realizados após exames radiológicos, cirurgias ou autópsias (PARREIRA *et al.*, 2017).

Por fim, através do MTOS, ainda na década de 90, o ACS desenvolveu o TRISS, considerado como um parâmetro para avaliar a qualidade da assistência das instituições de atendimento

de trauma norte-americanas (CHAMPION *et al.*, 1981; LEFERING, 2009; DOMINGUES *et al.*, 2015). A determinação do TRISS correlaciona o índice RTS (fisiológico) e o ISS (anatômico), considerando também a idade do paciente e o mecanismo do trauma — contuso ou penetrante. O índice encontrado pode ser interpretado como uma verificação de pacientes que evoluíram para um resultado estatístico imprevisto ou como uma probabilidade de sobrevivência durante certo período (BOYD; TOLSON; COPES, 1987; WHITAKER, 2000; JÚNIOR *et al.*, 2007; ESTUMANO *et al.*, 2015; DOMINGUES *et al.*, 2015).

2.2 Avaliação Funcional

Para avaliar as atividades cotidianas dos pacientes foi utilizado o Índice de Barthel, em que o mesmo é dado por

$$IB = \sum_{i=1}^{10} x_i, \quad (2.4)$$

sendo x_i a pontuação obtida de cada pergunta respondida do questionário aplicado ao paciente.

O escore deste índice é obtido pela soma das pontuações dos itens classificados em 0, 5, 10 e 15, conforme a independência ou necessidade de auxílio para realizar as atividades (DIOGO, 2003; FONSECA; PENNA, 2008).

Ele aborda as atividades fundamentais da vida diária do paciente como, por exemplo, comer, higiene pessoal, uso dos sanitários, tomar banho, vestir e despir, controle de esfínteres, deambular, transferência da cadeira para a cama e subir e descer escadas. O objetivo deste índice é medir a capacidade do paciente de executar suas atividades diárias com independência. A escala numérica pode ser construída com 10 questões e classificada de 0 (zero) a 100, sendo de 0-20 (dependência total), 21-60 (grave dependência), 61-90 (moderada dependência), 91-99 (muito leve dependência) e 100 (paciente independente) (BARTHEL, 1965; ARAÚJO *et al.*, 2007; FONSECA; PENNA, 2008).

2.3 Qualidade de Vida

A saúde é um termo muito complexo de se conceituar. A OMS define saúde como "um completo estado de bem-estar físico, mental e social e não meramente a ausência de doença" (FLECK *et al.*, 2000). Para Scliar (2007), o conceito de saúde está ligado à circunstância social, econômica, política e cultural, o que significa que saúde tem significados diferentes de pessoa para pessoa.

A definição de qualidade de vida não é algo trivial, sendo que cada indivíduo tem uma percepção diferente da vida e maneiras distintas de julgar o que é importante para viver. A busca de uma ferramenta que avaliasse a qualidade de vida de pacientes motivou o Grupo de Qualidade

de Vida da OMS a desenvolver um projeto colaborativo, por meio do qual seria descrita a versão em português da metodologia do WHOQOL-100, um questionário com 100 itens no seu formato internacional (FLECK *et al.*, 1999).

Com o desenvolvimento do WHOQOL-100, o Grupo de Qualidade de Vida, com o objetivo de criar uma ferramenta com menor extensão e com mais agilidade na aplicação, propôs uma nova versão abreviada, o *World Health Organization Quality of Life* (WHOQOL-BREF), possuindo vinte e seis questões, sendo que duas abordam questões gerais sobre qualidade de vida e vinte quatro compreendendo quatro domínios: físico, psicológico, social e meio ambiente (GROUP *et al.*, 1998; FLECK *et al.*, 2000; KLUTHCOVSKY; KLUTHCOVSKY, 2009).

Como indicador de qualidade de vida dos pacientes com TCE foi utilizado o instrumento WHOQOL-BREF, empregue mundialmente em decorrência da sua fácil aplicação e compreensão (FLECK *et al.*, 2000). O preenchimento do questionário foi realizado em uma única visita e foi auto-administrado ou administrado por um entrevistador conforme as condições do paciente. O pesquisador permaneceu no local até o término do preenchimento (TAVARES, 2006).

A cada característica soma-se os valores dos itens de cada alternativa marcada e calcula-se a média de cada domínio. Os domínios são:

Domínio Físico é dado por

$$\overline{DF} = \frac{\sum_{i=1}^7 Q_i}{7}, \quad (2.5)$$

em que Q_i é a pontuação da questão.

Para obter o escore do domínio físico soma-se os valores de cada questão e divide por 7.

Domínio Psicológico é calculado através de

$$\overline{DP} = \frac{\sum_{j=1}^6 Q_j}{6}, \quad (2.6)$$

em que Q_j é a pontuação da questão.

O escore do domínio psicológico é obtido somando as questões e dividido por 6.

Relação Social é obtida por

$$\overline{RS} = \frac{\sum_{k=1}^3 Q_k}{3}, \quad (2.7)$$

em que Q_k é a pontuação da questão.

O valor do escore da relação social é dado pela soma das pontuações de cada questão e dividido por 3.

Meio Ambiente é calculado por

$$\overline{MA} = \frac{\sum_{w=1}^8 Q_w}{8}, \quad (2.8)$$

em que Q_w é a pontuação da questão.

O resultado do escore do meio ambiente é dado pela soma das pontuações e dividido por 8.

A seguir são apresentados os Domínios e Facetas do *WHOQOL-BREF*.

Quadro 2.4 – Facetas do *WHOQOL-BREF*

Domínio 1 - Domínio físico	Domínio 2 - Domínio psicológico
Dor e desconforto Energia e fadiga Sono e repouso Mobilidade Atividades da vida cotidiana Dependência de medicação Capacidade de trabalho	Sentimentos positivos Pensar, aprender, memória e concentração Autoestima Imagem corporal e aparência Sentimentos negativos Espiritualidade/religião/crenças pessoais
Domínio 3 - Relações sociais	Domínio 4 - Meio ambiente
Relações pessoais Suporte (apoio) social Atividade sexual	Segurança física e proteção Ambiente no lar Recursos financeiros Cuidados de saúde e sociais: disponibilidade e qualidade Oportunidades de adquirir novas informações e habilidades Participação em, e oportunidades de recreação Ambiente físico Transporte

Fonte: [Fleck et al. \(2000\)](#)

O Quadro 2.5 demonstra as fórmulas dos índices utilizados nesse estudo.

Quadro 2.5 – Resumo das fórmulas dos índices

NOME	SIGLA	FÓRMULA
Índices de gravidade: São pontuações, quantificados por <i>score</i> numéricos, que variam de acordo com a intensidade e os tipos de lesões decorrentes do traumatismo, medidos através de parâmetros anatômicos, fisiológicos e combinados.		
<i>O Revised Trauma Score</i>	RTS	$RTS = 0,9368 * (GCS) + 0,7326 * (PAS) + 0,2908 * (FR).$
Escala Coma Glasgow	GCS	$GCS = \sum_{i=1}^{13} x_{(i)}, i - \text{ésima medição}$
<i>Abbreviated Injury Scale</i>	AIS	Escala numérica.
<i>O Injury Severity Score</i>	ISS	$ISS = \sum_{j=1}^3 \max AIS_j^2, j - \text{ésima região}.$
Índice de Barthel	IB	$IB = \sum_{i=1}^{10} x_i, x_i \text{ é a pontuação obtida de cada questão}.$
<i>WHOQOL-BREF</i>	Q_{BREF}	$\overline{DF} = \frac{\sum_{i=1}^7 Q_i}{7}, \overline{DP} = \frac{\sum_{j=1}^6 Q_j}{6}, \overline{RS} = \frac{\sum_{k=1}^3 Q_k}{3} \text{ e } \overline{MA} = \frac{\sum_{w=1}^8 Q_w}{8},$

Fonte: autor (2018)

O Quadro 2.6 apresenta uma breve descrição dos índices utilizados nesse estudo.

Quadro 2.6 – Resumo das descrições dos índices

NOME	SIGLA	DESCRIÇÃO
<i>O Revised Trauma Score</i>	RTS	O RTS é um <i>score</i> avalia a alteração fisiológica do paciente, considera para o cálculo três componentes: Escala de Coma de Glasgow (GCS), Pressão Arterial Sistólica (PAS) e Frequência Respiratória (FR).
<i>Glasgow Coma Scale</i>	GCS	GCS é uma ferramenta clínica possui valor preditivo para avaliar pacientes com mudanças no nível de consciência, sua pontuação contribui na determinação de severidade do trauma, a interpretação clínica do paciente e pode auxiliar o especialista na escolha do melhor estudo clínico.
<i>Abbreviated Injury Scale</i>	AIS	A AIS é um índice de base anatômica que classifica as lesões corpóreas das regiões que sofreram o trauma, onde variam de 1 a 6, sendo 1 — Leve; 2 — Moderada; 3 — Séria, sem risco de vida; 4 — Grave, com risco iminente de vida, 5 — Crítica, com poucas chances de vida e 6 — Máxima, normalmente fatal.
<i>O Injury Severity Score</i>	ISS	O ISS é um <i>score</i> classificador anatômico, baseado na <i>Abbreviated Injury Scale</i> (AIS) que é uma lista elaborada de milhares de lesões conforme a gravidade. Para cálculo considera as três regiões mais afetadas do corpo.
Índice de Barthel	IB	O Índice de Barthel aborda as atividades fundamentais da vida diária do paciente como, comer, higiene pessoal, uso dos sanitários, tomar banho, vestir e despir, controle de esfínteres, deambular, transferência da cadeira para a cama, subir e descer escadas. Sua escala varia de 0 a 100.
<i>WHOQOL-BREF</i>	Q_{BREF}	Como indicador de qualidade de vida dos pacientes com TCE foi utilizado o instrumento WHOQOL-BREF. Verifica-se que os escores médios entre os quatro domínios.

Fonte: autor (2018)

Divulgado pela OMS (2015), traumas, sobretudo por lesões de trânsito, continuam sendo a principal causa de morte de indivíduos jovens. As taxas mais altas concentram-se na região

africana, enquanto as taxas mais baixas são observadas nas regiões da Europa, principalmente em países com renda alta. Ainda segundo o relatório de 2012, foram registradas mais de 300 mil mortes ocasionadas por acidentes de trânsito em jovens com idade entre 15 e 29 anos, seguidas de suicídio e HIV/AIDS com aproximadamente 250 mil.

Na seção seguinte veremos os referenciais das técnicas de aprendizado estatístico, que foram aplicadas na base de dados a fim de estimar o risco de vida dos pacientes.

2.4 Aprendizado Estatístico

O Aprendizado Estatístico é composto por um conjunto diversificado de ferramentas para modelar e extrair conhecimento de um banco de dados. O aprendizado pode ser dividido em duas partes: supervisionados ou não-supervisionados. O supervisionado compreende a construção de um modelo estatístico para prever ou estimar *outputs* a partir de *inputs*. Já o não-supervisionado estuda os *inputs* sem a existência dos *outputs*. Apesar da denominação Aprendizado Estatístico ser empregada com maior frequência atualmente, seus conceitos foram desenvolvidos há muitos anos, mas sua abordagem tornou-se mais aplicável em meados da década de 80. Com o avanço da tecnologia computacional, essa ferramenta manifestou-se como um novo segmento na estatística, com foco na modelagem e na predição de dados (JAMES *et al.*, 2013). Para Vapnik (1999), o Aprendizado Estatístico é fundamentado na formulação matemática e estatística para o estudo de dados, possibilitando estimar a aprendizagem que caracteriza o comportamento do algoritmo. Por sua vez, pesquisadores têm se atraído pelo uso dessa ferramenta, já que ela oferece novas abordagens algorítmicas que se embasam em princípios computacionais aplicados a problemas que precisam de estimativas ou predições. Sua estrutura fortalece a relação de classificação dos dados, minimizando o erro no treinamento (HAYKIN, 1999; LORENA; CARVALHO, 2007; VAPNIK, 2013).

A composição de um modelo é uma etapa importante, pois os resultados mostram uma melhoria na precisão, mas infelizmente, as coisas são um pouco mais complicadas, há uma necessidade de avaliar o desempenho do modelo no conjunto de treinamento e saber o quão ele está generalizando no aprendizado, se o treinamento ocorrer por um longo tempo, o modelo pode se ajustar demais aos dados, o que evidencia que os ruídos e as imprecisões também serão aprendidas e o modelo não será capaz de generalizar para os dados de teste, se tornando um aprendizado não útil, nesta situação dizemos que o modelo está com sobre ajuste ou ainda com “*overfitting*” (MARSLAND, 2011).

A quantidade de dados produzidos pela população aumenta de forma acelerada, gerando desafios e sendo conhecida como *Big Data* (BELLINGER; CASTRO; MILLS, 2004; ZAKIR; SEYMOUR; BERG, 2015; WANG *et al.*, 2016). Esses dados, que são produzidos em larga escala, podem trazer benefícios econômicos importantes para empresas privadas, setores públicos, assim como para os cidadãos. Com a utilização dos conhecimentos extraídos dessas informações, é

possível criar estratégias que aumentem a produtividade e a competitividade, proporcionando melhorias para a população (MANYIKA *et al.*, 2011; WALKER, 2014). Pode-se entender o *Big Data* como um conjunto de tecnologias, processos e práticas que gera informações que permitem aos pesquisadores extraírem conhecimento para organizações que, por sua vez, podem estimar suas decisões com maior confiabilidade (RUSSOM, 2013; OLSHANNIKOVA *et al.*, 2015). O Aprendizado Estatístico tornou-se um instrumento importante para análise dessas bases de dados, visto que utiliza abordagens mais rápidas e eficazes, que geram conhecimentos que podem viabilizar o processo de estudo e colaborar nas estratégias adotadas pelos setores (IGNÁCIO, 2012). Uma das primeiras publicações sobre essa área aconteceu em 2001, *The Elements of Statistical Learning*, e sua segunda edição em 2009, tornando-se um tema popular nas diversas áreas do conhecimento (FRIEDMAN; HASTIE; TIBSHIRANI, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009b).

Objetivando-se melhorar a compreensão da aplicação do Aprendizado Estatístico, podemos considerar os três seguintes estudos: o *Wage Data*, que investiga uma sequência de elementos relacionados com os salários de um grupo de homens na região atlântica dos Estados Unidos, associando as variáveis idade, educação e estado civil de um funcionário com o seu salário; o *Stock Market Data*, que analisa o comportamento do mercado de ações que compreende movimentos diários nos índices em um período de 5 anos, com o intuito de prever índices superiores ou inferiores em determinado dia, utilizando informações de uma série de acontecimentos decorridos durante certo período; e o *Gene Expression Data*, que envolve apenas variável de entrada, tentando-se prever uma variável de saída, conhecida como um problema de clusterização. Este conjunto de dados consiste na medição de expressão gênica para cada uma das linhas celulares de câncer que, ao invés de prever uma variável de saída, interessa-se em encontrar grupos, ou *clusters*, entre as linhas de células com base nas suas medições de expressão gênica (JAMES *et al.*, 2013). Métodos de classificação têm sido muito utilizados pela comunidade científica em aplicações reais. O uso dessas técnicas pode gerar informações que possibilitam previsões mais confiáveis, além de serem computacionalmente eficientes com grandes quantidades de dados (BREIMAN, 2001; SCHNEIDER; FRIEDL; POTERE, 2009; SANTOS *et al.*, 2012; ANDRADE *et al.*, 2013; BROWN *et al.*, 2013; SARMIENTO *et al.*, 2014).

Na seção a seguir será apresentado o referencial teórico das principais técnicas de classificação utilizadas para a previsão e para o reconhecimento das relações entre as variáveis. Para tanto, foram testados os modelos GLM, RF, SVM e Redes probabilísticas (NB).

2.4.1 Generalized Linear Model (GLM)

A seguir será apresentada uma descrição teórica do GLM que, por sua vez, trata-se de uma extensão dos Modelos Lineares (LEE; NELDER, 1998), neste trabalho sendo considerado a função de ligação logit. Esse modelo oferece técnicas fundamentais para estudos estatísticos

de problemas reais apresentados por diversas áreas como agricultura, economia, engenharia, medicina, entre tantas outras que dependem da interpretação de dados (LINDSEY, 2000).

Introduzida por Nelder e Baker (1972), esta ferramenta relaciona a união de diversos modelos estatísticos, unificando os mesmos em um único modelo que possui como casos especiais os modelos de regressão linear clássico, os modelos de análise de variância e covariância, o modelo de regressão logística, o modelo de regressão de Poisson, os modelos log-lineares, o modelo *probit*, entre outros, permitindo obter as estimativas dos parâmetros por meio do método de máxima verossimilhança. Essa classe de modelos é definida pela transformação das variáveis preditoras, que descrevem a estrutura do modelo em probabilidades, estimando a variável resposta. Ela apresenta algumas limitações com sua estrutura de linearidade para variável explicativa e a restrição de independência das variáveis respostas (LEE; NELDER, 1998; LINDSEY, 2000; SANT'ANNA, 2006). Com os avanços computacionais ao longo dos anos, o GLM tem se mostrado de grande importância na modelagem estatística (TURKMAN; SILVA, 2000). Os GLMs se desenham no formato do modelo de regressão linear e têm como objetivo reunir procedimentos estatísticos em uma única família, a fim de encontrar uma transformação para estabilizar ou reduzir a variabilidade existente e normalizar os dados que antes eram tratados separadamente (LEE; NELDER, 1998). Esses modelos abrangem diferentes distribuições que pertencem à família exponencial, que podem ser consideradas na função de ligação, dentre elas podemos citar as distribuições normal, Poisson, binomial, multinomial, Gama, binomial negativa e a inversa gaussiana (COX, 1996; LEE; NELDER, 1998; PAULA, 2013; RAMOS *et al.*, 2017).

Para Cordeiro e Demétrio (2008), a escolha de modelos é de fundamental importância para o sucesso da modelagem estatística, sendo importante encontrar um modelo de fácil entendimento, que descreva o comportamento dos dados da pesquisa. Por sua vez, Cordeiro e Demétrio (2008) e Nelder e Baker (1972) mostraram que a combinação de modelos de regressão linear, seguindo a teoria da unificação de modelagem estatística, produz os GLMs, que seguem uma distribuição de probabilidade pertencente à família exponencial, que incluem uma variável resposta univariada, variáveis explicativas e uma seleção de amostra aleatória de n observações independentes. Os GLMs podem ser caracterizados da seguinte forma:

i) a variável resposta (Y), componente aleatório do modelo, segue uma distribuição pertencente à família exponencial, que relaciona várias distribuições.

ii) as variáveis explicativas $X_1, X_2, X_3, \dots, X_i$, que compõem os componentes do modelo e se estruturam de forma linear, estabelecendo o componente sistemático do modelo.

iii) a relação entre os componentes aleatórios (variável resposta) e sistemáticos (variáveis explicativas), utilizados para formar uma função, denominada função de ligação.

No GLM, cada resposta de Y das variáveis dependentes é assumida como sendo gerada a partir de uma distribuição específica na família exponencial. A média μ da distribuição depende

das variáveis independentes da classe de X , através de

$$E(Y) = \mu = g^{-1}(X\beta), \quad (2.9)$$

onde $E(Y)$ é o valor esperado de Y ; $X\beta$ é o preditor linear, uma combinação linear de parâmetros desconhecidos β ; g é a função de ligação.

Nesta estrutura, a variância é uma função, V , da média:

$$Var(Y) = V(\mu) = V(g^{-1}(X\beta)). \quad (2.10)$$

Os parâmetros desconhecidos, β , são tipicamente estimados por máxima verossimilhança, máxima quase-verossimilhança ou técnicas bayesianas.

É conveniente que V siga uma distribuição da família exponencial, mas pode ser simplesmente que a variação seja uma função do valor preditivo. Os parâmetros desconhecidos, β , são estimados com máxima verossimilhança, máxima quase-verossimilhança ou técnicas bayesianas.

Componentes do GLM consiste em três elementos:

1. Uma distribuição de probabilidade da família exponencial.
2. Um preditor linear $\eta = X\beta$.
3. Uma função de ligação g tal que $E(Y) = \mu = g^{-1}(\eta)$.

A família de distribuições exponencial é uma generalização da família exponencial e modelo de dispersão exponencial de distribuições e inclui essas distribuições de probabilidade, parametrizadas por θ e τ , cuja função densidade f pode ser dada por

$$f_y(y|\theta, \tau) = h(y, \tau) \exp\left(\frac{\mathbf{b}(\theta)^T \mathbf{T}(y) - A(\theta)}{d(\tau)}\right), \quad (2.11)$$

em que o parâmetro de dispersão τ , normalmente e geralmente está relacionado à variação da distribuição. As funções $h(y, \tau)$, $\mathbf{b}(\theta)$, $\mathbf{T}(y)$, $A(\theta)$ e $d(\tau)$ são conhecidas. Muitas distribuições comuns estão nesta família, incluindo os binômios normal, exponencial, gama, Poisson, Bernoulli e binomial, multinomial e negativo.

2.4.2 Random Forest (RF)

Nesta seção será apresentada uma descrição do funcionamento e da construção do algoritmo RF, que é um classificador formado por um conjunto de métodos preditores, constituídos de várias árvores de decisão, independentes e divididas de forma similar. Cada árvore recebe um voto que indica a decisão sobre a classe à qual vai pertencer um dado objeto. Nesse sentido, o objeto pertencerá à classe com maior número de votos estimado (BREIMAN, 2001; RODRIGUES;

AMARAL, 2012; KRUPPA *et al.*, 2013; TELOKEN *et al.*, 2016). Este algoritmo sustentado por Breiman (2001), relaciona-se com os conceitos de *Bagging*, com escolhas aleatórias de parâmetros para adicionar ao modelo da árvore de decisão. As vantagens desse classificador são: a sua execução rápida, a não dificuldade com *overfitting* e a utilização de apenas uma parte aleatória do conjunto de observações, demonstrando força no processamento com dimensionalidade dos dados que, por sua vez, não requer estimativas sobre a distribuição dos dados (GUO *et al.*, 2011; LANTZ, 2013).

O RF reúne uma coleção de classificadores organizados por árvores de decisão, que geram amostras aleatórias do conjunto de treinamento. Tendo um conjunto de treinamento, cada árvore é separada por uma amostra aleatória, onde cada amostra é construída de maneira independente, mas com a mesma distribuição para todas as árvores. Esse classificador seleciona aleatoriamente os conjuntos por suas características e divide por nó de cada árvore, onde cada nó recebe um novo subconjunto de características (GISLASON; BENEDIKTSSON; SVEINSSON, 2006; TIBSHIRANI *et al.*, 2013).

De outro modo, no processo de classificação RF, uma seleção de classificadores é atribuída para a árvore de decisão. Esse classificador utiliza um conjunto de árvores de decisão $h(x, \theta_k)$, $k = 1, \dots$, em que θ_k são vetores aleatórios independentes divididos igualmente, e cada árvore vota pela classe mais comum em X .

Dado um conjunto de classificadores $h_1(x)$, $h_2(x)$, $\dots$, $h_K(x)$, e um conjunto de treinamento aleatório a partir do vetor Y, X . A função da margem do classificador é dada por

$$mg(X, Y) = av_k I(h_k(X) = Y) - \max_{j \neq y} av_k I(h_k(X) = j), \quad (2.12)$$

em que I é a função indicador, av_k é a média dos votos e a classe $h_k(X)$ é a precisão de X conforme o classificador construído utilizando o vetor randômico k . A precisão do classificador para a previsão de um determinado padrão de X aumenta conforme aumenta a margem. A correlação das árvores aumenta, a força do conjunto tende a diminuir ou o limite do erro de generalização tende a aumentar. O limite erro generalizado converge quando o número de árvores for suficientemente grande (GÓMEZ, 2012), e pode ser visto pela fórmula

$$PE^* = P_{X,Y}(mg(X, Y) < 0). \quad (2.13)$$

Para um número grande de árvores decorre da *Strong Law of Large Numbers* e da estrutura da árvore que denota na equação a dada por

$$P_{X,Y}(P_\theta(h(X, \theta) = Y) - \max_{x \neq y} P_\theta(h(X, \theta) = j) < 0), \quad (2.14)$$

em que $h(X, \theta_k)$ é uma reunião de classificadores estruturados em árvores ou florestas aleatórias, por sua vez, θ são vetores independentes e similarmente partilhados e cada árvore vota pela

classe mais comum em X .

É importante ressaltar que RF não tem problemas com *overfitting*. Adota-se um número suficientemente grande para que o erro se estabeleça, um número grande não ocasionará *overfitting*. As árvores são sempre adicionadas, mas produzem o valor limite de erro de generalização (GÓMEZ, 2012; JAMES *et al.*, 2013).

Na prática, adota-se um número suficientemente grande para que o erro se estabeleça - um número grande de B não ocasionará *overfitting*.

Se a aleatoriedade aumenta, *Bagging* pode ser utilizado no conjunto com a seleção aleatória de características. O novo conjunto de treinamento é gerado por substituição a partir do vetor de entrada inicial, e uma nova árvore é compelida a partir de um novo conjunto de treinamento, utilizando seleção aleatória de características. As árvores atingem o seu maior tamanho e não é realizada a poda sobre elas. Podemos ter duas razões para a utilização de *Bagging*: a primeira é que a sua utilização tem melhor desempenho na precisão, quando utilizada característica aleatória; e a segunda é que ele pode ser usado para estimar o erro de generalização da relação dos conjuntos de árvores, bem como prever a força da correlação durante o processo (HASTIE; TIBSHIRANI; FRIEDMAN, 2009a; GÓMEZ, 2012).

Na Figura 2.3 é possível observar que, a partir de uma base de dados X , elabora-se múltiplas RF, onde cada uma é construída através de regras, possibilitando descobertas de novos padrões que corroboram para uma tomada de decisão mais confiável. Com as árvores criadas, calcula-se qual delas apresenta o melhor desempenho. Para isso é feita a seleção para obter o resultado Y (TELOKEN *et al.*, 2016).

Figura 2.3 – Representação gráfica do modelo de classificação RF, sendo x os dados de entrada que são classificados por todas as árvores

Fonte: Teloken *et al.* (2016)

A construção das árvores se dá pela escolha aleatória das características dos atributos, que são alocados nos nós de cada uma das árvores geradas. A RF é o conjunto de todas as árvores. (TELOKEN *et al.*, 2016).

2.4.3 Support Vector Machine (SVM)

As SVMs são métodos que utilizam técnicas de Aprendizado Estatístico para classificação e descoberta de padrões em conjuntos de dados, obtendo informações que podem auxiliar na tomada de decisão. Tais técnicas vêm sendo aplicadas com sucesso em diversas áreas, na identificação de faces, na categorização de textos, entre outras (CAMPBELL, 2002; LORENA; CARVALHO, 2007; TZOTSOS; ARGIALAS, 2008; TAKAHASHI, 2012). A partir da década de 90, as SVMs têm sido muito utilizadas nas universidades, laboratórios e empresas, principalmente quando se trata de dados com alta dimensionalidade (MITCHELL *et al.*, 1997). O modelo obtido pelos SVM é usado para discriminar o alvo específico no conjunto de dados, estimando uma nova categoria de dados da base em que ocorreu o aprendizado e, com isso, projetando padrões e informações relevantes (LORENA; CARVALHO, 2007; HONG *et al.*, 2015).

As principais vantagens dos modelos SVM são: a elevada capacidade de generalização, por meio da qual os *overfitting* são evitados e a minimização do risco empírico, do risco estrutural e da dimensionalidade. Estão sendo muito utilizados em problemas de classificação para modelagem e têm se mostrado eficientes na previsão de dados que não pertençam ao conjunto de treinamento, evitando o “*overfitting*”. As SVMs têm se sobressaído à maioria das técnicas de Aprendizado Estatístico, obtendo baixo erro no conjunto de treinamento e alta intensidade no conjunto de teste, enquanto a maioria das técnicas tem encontrado dificuldades no aprendizado dos dados, em decorrência da dimensionalidade e na construção da função objetivo. As SVMs mais utilizadas são: **Linear, Polinomial, Gaussianas e Sigmoidal** (FERRÃO *et al.*, 2007).

Os parâmetros do hiperplano, que maximizam a separação da margem são o vetor peso w e o centralizado w_0 que minimiza a Equação 2.15 e satisfaz a Equação 2.16. Cada hiperplano é caracterizado por sua direção (determinada por w) e sua posição exata no espaço (determinada por w_0).

$$J(w, w_0) = \frac{1}{2}w^2, \quad (2.15)$$

$$y_i(w^T x_i + w_0) \geq 1, i = 1, 2, \dots, N, \quad (2.16)$$

em que N é o número de padrões a serem classificados (TZOTSOS; ARGIALAS, 2008; NASCIMENTO *et al.*, 2016).

Para classes não-separáveis, os parâmetros podem ser calculados por

$$J(w, w_0, \xi) = \frac{1}{2}w^2 + C \sum_{i=1}^N \xi_i, \quad (2.17)$$

em que o parâmetro C é uma constante positiva que controla a influência relativa dos dois termos e ξ são novas variáveis conhecidas como variáveis de folga. A tarefa de otimização fica mais

complexa. A tentativa agora é que a margem fique a maior possível, mas mantenha o valor de $\xi > 0$ o menor possível.

Esta ferramenta, por sua vez, tem o objetivo de encontrar o hiperplano de divisão ótima, que minimiza o erro da classificação para novos pontos que não foram encontrados do conjunto teste. A princípio, a ideia é maximizar a distância entre as margens e os pontos, mantendo as distâncias iguais para cada classe, porém, isso nem sempre ocorre, visto que os dados podem não ser linearmente separáveis. Para isso, ajusta-se o modelo usando uma função *kernel* não-linear que calcula os vetores de suporte para cada ponto e, em seguida, separa em uma dimensão onde os dados se tornam linearmente separáveis, deixando o algoritmo com um desempenho mais eficiente (BURGES, 1998; LORENA; CARVALHO, 2007; JAMES *et al.*, 2013). Depois do processo de mapeamento dos pontos do conjunto teste, é utilizada a função de decisão dada em (2.18), que encontra o hiperplano com máxima margem e mapeia o novo ponto no espaço em sua classe, sendo assim atribuída em função de qual lado do hiperplano o ponto está localizado (SOUZA, 2014). Tal função é dada por

$$f(X^T) = \sum_{i=1}^l y_i \alpha_i K(X_i, X_j) + b, \quad (2.18)$$

onde X^T é um dado do conjunto teste, l o número de vetores de suporte, y_i é o rótulo da classe do vetor de suporte, α_i e b são os parâmetros encontrados durante o treinamento e $K(X_i, X_j)$ é a função de *kernel* que calcula o produto do dado do conjunto de teste para cada um dos vetores de suporte.

Figura 2.4 – Um hiperplano para a classificação de exemplos das classes 1 e 2

Fonte: Han, Pei e Kamber (2011)

A Figura 2.4 ilustra dois gráficos, **a** e **b**, que estão separados por duas classes de observações, os hiperplanos de margem pequena e máxima, respectivamente. Os pontos que se encontram nas linhas tracejadas representam os vetores de suporte e a distância entre esses pontos e a margem é indicada por setas (JAMES *et al.*, 2013). O hiperplano com margem máxima deve ter maior precisão de generalização em relação ao de margem menor (HAN; PEI; KAMBER, 2011).

2.4.4 Redes Probabilísticas (Naïve Bayes)

Este algoritmo, muito utilizado na abordagem de modelos probabilísticos, é aplicado em problemas que buscam estimar a melhor alternativa para a classificação mais viável, com base em probabilidades. É apontado como um classificador simples (ingênuo), por assumir que todos os atributos são condicionalmente independentes, dado o valor da classe. Muito aplicado para classificação de spam, análise de perfil, previsão de risco e mineração de dados (DOMINGOS; PAZZANI, 1997; DUMAIS *et al.*, 1998; ZHANG, 2004). Esse algoritmo é muito utilizado em Aprendizado Estatístico e é um classificador probabilístico embasado pelo Teorema de Bayes, o qual foi criado por Thomas Bayes. Trata-se de uma probabilidade condicional, por meio da qual se verifica as chances de um evento ocorrer dado um evento conhecido *a priori*. (PEREZ; LARRANAGA; INZA, 2006).

Por ser muito simples e rápido, possui um desempenho relativamente maior do que

outros classificadores

O teorema de Bayes é utilizado para calcular a probabilidade de estimar a classificação mais provável de $X = (x_1, x_2, \dots, x_n)$ dado a classe w_i , tal probabilidade é calculada através de

$$P(w_i|x) = \frac{P(x|w_i) * P(w_i)}{P(x)}, \quad (2.19)$$

na qual $P(w_i)$ é a priori, $P(x|w_i)$ é a verossimilhança, $P(X) = \sum_{j=1}^n P(x|w_j) * P(w_j)$ é a evidência e $P(w_i|x)$ é a posteriori, sendo que a tomada de decisão é feita na posteriori.

Simplificando o cálculo de $P(w_i|x)$ e assumindo que todas as variáveis são condicionalmente independentes, a função é dada por

$$NB = \arg \max_{w_i \in x} P(w_i) \prod_i P(w_i|x), \quad (2.20)$$

em que $P(w_i)$ é a *priori* e $\prod_i P(w_i|x)$ é o produto da probabilidade de cada variável dada a classe.

Este classificador é mais restritivo do que os outros, pois não permite dependências entre as classes (CARVALHO *et al.*, 2011). O classificador não considera interações entre os conjuntos de classes com mais de dois elementos, visto que isso pode ocasionar um viés na função de decisão e pode não convergir para a função ótima. No entanto, esse viés é compensado por uma variação menor das estimativas, tendo que lidar apenas com unidimensionalidade $P(w_i)$ e estimativas bidimensionais das funções $P(w_i|X)$, simplificando o aprendizado e facilitando a compreensão do modelo obtido (SANTOS, 2010).

No próximo capítulo serão detalhados os procedimentos metodológicos a que se referem os dados analisados, classificando a pesquisa quanto aos objetivos, procedimentos, questão de pesquisa e amostragem (BOOTH; COLOMB; WILLIAMS, 2008).

2.4.5 Métricas de Desempenho para Problemas de Duas Classes

2.4.5.1 Matriz de Confusão

Para avaliar as precisões dos classificadores utilizou-se uma importante técnica de estimativa dos valores produzidos pelos classificadores, denominado matriz de confusão, considerando seus respectivos pontos ótimo. O objetivo é comparar as respostas resultantes dos modelos com as respostas verdadeiras ou originais. Para problemas de classificação binária, esta técnica é muito utilizada para analisar os resultados encontrados por cada classificador (CHAGAS *et al.*, 2009; FACELI *et al.*, 2011; VIANA *et al.*, 2015). A Figura 2.5 ilustra uma tabela da matriz de confusão, em que VP são os verdadeiros positivos (número de exemplos da classe positiva e que foram corretamente classificados), VN são os verdadeiros negativos (o número de exemplos da classe negativa e que foram corretamente classificados), FP são os falsos positivos (número de exemplos da classe negativa e que foram incorretamente classificados pelo modelo) e FN

são os falsos negativos (número de exemplos da classe positiva e que foram incorretamente classificados).

		Classe predita	
		+	-
Classe verdadeira	+	VP	FN
	-	FP	VN

Figura 2.5 – Matriz de confusão para um problema de duas classes

Fonte: [Faceli et al. \(2011\)](#)

As medidas de desempenho baseados na matriz de confusão e utilizadas neste trabalho são descritas abaixo:

– **Acurácia (Accuracy- ACC):** é a razão da soma de todos os casos corretamente classificados, independente da classe, pelo número total de objetos no conjunto teste ([FACELI et al., 2011](#); [VIANA et al., 2015](#)). É dada por

$$ACC = \frac{VP + VN}{VP + VN + FN + FP} \quad (2.21)$$

– **Sensibilidade (Sensitivity - SEN):** corresponde à taxa de acerto na classe positiva, ou seja, determinar o evento dado que realmente ocorreu ([FACELI et al., 2011](#); [VIANA et al., 2015](#)). É dada por

$$SEN = \frac{VP}{VP + FN} \quad (2.22)$$

– **Especificidade (Specificity - SPE):** corresponde à taxa de acerto na classe negativa, é complementar à sensibilidade, indica o quão bom o modelo é para determinar o não evento, dado que o evento realmente não ocorreu ([FACELI et al., 2011](#); [VIANA et al., 2015](#)). É dada por

$$SPE = 1 - SEN = \frac{VN}{VN + FP} \quad (2.23)$$

– **Matthews Correlation Coefficient (MCC)** o coeficiente de correlação de Matthews é utilizado em Aprendizado Estatístico como uma medida da qualidade das classificações binárias, introduziu por [Matthews \(1975\)](#). Este método considera os verdadeiros e falsos positivos e negativos. O MCC é um coeficiente de correlação entre as classificações de duas classes de precisão; seus valores variam entre -1 e 1, um valor de 1 representa uma previsão perfeita, 0 não

é melhor do que a previsão aleatória e -1 demonstra divergência entre a previsão e a observação (POWERS, 2011). Ele pode ser calculado diretamente da matriz de confusão e é dada por

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (2.24)$$

2.4.5.2 Curva ROC

A curva ROC é uma ferramenta de avaliação gráfica, utilizada em Aprendizado Estatístico para a avaliação de modelos, sendo um método poderoso para avaliar modelos de classificação (SPACKMAN, 1989; BRADLEY, 1997; PRATI; BATISTA; MONARD, 2008). Para Prati, Batista e Monard (2008) estes gráficos possibilitam uma melhor visualização bidimensional do problema, onde no eixo X é representado pela Taxa de Falsos Positivos (TFP) e no eixo Y a Taxa de Verdadeiros Positivos (TVP), em que o modelo de classificação é denotado por um ponto no espaço ROC. Para encontrar esse ponto no espaço, calcula-se a taxa de verdadeiros e falsos positivos do modelo através dos resultados obtidos da sua matriz de confusão. O ponto (0,0) no espaço ROC corresponde à estratégia de não classificar uma observação positiva, modelos que coincidem com esse ponto não apresentam falso positivo e não classificam um verdadeiro positivo. Já o inverso (1,1), sempre representa uma classificação positiva. O ponto (0,1) representa as taxas de verdadeiros positivos e verdadeiros negativos, ou seja, foram classificados corretamente, quanto mais próximo deste ponto, melhor será a classificação, sendo um modelo perfeito. A linha diagonal representa as classificações aleatórias dos modelos, pontos que pertencem ao espaço ROC superior à diagonal, podem ser considerados modelos que apresentam melhor desempenho que o aleatório e pontos pertencentes abaixo podem representar um modelo pior do que o aleatório. (BRAGA, 2001; PRATI; BATISTA; MONARD, 2008; FACELI *et al.*, 2011).

Na Figura 2.6 são apresentadas as principais características de um espaço ROC, a linha diagonal determina os classificadores que desempenham previsões aleatórias.

Figura 2.6 – Exemplo de Espaço ROC com três classificadores

Fonte: [Faceli et al. \(2011\)](#)

Quando comparadas duas ou mais curvas, aquela que mais se aproxima do ponto (0,1) é a que apresenta os melhores resultados na classificação dos dados. Cada modelo apresenta uma região com melhor performance que do outro. Uma medida muito utilizada para comparar o resultado de cada modelo é a AUC que gera valores entre 0 e 1, os valores que mais se aproximam de 1 são considerados os melhores, ou seja, o modelo com melhor desempenho ([FACELI et al., 2011](#)).

O ponto (0,0) na Figura 2.6 representa a maioria das classificações negativas e o maior ponto de corte possível, já o ponto (1,1) são as classificações positivas, onde o ponto de corte diminui, o ponto (0,1) são as classificações perfeitas, onde todas as observações são positivas e negativas e classificadas perfeitamente, por isso chamada de céu ROC, inverso a isso, o ponto (1,0) representa o inferno ROC ([FACELI et al., 2011](#); [HABIBZADEH; HABIBZADEH; YADOLLAHIE, 2016](#)).

MATERIAL E MÉTODOS

Para um aprofundamento do cenário brasileiro em relação às vítimas de trauma, foi pesquisado os falecimentos por CE em 2015. As informações coletadas provêm do banco de dados do Departamento de Informática do Sistema Único de Saúde (DATASUS). Na Figura 3.7 são apresentados os percentuais de mortes nas cinco regiões do país.

Figura 3.7 – Percentual de mortes por CE no Brasil em 2015

Fonte: autor (2018)

Observa-se que a região Sudeste tem a maior proporção de mortes por causas externas, 34%, seguida da região Nordeste com 30%. É importante ressaltar que, embora a região Sudeste do Brasil seja a segunda menor região do país, ocupando uma área de cerca de 924.620 km^2 , ela é a região brasileira com o maior número absoluto de pessoas e de densidade demográfica. Essa região é a mais desenvolvida do país, responsável pela maior arrecadação do Produto Interno

Bruto, com maior industrialização, centros urbanos e, conseqüentemente, graves problemas sociais relacionados ao acelerado crescimento das cidades.

Verifica-se na Figura 3.8 a distribuição de mortes por acidentes de transporte, por regiões brasileiras, em 2015, referente às estatísticas do DATASUS. Na região Nordeste, por exemplo, predominam os falecimentos por acidentes de motocicleta. Na região Sudeste, por sua vez, três grupos se destacam; mortes ocorridas por automóveis, caminhonetes e veículos pesados, mortes por motocicletas e acidentes com pedestres.

Figura 3.8 – Distribuição das ocorrências de óbitos por acidentes de transporte dividido por categorias em diferentes regiões brasileiras

Fonte: autor (2018)

Na

2018)efsecao:material serão discutidos aspectos históricos da forma de coleta das informações dos pacientes com traumas provenientes de um hospital do interior do estado de São Paulo. Em seguida, a

2018)efsecao:dados descreverá o banco de dados, assim como a sua sistematização e as formas adotadas de notificação de traumas. Por fim, na

2018)efsecao:metodos será apresentada a aplicação dos métodos descritos no referencial teórico, considerando a problemática abordada.

3.1 Material

Desde 1996, no Brasil, o Núcleo Hospitalar de Epidemiologia (NHE), da Unidade de Emergência (UE), criou uma ficha de vigilância epidemiológica dos traumas ocorridos nos acidentes de transporte, contendo dados e informações sobre o paciente, o tratamento e a evolução clínica. A partir de 2004, essa ficha foi inovada e sistematizada com mais informações de todas as CE (lesões e índices de gravidade dos traumas). Através de um *software* é realizada a coleta

dos dados e, com base nessas informações, são calculados, automaticamente, os índices de trauma.

A UE é responsável pelo atendimento de urgência e emergência de pacientes que sofrem lesões traumáticas e não traumáticas em nível terciário (alta complexidade). Eles são encaminhados pela Central de Regulamentação Médica do Serviço de Atendimento Móvel de Urgência (SAMU) do município e pela Central de Regulação e Oferta de Serviços de Saúde (CROSS) para os demais municípios da sua região e do estado de São Paulo. Os centros de trauma são classificados em quatro níveis, considerando a gravidade do trauma. A UE está no Nível I, na qual são atendidos um grande volume de pacientes com traumas graves.

3.2 Banco de Dados

Os dados provêm de um hospital localizado no interior do estado de São Paulo, relacionado ao TCE que, por sua vez, é o principal responsável pelo alto índice de mortalidade e incapacidade temporária ou permanente na população adulta jovem. Os participantes do estudo são pacientes com idade superior a 14 anos, que obtiveram alta hospitalar da enfermaria de neurologia da UE no período de maio de 2004 a julho de 2005. As informações dos pacientes hospitalizados por TCE foram extraídas dos prontuários médicos. Os dados trabalhados são secundários, no qual apresentam 50 registros de pacientes, contendo 50 variáveis relacionadas às condições sociodemográficas dos pacientes, bem como o *status* de saúde dos mesmos.

3.3 Métodos

Conforme citado anteriormente, participaram do presente estudo 50 pacientes. Os modelos consideram 14 covariáveis, estando 7 delas ligadas à qualidade de vida avaliada pelo instrumento de medição *WHOQOL-BREF*: "Autoestima", "Imagem corporal e aparência", "Dependência de medicação ou de tratamentos", "Suporte (apoio) social", "Segurança física e proteção", "Ambiente no lar" e "Ambiente físico"; e 7 relacionadas à: "Idade", "GCS Inicial", "Tempo de internação hospitalar", "Tempo de Intubação Orotraqueal (IOT)", "Sexo", "GCS" e "Tempo de internação na enfermaria neurológica", que auxiliaram na classificação da presença ou não de risco ao paciente. Durante a realização da modelagem estatística, transformou-se a variável resposta "Gravidade AIS" em dicotômica, considerando 0 (zero) para os pacientes fora de risco e 1 (um) para os pacientes que apresentaram algum tipo de risco. Com o objetivo de testar os modelos, foram separados, aleatoriamente, os dados contendo 80% (train) e 20% (test) dos pacientes. Assim, as categorias "Moderado" e "Grave" (alto risco de vida) descrevem os pacientes que não apresentam características de alto risco. Por outro lado, as categorias "Grave" (com risco de vida), "Crítico" (sobrevida incerta) e "Não sobrevive" discriminam pacientes que apresentam risco.

Assim, os modelos apresentados na seção 2.4 foram ajustados, testados e, por meio de suas estatísticas de desempenho, selecionados, chegando ao melhor modelo e construindo um score capaz de classificar os pacientes com risco de vida e maiores necessidades de atendimento, por meio de probabilidades. Mais especificamente falando, foram utilizadas técnicas de Aprendizado Estatístico, de modo a comparar o desempenho dos classificadores GLM, RF, SVM e NB e, posteriormente, desenvolver um modelo de *score* associado ao risco de vida do paciente. A Figura 3.9 representa a esquematização deste estudo.

Figura 3.9 – Processo de descoberta do *Insight*

Fonte: autor (2018)

No próximo capítulo serão descritos mais detalhadamente os resultados obtidos por meio da técnica supracitada, assim como os diferentes tipos de abordagens utilizadas para a descoberta de *insight*.

RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados os resultados, bem como uma breve discussão sobre a utilização de modelos estatísticos à luz da problemática de trauma, vinculada à sobrevivência do paciente, a fim de auxiliar os especialistas na tomada de decisão. Ademais, os resultados apresentados serão relacionados com estudos anteriores, conectando o referencial teórico aos achados obtidos sobre pacientes hospitalizados por trauma.

Este trabalho irá tratar de observações relacionadas ao traumatismo craniano. Esse tipo de trauma (TCE) tem provocado um grande número de vítimas por todo mundo, elevando as taxas de morbidade e mortalidade e atingindo principalmente os mais jovens, sendo ainda considerado o trauma que mais quantifica vítimas. Nos EUA ocorrem mais de 250 mil casos de vítimas de TCE por ano, cerca de 60.000 mortes por esse tipo de trauma. No Brasil há uma estimativa de que mais de um milhão da população possua algum tipo de sequela neurológica devido o TCE. A taxa de mortalidade fica entre 30% a 70% nas situações das vítimas com gravidade alta, estando associada à queda e acidentes de trânsito. A recuperação dos pacientes é marcada por inúmeros desafios físicos, cognitivos e emocionais (MARIK; VARON; TRASK, 2002; OLIVEIRA; IKUTA; REGNER, 2010; GENTILE *et al.*, 2011; GAUDÊNCIO; LEÃO, 2013; ALVAREZ *et al.*, 2016). Outra estatística sobre o Brasil, baseada em registros do DATASUS no período de 2008 a 2012, é o número de hospitalizações por ano, cerca de 125.500 causadas pelo TCE. A estimativa é de 65,7 internações por 100 mil habitantes por ano, com 9.715 mortes e com um tempo médio de internação de 5,5 dias. Os gastos anuais com internações chegam a R\$ 156.300.000,00, não incluindo os custos indiretos (GENTILE *et al.*, 2011; ALMEIDA *et al.*, 2016; MAGALHÃES *et al.*, 2017).

As observações foram extraídas dos prontuários médicos de $n = 50$ pacientes, com diagnóstico de TCE, que foram hospitalizados na enfermaria clínica de um hospital do interior do estado de São Paulo. As observações são do período de maio de 2004 a julho de 2005. Foram 44 casos (88%) do sexo masculino e 6 (22,9%) do sexo feminino. As informações sócio econômicas

dos pacientes foram consideradas no estudo através dos parâmetros de avaliação de classificação econômica da Associação Nacional de Empresas de Pesquisa (ANEP) (BRASIL, 2008). Em relação à classe social foram considerados n=40 pacientes após alta hospitalar, sendo que 80% pertencem às classes C e D. As frequências dos dados sócio econômicos dos 40 pacientes com TCE conforme a classificação da ANEP de 2000 são às classes A2 (1), B1 (2), B2 (3), C (18), D (14) e E (2), com relação à escolaridade foram divididas por categorias, analfabetos (03) Fundamental I (16), Fundamental II (13), Ensino Médio (17) e Ensino superior (1). A maioria das vítimas (70% - 35) encontrava-se no intervalo de idades mais jovens, sendo 25 com idade entre 15 e 35 anos (50%) e 10 (20%) entre 36 e 45 anos, acima de 45 anos representa 30% das vítimas. Dos pacientes, 88% são da raça branca e 64% possuem escolaridade baixa, (Ensino Fundamental) (TAVARES, 2006).

Sobre a causa do TCE, predominam-se os acidentes de trânsito (62% dos casos) e as quedas (24%). Acerca dos acidentes de trânsito, os acidentes automobilísticos provocaram maior número de vítimas (32%), na sequência os acidentes de bicicletas (12%) e motocicletas (6%). As vítimas de agressões físicas e ferimentos por arma de fogo desse estudo eram mais jovens, enquanto que as vítimas de quedas foram pessoas mais idosas. Os mais jovens apresentaram menor proporção nos acidentes por queda e os que ocorriam estavam relacionados ao uso de bebidas alcoólicas (6%), com doenças neurológicas convulsivas (2%), a acidentes de trabalho (4%) e com quedas casuais (4%). O TCE, entre todos os tipos de traumas, é o que mais impacta nas taxas de mortalidade e morbidade, sendo o principal trauma que atinge a faixa etária menor de 5 anos, jovens adultos entre 15 e 24 anos, economicamente ativos e homens e idosos acima dos 65 anos. (JENNETT, 1996; MOORE; MATTOX; FELICIANO, 2006). Acidentes automobilísticos são os que mais provocam vítimas de TCE, sendo a maioria delas adolescentes e adultos. Por outro lado, quedas estão ligadas em maior proporção a indivíduos com maior idade (idosos) ou crianças (INEM, 2012; GAUDÊNCIO; LEÃO, 2013).

Os pacientes que tiveram apenas lesão frontal e temporal representam, respectivamente, 34% e 22%. No entanto, em relação aos pacientes que apresentaram mais de uma área afetada, a região frontal teve maior percentual de ocorrência (72% dos casos), enquanto a região temporal foi de 34%. Acidentes automobilísticos (colisão) provocaram 26% das lesões frontais, por quedas 10%; nos casos de lesões temporais, 16% ocorreram por quedas, 8% por acidentes de bicicleta, 10% por atropelamentos e 8% por acidentes automobilísticos ligados à colisão. Nos casos associados às lesões primárias naturais do TCE foram observadas: fraturas cranianas (22%), contusões (48%), lesão axonal difusa (26%), hematomas (62%) intraparenquimatoso (4%), subdural (30%), extra-dural (16%) e outros (12%), com relação a lesões secundárias foi observado 38%. Foi verificada a frequência de hemorragia em 24% dos pacientes, sendo que a mais constante foi a intraparenquimatosa seguida da aracnoídea. Estima-se que cerca de 50% dos óbitos por TCE ocorrem nas primeiras duas horas, logo depois do evento do trauma, devido a lesões primárias do traumatismo. As lesões secundárias são responsáveis pelos outros 50%, que ocorrem após a hospitalização (INEM, 2012).

Pode-se verificar na Figura 4.10, pela função de Kaplan-Meier, uma predominância dos acidentes de trânsito (62% dos casos). Os pacientes com idade de 15 a 25 e de 26 a 35 anos representam, respectivamente, 20% e 18% dos 62% de vítimas de acidentes de transporte. Na sequência, as vítimas sofrem TCE pela agressão física e ferimento por arma de fogo. As vítimas de acidente de bicicleta e agressão física tendem a ficar mais tempo hospitalizadas, diferente das vítimas de ferimento por arma de fogo, que são as que ficam menos tempo hospitalizadas. Um estudo realizado para descrever o perfil das vítimas que foram hospitalizadas em hospitais do SUS por causa de acidentes de transporte terrestre no período de 2000 a 2013, estimou que 1.747.191 pacientes foram internados e que 410.448 casos (23,5%) tinham chances de diagnósticos com sequelas físicas, sendo a sua maior parte composta por pessoas do sexo masculino (77%), com idade de 20 a 29 anos (26,5%). A região Sudeste obteve maior percentual de vítimas (46,5%) (ANDRADE; JORGE, 2016). Outro estudo relacionado ao TCE, com o objetivo de conhecer as causas e o perfil das vítimas com TCE atendidas em um Pronto-Socorro de uma cidade no Rio Grande do Sul, analisou 496 vítimas de 0 (zero) a 15 anos de idade. Constatou-se que a gravidade leve foi a mais observada (56%), que a idade que mais sofreu lesões foram crianças com um ano, que as lesões por quedas foram predominantes no estudo (47%), seguidas pelas agressões (SANTOS *et al.*, 2013).

Figura 4.10 – Função de sobrevivência empírica para admissão dos pacientes considerando diferentes tipos de ocorrência

Fonte: autor (2018)

Segundo WHO (2009), uma pesquisa realizada em 178 países revelou que ocorreram mais de 1,2 milhão de mortes em todo mundo por acidentes de trânsito e que cerca de 50 milhões de pessoas ficaram com algum tipo de lesão. Ainda, os dados mostram que mais de 90% dos falecimentos ocorreram em estradas de países de baixa e média renda. De acordo com a OMS

(2015), em um estudo mais recente, concluiu-se que, em 2013, o número de mortes por lesões no trânsito foi de 1,25 milhão em todo o mundo, valor este estabilizado desde 2007. O estudo também mostrou que em 68 países de baixa e média renda houve um aumento do número de mortes, revelando que nesses países as taxas de vítimas fatais é duas vezes maior que a dos países de alta renda. Dentre os objetivos do desenvolvimento sustentável, discutidos pelos chefes de estado presentes na Assembleia Geral das Nações Unidas em setembro de 2015, está inclusa a meta de diminuir pela metade as mortes e vítimas de trauma causadas e afetadas pelo trânsito até 2020 (WHO, 2009; OMS, 2015). No Brasil, acidentes automobilísticos configuram-se como causa direta nos elevados custos solicitados pelo SUS, elevando o número de atendimentos e atrasando tratamentos. Ainda, há vários outros custos relacionados às emoções e vidas sociais das vítimas e das famílias, além dos impactos na economia (MASSAÚ; ROSA, 2016). Os primeiros atendimentos pós acontecimento do trauma podem determinar as chances de sobrevivência do paciente, ou seja, quanto mais rápido for definido o prognóstico da vítima de trauma, menor a possibilidade de morte, pois o período com maior taxa de mortalidade são as primeiras horas do evento ocorrido (WHITAKER; GUTIÉRREZ; KOIZUMI, 1998; CARVALHO; JÚNIOR, 2004; MALVESTIO; SOUSA, 2008).

Na Tabela 4.1 apresentamos os intervalos das idades dos pacientes, conforme seu percentual de ocorrência. Verifica-se que o número de vítimas decresce conforme o aumento da idade, corroborando a literatura. As vítimas que mais sofrem com a mortalidade ou com a morbidade são adultos jovens com anos potenciais de vida. Os idosos apresentam maior taxa de hospitalizações no Brasil. Entre 2008 e 2010 foram registrados no SUS mais de 413 mil internações por causas externas, o maior número de ocorrências é referente às vítimas de quedas e atropelamentos (LUZ *et al.*, 2011; SANTOS; RODRIGUES; DINIZ, 2017). Para idades menores que 60 anos, predominam-se vítimas do sexo masculino. Já para idades superiores a 60 anos, predominam vítimas do sexo feminino (CAMPOS *et al.*, 2007; JÚNIOR; FOLCHINI; RUEDIGER, 2013).

Tabela 4.1 – Percentual de pacientes vítimas de trauma, conforme faixa etária.

Faixa etária (anos)	%
15 a 25	28,0
26 a 35	22,0
36 a 45	20,0
46 a 55	8,0
56 a 65	12,0
> 66	10,0
Total	100,0

Fonte: autor (2018)

A Figura 4.11 apresenta a distribuição dos pacientes por idade. Observa-se que a maioria das vítimas possui 20 a 30 anos de idade. Andrade e Mello-Jorge (2016) argumentam que em

2013 foram registradas 42.266 mortes em território brasileiro oriundas de acidentes de transporte, apresentando, assim, uma taxa de 21 mortes por 100 mil habitantes, sendo a maioria delas referente a vítimas do sexo masculino. Além disso, foi observada uma taxa elevada na faixa etária de 20 a 29 anos de idade. Em um estudo recente, a [OMS \(2015\)](#) corrobora o estudo anterior, relatando que 75% das mortes por acidentes de transportes terrestres são de jovens e de pessoas do sexo masculino. [Liang *et al.* \(2015\)](#) mostram que motociclistas adolescentes representam a maioria dos pacientes que são hospitalizados para tratamento do trauma. Esses jovens tendem a apresentar lesões mais graves comparados a um padrão de lesão corporal dos motociclistas com mais idade.

Figura 4.11 – Distribuição da idade de pacientes que sofreram trauma

Fonte: autor (2018)

Além do TCE, todas as vítimas sofreram outros tipos de lesões, como escoriações, contusões e lacerações generalizadas que são distribuídas por vários segmentos do corpo. A principal área afetada foi a região facial (30%), na sequência os membros superiores e tórax (50%). A densidade do número de áreas afetadas pelo trauma é apresentada na Tabela 4.2. A maioria dos pacientes observados apresentou de 2 a 3 áreas afetadas. O TCE é responsável pelas altas taxas de mortalidade e sequelas em pacientes com múltiplas lesões traumáticas em todo o

mundo (GENTILE *et al.*, 2011). Segundo Melo, Silva e Júnior (2004), uma pesquisa realizada em uma cidade do estado da Bahia constatou que as principais causas de vítimas do TCE são: acidentes de transporte, seguidos das agressões físicas e das quedas, tendo como maior número de vítimas adultos jovens abaixo dos 40 anos.

Tabela 4.2 – Número de áreas afetadas pelo trauma.

Número de áreas afetadas	Frequência
2	19
3	14
4	6
5	4
6	7

Fonte: autor (2018)

Foram observados 22 pacientes que sofreram trauma derivado do acidente automobilístico, 3 por motocicleta, 6 por veículo por baixa velocidade (bicicleta), 6 por agressão física, 12 por queda e 1 ferimento por arma de fogo. Dentre eles, 31 pacientes necessitaram do auxílio da ventilação manual e 19 não, sendo o tempo máximo observado de 29 dias.

O tempo médio da internação hospitalar foi de 27 dias, enquanto o tempo médio no CTI foi equivalente a 8 dias. Uma outra variável importante refere-se ao tempo médio de internação na enfermaria neurológica foi de 18 dias. Para maiores informações descritivas sobre as covariáveis adotadas consultar o Apêndice A.

Os grupos de pacientes com risco de vida ficam mais tempo hospitalizados tanto na emergência quanto na Enfermaria Neurológica. As Figuras 4.12 e 4.13 apresentam a comparação desses grupos em relação ao tempo de internação hospitalar. A variação dos grupos nas duas figuras demonstram pouca variabilidade, visto que as medianas de cada grupo estão muito próximas. Outra visualização notável é por meio do *boxplot*, onde a distribuição dos dados não parece diferente entre as categorias, demonstrando que as observações não estão bem separadas por cada grupo. Pacientes que apresentam médio e alto risco, por exemplo, pacientes com amnésia pós-traumática, distúrbios de memória, síncope após traumatismo, suspeita de lesão penetrante, fratura de crânio sem lesão intracraniana e politraumatismo devem permanecer por mais tempo em observação e receber maiores cuidados, pois correm o risco de progredir para problemas neurológicos mais graves (GENTILE *et al.*, 2011).

Figura 4.12 – Tempo de internação hospitalar

Fonte: autor (2018)

Figura 4.13 – Tempo de internação na Enfermaria Neurológica

Fonte: autor (2018)

Observa-se na Figura 4.14 que os grupos não apresentam diferenças significativas entre as respostas dos pacientes alto e baixo risco (TAVARES, 2006). A GCS tem grande importância na medição da gravidade do TCE durante a admissão do paciente. Esse índice tem mostrado alto desempenho na avaliação do nível de consciência. Pacientes com índices baixos na admissão tendem a ficar mais tempo hospitalizados (OLIVEIRA; PEREIRA; FREITAS, 2014; SILVA *et al.*, 2018).

Figura 4.14 – Distribuição da gravidade do TCE em relação ao GCS inicial

Fonte: autor (2018)

Os índices de gravidade RTS e ISS têm se mostrado de grande utilidade na determinação dos prognósticos dos pacientes, auxiliando na prescrição da sua sobrevivência. Considerado como escala fisiológica, o valor do RTS, atribuído na admissão do paciente, mostra-se um bom fator descritivo, referente à taxa de mortalidade e sobrevida (ESTUMANO *et al.*, 2015).

O valor médio do RTS foi de 6,300, com valores mínimo e máximo de 4,094 e 7,84, respectivamente. As vítimas de trauma por acidentes automobilísticos obtiveram valores do RTS entre 3 e 4, enquanto que para acidentes por quedas observou-se valores acima de 7. É importante ressaltar que pacientes com valores maiores que 7 apresentam alta probabilidade de ter uma boa recuperação do traumatismo. Estudos mostram que grupos de pacientes que obtiveram valores abaixo de 7, apresentaram um risco maior de evoluir para o óbito, enquanto que pacientes com valores maiores têm mais chances de sobrevivência (SOUZA *et al.*, 2016; ALVAREZ *et al.*, 2016). Wisner (1992) argumenta que os indicadores fisiológicos são muito utilizados na fase inicial do estudo clínico das vítimas e apresentam conexão com as taxas de mortalidade e sobrevivência das vítimas.

Observou-se que os pacientes desse estudo obtiveram valor ISS entre 5 e 35. A Tabela 4.3 apresenta a distribuição dos pacientes dividida em duas partes: pacientes com pontuação de ISS < 16 e ISS $\geq$ 16, sendo 62% dos casos com valores $\geq$ 16, indicando que possuem maior risco de vida. Estudos indicam que pacientes com valores de ISS maiores ou iguais a 16 apresentam maior risco de evoluir para óbito quando comparados a valores de ISS menores que 16 (FERREIRA *et al.*, 2009; ESTUMANO *et al.*, 2015; DUBROVINA *et al.*, 2017).

Tabela 4.3 – Número de pacientes hospitalizados conforme pontuação do ISS

ISS	Número de pacientes	%
< 16	19	38
≥ 16	31	62

Fonte: autor (2018)

Quanto à quantificação do trauma, recorrente na literatura, o centro de referência para o atendimento das vítimas do TCE utiliza o ISS, o RTS e o índice de Barthel. Observe através da Figura 4.15 que essa avaliação retornada pelos índices não apresenta robustez, sendo difícil enxergar um padrão no comportamento dos dados, por exemplo, para determinar o tempo de internação do paciente. Os índices apresentarão pouca descrição dos grupos de pacientes com alto e baixo risco, o que traz evidências de fragilidade dessas escalas numéricas para separar os pacientes e auxiliar no melhor prognóstico para o tratamento.

Figura 4.15 – Tempo de internação em relação ao ISS, RTS e índice de Barthel

Fonte: autor (2018)

Observando mais atentamente os índices ISS e RTS, realizamos um teste não-paramétrico (teste de Kruskal-Wallis) de comparação de medianas para verificar se há diferença entre os pacientes que apresentaram risco de vida e os que não apresentaram. Considerando um nível

de significância de 5%, não foram rejeitadas as hipóteses de igualdade entre as medianas dos grupos, conforme pode ser visto na Tabela 4.4.

Tabela 4.4 – Tabela referente ao teste de Kruskal-Wallis

	Estatística	Valor-p
ISS	2,54	5%
RTS	2,31	13%

Fonte: autor (2018)

Visualmente é possível observar na Figura 4.16 os achados da Tabela 4.4, que os grupos de pacientes com alto e baixo risco apresentam características iguais. Esses dois índices não descrevem e não discriminam bem os grupos com alto ou baixo risco, por isso foram testados quatro classificadores: GLM, RF, SVM e NB.

Figura 4.16 – Boxplot RTS e ISS em relação ao alto e baixo risco de vida

Fonte: autor (2018)

Assim, este trabalho foi motivado pelo desenvolvimento de novos classificadores que possibilitem associar uma probabilidade ao risco de vida dos pacientes que sofreram traumatismo craniano. Dessa forma, realizou-se a comparação de quatro classificadores bastante conhecidos na literatura: GLM, RF, SVM e NB, conforme segue o código no Apêndice B. A base de dados foi dividida aleatoriamente em 80% treino e 20% teste. Porém, antes de ajustar os modelos propostos, adotamos o método de imputação via o vizinho mais próximo (1-KNN) para aproximadamente 11% (372 de 3250) da base (a sua maioria relacionada às perguntas sobre a QUALIDADE DE VIDA - WHOQOL). Sabemos que os dados contêm 50 observações (56% em alto risco e 44% baixo risco), o qual foi dividido de forma aleatória. Os modelos foram testados e ajustados e consideraram 14 covariáveis (selecionadas pelo especialista), sendo 7 delas ligadas à qualidade de vida e avaliadas pelo instrumento de medição *WHOQOL-BREF*: "Autoestima", "Imagem corporal e aparência", "Dependência de Medicação ou de tratamentos", "Suporte (apoio) social", "Segurança física e proteção", "Ambiente no lar" e "Ambiente físico"; e 7: "Idade", "GCS Inicial",

"Tempo de internação hospitalar", "Tempo de IOT", "Sexo", "GCS" e "Tempo de internação na enfermaria neurológica". Tais covariáveis foram utilizadas objetivando-se melhorar a estimação da probabilidade de risco dos pacientes de TCE.

A Figura 4.17, conhecida como curva *Receiver Operating Characteristic* (ROC), representa o desempenho dos modelos (MARTINEZ; LOUZADA-NETO; PEREIRA, 2003). As curvas apresentadas são visualizações dos coeficientes de sensibilidade (eixo y) e especificidade (eixo x) de cada modelo. Esse método é muito utilizado para avaliar o desempenho de modelos estatísticos, auxiliando na seleção do melhor modelo que possa auxiliar na decisão de profissionais da saúde (BRADLEY, 1997; FAWCETT, 2006; RESMINI *et al.*, 2012; OLIVEIRA, 2015). É também uma ferramenta gráfica normalmente utilizada para detectar sinais, para avaliar a qualidade de transmissão de um sinal em um determinado canal de ruído (PRATI; BATISTA; MONARD, 2008). Na área da saúde utiliza-se a curva ROC para analisar a qualidade de testes de diagnósticos (SILVA; CARVALHO; GATTASS, 2004; ZHOU; MCCLISH; OBUCHOWSKI, 2009).

A curva ROC possibilita selecionar o modelo com melhor desempenho, segundo a seleção de um ponto ótimo no qual tornará o modelo mais poderoso quanto à sua preditividade, classificando assim os eventos que estão relacionados com o risco do paciente e, consequentemente, retornando o desempenho do mesmo; esse resultado é nomeado como matriz de confusão (HERRERO *et al.*, 2017). Os valores mensurados de cada modelo podem ser observados na Figura 4.17, onde estão apresentados os desempenhos alcançados por cada classificador.

Figura 4.17 – Curva ROC - Comparação de desempenho dos modelos

Fonte: autor (2018)

Para avaliar o desempenho de cada modelo, estatísticas de desempenho foram adotadas. Tais estatísticas se baseiam na matriz de confusão, utilizando AUC, que é a área sob a curva ROC (METZ; HERMAN; ROE, 1998), a ACC, que é uma descrição de erros aleatórios, uma medida da variabilidade estatística, SEN que é a proporção de verdadeiros positivos, SPE a proporção

de verdadeiros negativos e a medida de qualidade MCC. A análise da curva ROC é baseada na teoria da decisão estatística (EGAN, 1975).

A Tabela 4.5 contém os valores encontrados na base teste (20%) referentes a ACC, AUC, SEN, SPE e MCC de cada modelo, considerando seus respectivos pontos ótimo. Pode-se observar a comparação dos modelos GLM (considerando uma distribuição de probabilidade Binomial com função de ligação logit), RF (considerando 500 árvores), SVM (considerando o *Radial Basis kernel "Gaussian"*) e NB, e verificar qual apresentou maior proporção de predições.

Na Tabela 4.5 são considerados para análise da escolha do melhor modelo os índices de desempenho. Verificando as estatísticas na matriz, o modelo RF possui os melhores desempenhos ACC = 0,70 AUC = 0,60, SEN = 0,75. SPE = 0,67 e MCC = 0,41. Combinado à necessidade dos especialistas, a escolha do modelo priorizou um equilíbrio entre as estatísticas Especificidade (que aponta o paciente em alto risco) e Sensibilidade (que aponta o paciente baixo risco), associado às estatísticas de desempenho dos coeficientes ACC, AUC e MCC. Pode-se verificar na tabela abaixo os valores do MCC para o GLM (MCC = -0,33) indicando uma discordância parcial entre previsão e observação e no modelo SVM (MCC = 0) demonstrando evidências de que a previsão não é melhor do que a aleatória.

Tabela 4.5 – Estatísticas de desempenho dos modelos ajustados

	GLM	RF	NB	SVM
ACC	0,40	0,70	0,60	0,50
AUC	0,60	0,60	0,56	0,52
SEN	0,44	0,75	0,57	0,50
SPE	0,00	0,67	0,67	0,50
MCC	-0,33	0,41	0,22	0,00

Fonte: autor (2018)

A seleção do melhor modelo se deu combinando a performance das estatísticas de desempenho, considerando que o modelo RF apresenta melhor resultado em relação ao apoio na decisão médica na tomada de decisão do melhor prognóstico clínico, levando em conta o risco do paciente.

Assim, segundo o modelo que melhor se ajustou aos dados (RF), foi possível montar um *ranking* para estimar a probabilidade de risco do paciente, considerando que os recursos são escassos e necessitam ser otimizados.

Por exemplo, por meio do *ranking* descrito na Tabela 4.6, sendo este baseado no desempenho do modelo RF, ou seja, na base de teste, os pacientes que apresentarem uma probabilidade estimada igual ou maior que 65% poderão ser considerados como pacientes com risco (uma vez definido pelo especialista, por exemplo, um *threshold* de 65%). Dessa forma, com a inclusão da informação das variáveis associadas ao instrumento de medição *WHOQOL-BREF*: "Autoestima", "Imagem corporal e aparência", "Dependência de medicação ou de tratamentos", "Suporte

(apoio) social", "Segurança física e proteção", "Ambiente no lar" e "Ambiente físico"; e as outras 7 relacionadas: "Idade", "GCS Inicial", "Tempo de internação hospitalar", "Tempo de IOT", "Sexo", "GCS" e "Tempo de internação na enfermaria neurológica", foi possível classificar o paciente de acordo com o nível de tolerância estipulado pelo especialista (*threshold* aplicado).

Tabela 4.6 – Score segundo o melhor modelo

Score	Taxa de Risco	Participação % da classe
0-25	0%	0%
25-50	0%	0%
50-75	33%	60%
75-100	50%	40%

Fonte: autor (2018)

Assim, o classificador selecionado RF relacionou as covariáveis por sua importância para melhor predição da estimativa de probabilidade de risco, cujo objetivo principal visa a explicação das covariáveis mais importantes na descrição do risco de vida. O Quadro 4.7 apresenta a sequência de importância de cada variável.

Quadro 4.7 – Importância das covariáveis para o modelo

Covariáveis	Overall
Imagem corporal e aparência	100
Idade	87,159
GCS inicial	59,472
Tempo de internação hospitalar	53,774
Ambiente no lar	44,531
Suporte (apoio) social	35,22
Ambiente físico	35,216
Tempo de IOT	33,126
Segurança física e proteção	31,369
Sexo	29,603
GCS	25,936
Tempo de internação na enfermaria neurológica	25,187
Dependência de Medicação ou de tratamentos	20,748
Auto-estima	16,428

Fonte: autor (2018)

A Figura 4.18 apresenta a comparação dos desempenhos dos índices ISS, RTS, Barthel e o novo classificador (RF) referente à classificação de risco dos pacientes relacionada ao tempo de internação hospitalar. Pode-se observar no gráfico do ISS que as caixas do *boxplot* apresentam pouca variabilidade, sendo que a distância da mediana do grupo de risco é menor. Levando-se

em conta que esse índice considera valores numéricos naturais para a classificação dos pacientes o ISS demonstra não ter um bom desempenho para os pacientes desse estudo como uma métrica de descrição dos pacientes com alto ou baixo risco de vida. Os boxplots referentes aos grupo de pacientes com risco de vida associados ao índice RTS não tiveram diferença em relação de risco, demonstrando que o índice não descreveu de forma satisfatória o comportamento desses indivíduos. O índice de Barthel e a discrepância das caixas do *boxplot* não trazem evidências relevantes para a separação dos pacientes com alto ou baixo risco de vida.

O novo classificador apresentou o melhor desempenho quando comparado aos outros, demonstrando um melhor comportamento na classificação dos pacientes associados às características da base de dados e possibilitando melhorar as estimativas das probabilidades relacionadas ao risco, quanto maior a probabilidade, maior é o risco de vida do paciente.

Figura 4.18 – Comparação dos desempenhos dos índices sob a classificação de risco dos pacientes

Fonte: autor (2018)

Com base nos resultados encontrados, espera-se que o presente estudo ofereça recursos aos especialistas na tomada de decisão médica, visando a melhoria da qualidade de vida dos pacientes hospitalizados em decorrência do trauma. O novo *score* aqui apresentado tem o intuito de oferecer maiores informações aos profissionais da saúde sob uma visão estatística. Urge salientar que esse estudo não tem como objetivo principal desacreditar os outros índices já aplicados nos cuidados dos pacientes com trauma, mas propor uma alternativa para o conjunto de dados analisado.

CONSIDERAÇÕES FINAIS

Dada a dinâmica e a dimensão dos problemas no sistema público de saúde, torna-se de extrema importância assegurar instrumentos que possam gerar informações que auxiliem profissionais da saúde na escolha do melhor prognóstico para o paciente, para que a escolha do tratamento seja a menos impactante possível na vida da vítima, minimizando as chances de sequelas ou, ainda, prevenindo a mortalidade.

Neste trabalho consideramos diferentes ferramentas de classificação para analisar vítimas de TCE, internadas em um hospital no interior de São Paulo, no período de maio 2004 a julho 2005. Tais análises possibilitaram desenvolver ferramentas para elaboração de um *score*, com o objetivo de discriminar pacientes com a presença ou ausência de risco. Dessa forma, especialistas em trauma poderão utilizar tais informações na tomada de decisão médica, possibilitando selecionar o melhor tratamento clínico a ser aplicado às vítimas de trauma.

Portanto, técnicas estatísticas foram utilizadas para analisar dados médicos, particularmente dados de pacientes que sofreram TCE, relacionados às variáveis, índices de gravidade corporais, índice da capacidade funcional e qualidade de vida para elaborar um *score* que estimasse a probabilidade de risco do paciente.

Dos modelos de classificação, GLM, RF, SVM e NB, demonstramos que o método RF, que utiliza técnicas de aprendizagem de máquina para classificação e descoberta de padrões, apresentou os melhores resultados em relação à tomada de decisão do melhor prognóstico clínico, considerando o risco de vida do paciente. A seleção do melhor modelo priorizou um equilíbrio entre as estatísticas Sensibilidade e Especificidade, associados a estatísticas de desempenho de coeficientes de correlação, da área sob a curva e a acurácia, que apontam o paciente em risco.

5.1 Limitações do Trabalho

A base de dados não fornece o tempo de atendimento do paciente desde o ocorrido, mas o tempo de permanência no hospital. O atendimento móvel de urgência é de fundamental importância para diminuir o risco do paciente. Sistematizar essas informações para estudos pode gerar subsídios que permitam o planejamento logístico do serviço. Assim, poderemos criar estratégias visando reduzir a mortalidade de vítimas de trauma, já que a maior parte dos acidentes de trânsito é atendida pelos hospitais públicos.

Para este modelo foi incorporado as características locais e regionais e, portanto, é necessário ser testado em dados hospitalares de outras regiões para validação do desempenho da probabilidade de risco. Estudos espaciais realizados no estado de São Paulo envolvendo acidentes de trânsito, identificam diferentes taxas de mortalidade por local e região, apontando que existem lugares que precisam de intervenções maiores (NUNES; NASCIMENTO, 2012; PAVANITTO; MENEZES; NASCIMENTO, 2018). Assim, salienta-se que as características locais devem ser consideradas em estudos futuros.

5.2 Sugestões para Trabalhos Futuros

O trabalho ora apresentado permitiu identificar oportunidades que podem ser exploradas para o desenvolvimento de projetos futuros. Dentre eles:

1. O desenvolvimento da modelagem de sobrevivência do paciente associado ao tempo de atendimento à vítima, para verificar características temporais do atendimento móvel.
2. Estender o modelo à base de dados de outros Centros de Atendimento Hospitalar a pacientes de trauma, para validação do modelo e contribuição para a saúde pública de outras regiões.
3. Incorporar, se possível, os pontos indicados na limitação do trabalho como aprimoramento do modelo.

REFERÊNCIAS

- ALMEIDA, C. E. R. de; FILHO, J. L. de S.; DOURADO, J. C.; GONTIJO, P. A. M.; DELLARETTI, M. A.; COSTA, B. S. Traumatic brain injury epidemiology in brazil. **World neurosurgery**, Elsevier, v. 87, p. 540–547, 2016. Citado na página 45.
- ALVAREZ, B. D.; RAZENTE, D.; LACERDA, D. A.; LOTHER, N. S.; VON-BAHTEN, L. C.; STAHLSCHMIDT, C.; MENINI, M. Analysis of the revised trauma score (rts) in 200 victims of different trauma mechanisms. **Revista do Colégio Brasileiro de Cirurgiões**, SciELO Brasil, v. 43, n. 5, p. 334–340, 2016. Citado nas páginas 45 e 52.
- ANDRADE, L. N. d.; VIEIRA, T. G. C.; LACERDA, W. S.; VOLPATO, M. M. L.; JUNIOR, C. A. D. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em machado-mg. Editora UFLA, 2013. Citado na página 29.
- ANDRADE, S. S. C. d. A.; JORGE, M. H. P. d. M. Estimativa de sequelas físicas em vítimas de acidentes de transporte terrestre internadas em hospitais do sistema único de saúde. **Revista Brasileira de Epidemiologia**, SciELO Public Health, v. 19, p. 100–111, 2016. Citado na página 47.
- ANDRADE, S. S. C. d. A.; MELLO-JORGE, M. H. P. d. Mortality and potential years of life lost by road traffic injuries in brazil, 2013. **Revista de saude publica**, SciELO Public Health, v. 50, p. 59, 2016. Citado na página 48.
- ARA; LOUZADA, F.; MILAN, L. A. Classification binary models for biomedical data: Simple probabilistic networks and logistic regression. **REVISTA BRASILEIRA DE BIOMETRIA**, v. 36, n. 1, p. 48–55, 2018. Citado na página 17.
- ARAÚJO, F.; RIBEIRO, J. L. P.; OLIVEIRA, A.; PINTO, C. Validação do índice de barthel numa amostra de idosos não institucionalizados. 2007. Citado nas páginas 16 e 24.
- ARRUDA, B. P.; AKAMATSU, P. Y. F.; XAVIER, A. P.; COSTA, R. C. V.; OLIVEIRA-ALONSO, G. S. de; MADALENO, I. M. P. Traumatismo crânio encefálico e suas implicações cognitivas e na qualidade de vida. **Acta fisiátrica**, v. 22, n. 2, p. 55–59, 2016. Citado na página 16.
- AYDIN, S. A.; BULUT, M.; OZGÜÇ, H.; ERCAN, İ.; TÜRKMEN, N.; EREN, B.; ESEN, M. Should the new injury severity score replace the injury severity score in the trauma and injury severity score? **Ulusal travma ve acil cerrahi dergisi= Turkish journal of trauma & emergency surgery: TJTES**, v. 14, n. 4, p. 308–312, 2008. Citado nas páginas 22 e 23.
- BARSS, P. **Injury prevention: an international perspective epidemiology, surveillance, and policy**. [S.l.]: Oxford University Press, USA, 1998. Citado na página 18.
- BARTHEL, D. Functional evaluation: the barthel index, maryland state. **Med J**, v. 14, p. 16–65, 1965. Citado nas páginas 16 e 24.

- BELLINGER, G.; CASTRO, D.; MILLS, A. Data, information, knowledge, and wisdom. 2004. Citado na página 28.
- BOOTH, W. C.; COLOMB, G. G.; WILLIAMS, J. M. **The craft of research**. 3. ed. Chicago: University of Chicago press, 2008. Citado na página 37.
- BOYD, C. R.; TOLSON, M. A.; COPES, W. S. Evaluating trauma care: the triss method. trauma score and the injury severity score. **The Journal of trauma**, v. 27, n. 4, p. 370–378, 1987. Citado na página 24.
- BRADLEY, A. P. The use of the area under the roc curve in the evaluation of machine learning algorithms. **Pattern recognition**, Elsevier, v. 30, n. 7, p. 1145–1159, 1997. Citado nas páginas 39 e 55.
- BRAGA, A. Curvas roc: aspectos funcionais e aplicações. 2001. Citado na página 39.
- BRASIL. **Ministério da Saúde. Secretaria de Vigilância em Saúde. Departamento de Análise de Situação em Saúde. A violência no Brasil: abordando diferentes fontes**. 2007. Citado na página 15.
- _____. **Saúde Brasil 2014: uma análise da situação de saúde e das causas externas**. [S.l.]: MS Brasília, 2015. Citado na página 15.
- _____. **Ministério da Saúde**. 2018. Disponível em: <<https://news.un.org/pt/story/2015/11/1532171-acidentes-de-transito-sao-epidemia-para-o-setor-de-saude-publica>>. Acesso em: 28/02/2018. Citado na página 15.
- BRASIL, C. d. C. Critério de classificação econômica brasil. **Associação Brasileira de Empresas de Pesquisa (ABEP)**, 2008. Citado na página 46.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, n. 1, p. 5–32, 2001. Citado nas páginas 29, 31 e 32.
- BROWN, J. C.; KASTENS, J. H.; COUTINHO, A. C.; VICTORIA, D. de C.; BISHOP, C. R. Classifying multiyear agricultural land use data from mato grosso using time-series modis vegetation index data. **Remote Sensing of Environment**, Elsevier, v. 130, p. 39–50, 2013. Citado na página 29.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, Springer, v. 2, n. 2, p. 121–167, 1998. Citado na página 35.
- BUSTILLO, R. A.; COSTA, C. L.; MATÉ, M. d. C. O.; ZONFRILLO, M. R.; GOMEZ, M. S.; ROS, M. J. D. Grado de correlación entre las versiones 98 y 2005 (actualización 2008) de la abbreviated injury scale (ais) en la categorización del paciente traumatológico grave. **Emergencias: Revista de la Sociedad Española de Medicina de Urgencias y Emergencias**, Saned, v. 30, n. 1, p. 41–44, 2018. Citado na página 19.
- CAMILLONI, L.; ROSSI, P. G.; FARCHI, S.; CHINI, F.; BORGIA, P.; GUASTICCHI, G. Triage and injury severity scores as predictors of mortality and hospital admission for injuries: A validation study. **Accident Analysis & Prevention**, Elsevier, v. 42, n. 6, p. 1958–1965, 2010. Citado na página 23.
- CAMPBELL, C. Kernel methods: a survey of current techniques. **Neurocomputing**, Elsevier, v. 48, n. 1-4, p. 63–84, 2002. Citado na página 34.

CAMPOS, J. F.; POLETTI, N. A.; RODRIGUES, C. D.; GARCIA, T. P.; ANGELINI, J. F.; DOLLINGER, A. P. A. V.; RIBEIRO, R. Trauma em idosos atendidos no pronto atendimento da emergência do hospital de base. **Arq Ciênc Saúde**, v. 14, n. 4, p. 193–7, 2007. Citado na página 48.

CAMPOS, M. d. A. **O Injury Severity Score e a sua nova proposta em vítimas de trauma crânio-encefálico: diferenças em resultados e efetividade de valor preditivo**. Tese (Doutorado) — Universidade de São Paulo. Escola de Enfermagem, 2001. Citado na página 19.

CARVALHO, A.; FACELI, K.; LORENA, A.; GAMA, J. Inteligência artificial—uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**, 2011. Citado na página 37.

CARVALHO, A. d. O.; JÚNIOR, A. B. Caracterização das vítimas de trauma assistidas por um serviço de atendimento pré-hospitalar. **Hospital Israelita Albert Einstein**, v. 2, n. 3, p. 199–205, 2004. Citado na página 48.

CHAGAS, C. S.; VIEIRA, C. A.; FILHO, E. F.; JUNIOR, W. C. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 3, p. 319–327, 2009. Citado na página 37.

CHAMPION, H. Trauma scoring. **Scandinavian Journal of Surgery**, SAGE Publications Sage UK: London, England, v. 91, n. 1, p. 12–22, 2002. Citado nas páginas 19 e 23.

CHAMPION, H.; SACCO, W.; COPEL, W. Injury severity scoring again. **Journal of Trauma and Acute Care Surgery**, LWW, v. 38, n. 1, p. 94–95, 1995. Citado na página 22.

CHAMPION, H. R.; COPEL, W. S.; SACCO, W. J.; LAWNICK, M. M.; KEAST, S. L.; BAIN, J. L.; FLANAGAN, M. E.; FREY, C. F. The major trauma outcome study: establishing national norms for trauma care. **The Journal of trauma**, v. 30, n. 11, p. 1356–1365, 1990. Citado nas páginas 16, 18, 19, 20 e 21.

CHAMPION, H. R.; SACCO, W. J.; CARNAZZO, A. J.; COPEL, W.; FOUTY, W. J. Trauma score. **Critical care medicine**, v. 9, n. 9, p. 672–676, 1981. Citado na página 24.

CHAMPION, H. R.; SACCO, W. J.; COPEL, W. S.; GANN, D. S.; GENNARELLI, T. A.; FLANAGAN, M. E. A revision of the trauma score. **The Journal of trauma**, v. 29, n. 5, p. 623–629, 1989. Citado nas páginas 16 e 21.

CHAMPION, H. R.; SACCO, W. J.; HANNAN, D. S.; LEPPER, R. L.; ATZINGER, E. S.; COPEL, W. S.; PRALL, R. H. Assessment of injury severity: the triage index. **Critical care medicine**, v. 8, n. 4, p. 201–208, 1980. Citado na página 20.

CHAMPION, H. R.; SACCO, W. J.; HUNT, T. K. Trauma severity scoring to predict mortality. **World journal of surgery**, Springer, v. 7, n. 1, p. 4–11, 1983. Citado na página 20.

COPEL, W. S.; CHAMPION, H. R.; SACCO, W. J.; LAWNICK, M. M.; KEAST, S. L.; BAIN, L. W. The injury severity score revisited. **Journal of Trauma and Acute Care Surgery**, LWW, v. 28, n. 1, p. 69–77, 1988. Citado na página 21.

CORDEIRO, G. M.; DEMÉTRIO, C. G. Modelos lineares generalizados e extensões. **Sao Paulo**, 2008. Citado na página 30.

COX, R. W. Afni: software for analysis and visualization of functional magnetic resonance neuroimages. **Computers and Biomedical research**, Elsevier, v. 29, n. 3, p. 162–173, 1996. Citado na página 30.

DAVIS, J. W.; MOORE, F. A.; JR, R. C. M.; COCANOUR, C. S.; MOORE, E. E.; WEST, M. A. Western trauma association critical decisions in trauma: management of pelvic fracture with hemodynamic instability. **Journal of Trauma and Acute Care Surgery**, LWW, v. 65, n. 5, p. 1012–1015, 2008. Citado na página 19.

DIOGO, M. J. D. Satisfação global com a vida e determinados domínios entre idosos com amputação de membros inferiores. **Revista Panamericana de Salud Pública**, SciELO Public Health, v. 13, p. 395–399, 2003. Citado na página 24.

DOMINGOS, P.; PAZZANI, M. On the optimality of the simple bayesian classifier under zero-one loss. **Machine learning**, Springer, v. 29, n. 2-3, p. 103–130, 1997. Citado na página 36.

DOMINGUES, C. d. A. **Trauma and injury severity score: análise de novos ajustes no índice**. Tese (Doutorado) — Universidade de São Paulo, 2013. Citado na página 23.

DOMINGUES, C. d. A.; SOUSA, R. M. C. d.; NOGUEIRA, L. d. S.; POGGETTI, R. S.; FONTES, B.; MUÑOZ, D. The role of the new trauma and injury severity score (ntriss) for survival prediction. **Revista da Escola de Enfermagem da USP**, SciELO Brasil, v. 45, n. 6, p. 1353–1358, 2011. Citado na página 19.

DOMINGUES, C. de A.; NOGUEIRA, L. de S.; SETTERVALL, C. H. C.; SOUSA, R. M. C. de. Desempenho dos ajustes do trauma and injury severity score (triss): revisão integrativa. **Revista da Escola de Enfermagem da USP**, v. 49, n. spe, p. 138–146, 2015. Citado na página 24.

DUBROVINA, N.; GERRARD, R.; BOYKO, V.; ZAMIATIN, P.; SINELNIKOV, A.; GUROV, O.; HLADKYKH, D.; ZAMIATIN, D.; OLEFIR, A.; CHEVERDA, V. Application of statistical methods to the survival analysis for the evaluation of the efficiency of resuscitation measures in cases of complicated multiple trauma. *Biomedical Statistics and Informatics*, 2017. Citado na página 52.

DUMAIS, S.; PLATT, J.; HECKERMAN, D.; SAHAMI, M. Inductive learning algorithms and representations for text categorization. In: ACM. **Proceedings of the seventh international conference on Information and knowledge management**. [S.l.], 1998. p. 148–155. Citado na página 36.

EGAN, J. P. Signal detection theory and {ROC} analysis. Academic Press, 1975. Citado na página 56.

ESTUMANO, G. R. W.; ALMEIDA, J. P. d. O.; NETO, P. A. F.; FONTELLES, M. J. P. Índices de trauma como método prognóstico em pacientes vítimas de trauma abdominal atendidos no hospital de referência de urgência e emergência no estado do Pará. **Rev. para. med**, v. 29, n. 3, 2015. Citado nas páginas 21, 22, 24 e 52.

FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. d. L. *et al.* Inteligência artificial: Uma abordagem de aprendizado de máquina. 2011. Citado nas páginas 37, 38, 39 e 40.

- FARRATH, S.; PARREIRA, J. G.; OLLIARI, C. B.; SILVA, M. A.; PERLINGEIRO, J. A. G.; SOLDÁ, S. C.; ASSEF, J. C. Identifying severe abdominal injuries during the initial assessment in blunt trauma patients. **Revista do Colégio Brasileiro de Cirurgias**, SciELO Brasil, v. 40, n. 4, p. 305–311, 2013. Citado na página 22.
- FAWCETT, T. An introduction to roc analysis. **Pattern recognition letters**, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado na página 55.
- FERNÁNDEZ, G. J. I. Escalas e índices de severidade em trauma. **Trauma, Cidade**, 2003. Citado na página 16.
- FERRÃO, M. F.; MELLO, C.; BORIN, A.; MARETTO, D. A.; POPPI, R. J. Lssvm: uma nova ferramenta quimiométrica para regressão multivariada. comparação de modelos de regressão ls-svm e pls na quantificação de adulterantes em leite em pó empregando nir. **Química Nova**, SciELO Brasil, v. 30, n. 4, p. 852–859, 2007. Citado na página 34.
- FERREIRA, T. F. A.; NÁPOLIS, A. C. R. de; LIMA, C. S.; ARAÚJO, L. C.; GARCIA, C. B.; LIMA, P. S.; SÁ, D. M. de; SILVEIRA, J. Estudo da gravidade dos pacientes vítimas de acidentes de trânsito atendidos pelo hospital de clínicas de uberlândia de dezembro de 2005 a março de 2006 segundo índices de trauma. **Bioscience Journal**, v. 25, n. 2, 2009. Citado na página 52.
- FLECK, M.; LOUZADA, S.; XAVIER, M.; CHACHAMOVICH, E.; VIEIRA, G.; SANTOS, L.; PINZON, V. Aplicação da versão em português do instrumento abreviado de avaliação da qualidade de vida "whoqol-bref". **Revista de saúde pública**, SciELO Public Health, v. 34, p. 178–183, 2000. Citado nas páginas 16, 24, 25 e 26.
- FLECK, M. P. d. A.; LEAL, O. M. F.; LOUZADA, S. N.; XAVIER, M. K.; CHACHAMOVICH, E.; VIEIRA, G. M.; SANTOS, L. d.; PINZON, V. Desenvolvimento da versão em português do instrumento de avaliação de qualidade de vida da oms (whoqol-100). **Revista brasileira de psiquiatria= Brazilian journal of psychiatry**. São Paulo, SP. Vol. 21, n. 1 (jan./mar. 1999), p. 19-28, 1999. Citado na página 25.
- FONSECA, N. d. R.; PENNA, A. F. G. Perfil do cuidador familiar do paciente com seqüela de acidente vascular encefálico. **Ciência & Saúde Coletiva**, SciELO Public Health, v. 13, p. 1175–1180, 2008. Citado nas páginas 16 e 24.
- FRAGA, G. P. Programas de qualidade no atendimento ao trauma. **Medicina (Ribeirao Preto. Online)**, v. 40, n. 3, p. 321–328, 2007. Citado nas páginas 16 e 22.
- FRAGA, G. P.; MANSO, J. E. F.; STARLING, S. V. Cbc and sbait: adding to multiply. **Revista do Colégio Brasileiro de Cirurgias**, SciELO Brasil, v. 39, n. 4, p. 247–248, 2012. Citado na página 16.
- FRAGA, G. P. *et al.* Índices de trauma em pacientes submetidos à laparotomia. [sn], 2004. Citado na página 22.
- FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. **The elements of statistical learning**. [S.l.]: Springer series in statistics New York, 2001. v. 1. Citado na página 29.
- GABBE, B. J.; CAMERON, P. A.; FINCH, C. F. Is the revised trauma score still useful? **ANZ journal of surgery**, Wiley Online Library, v. 73, n. 11, p. 944–948, 2003. Citado na página 16.

- GAUDÊNCIO, T. G.; LEÃO, G. d. M. A epidemiologia do traumatismo crânio-encefálico: um levantamento bibliográfico no brasil. **Rev Neurocienc**, v. 21, n. 3, p. 427–34, 2013. Citado nas páginas 45 e 46.
- GENNARELLI, T.; WODZIN, E.; BARRINGTON, I. Association for the advancement of automotive medicine: The abbreviated injury scale 2005. **Update**, 2008. Citado na página 21.
- GENNARI, T. D. **Gravidade do trauma analisada por meio de diagnósticos clínicos e de necropsia**. Tese (Doutorado), 2000. Citado na página 21.
- GENTILE, J. K. de A.; HIMURO, H. S.; ROJAS, S. S. O.; CORDEIRO, V.; VEIGA, L. E. C. A.; CARVALHO, J. C. de. Condutas no paciente com trauma crânioencefálico. **Rev Bras Clin Med. São Paulo**, v. 9, n. 1, p. 74–82, 2011. Citado nas páginas 45 e 50.
- GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. **Pattern Recognition Letters**, Elsevier, v. 27, n. 4, p. 294–300, 2006. Citado na página 32.
- GÓMEZ, S. N. **Random forests estocástico**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul, 2012. Citado nas páginas 32 e 33.
- GONSAGA, R. A. T.; RIMOLI, C. F.; PIRES, E. A.; ZOGHEIB, F. S.; FUJINO, M. V. T.; CUNHA, M. B. Avaliação da mortalidade por causas externas. **Rev. Col. Bras. Cir**, v. 39, n. 4, p. 263–267, 2012. Citado na página 15.
- GROUP, W. *et al.* Development of the world health organization whoqol-bref quality of life assessment. **Psychological medicine**, Cambridge University Press, v. 28, n. 3, p. 551–558, 1998. Citado na página 25.
- GUO, L.; CHEHATA, N.; MALLET, C.; BOUKIR, S. Relevance of airborne lidar and multispectral image data for urban scene classification using random forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 66, n. 1, p. 56–66, 2011. Citado na página 32.
- HABIBZADEH, F.; HABIBZADEH, P.; YADOLLAHIE, M. On determining the most appropriate test cut-off value: the case of tests with continuous results. **Biochemia medica: Biochemia medica**, Medicinska naklada, v. 26, n. 3, p. 297–307, 2016. Citado na página 40.
- HAN, J.; PEI, J.; KAMBER, M. **Data mining: concepts and techniques**. [S.l.]: Elsevier, 2011. Citado nas páginas 17 e 36.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The elements of statistical learning: Data mining, inference, and prediction., 2nd edn.(springer-verlag: New york.). **NY, USA**, 2009. Citado na página 33.
- _____. Unsupervised learning. In: **The elements of statistical learning**. [S.l.]: Springer, 2009. p. 485–585. Citado na página 29.
- HAYKIN, S. Neural networks: A comprehensive foundation, vol. 2. **Segundo, Pentrice Hall. España**, 1999. Citado na página 28.
- HERRERO, S.; CARRERO, E.; VALERO, R.; RIOS, J.; FÁBREGAS, N. Monitoramento de pacientes neurocirúrgicos no pós-operatório—utilidade dos escores de avaliação neurológica e do índice bispectral. **Brazilian Journal of Anesthesiology**, Elsevier, v. 67, n. 2, p. 153–165, 2017. Citado na página 55.

HONG, S.; YOU, T.; KWAK, S.; HAN, B. Online tracking by learning discriminative saliency map with convolutional neural network. In: **International Conference on Machine Learning**. [S.l.: s.n.], 2015. p. 597–606. Citado na página 34.

HUSUM, H.; STRADA, G. Injury severity score versus new injury severity score for penetrating injuries. **Prehospital and disaster medicine**, Cambridge University Press, v. 17, n. 1, p. 27–32, 2002. Citado na página 23.

IBGE, I. B. de Geografia e E. **Tábua completa de mortalidade para o Brasil–2014. Breve análise da evolução da mortalidade no Brasil**. [S.l.]: IBGE Brasília, 2015. Citado na página 15.

IGNÁCIO, S. A. Importância da estatística para o processo de conhecimento e tomada de decisão. **Revista Paranaense de Desenvolvimento-RPD**, n. 118, p. 175–192, 2012. Citado na página 29.

IMHOFF, B. F.; THOMPSON, N. J.; HASTINGS, M. A.; NAZIR, N.; MONCURE, M.; CANNON, C. M. Rapid emergency medicine score (rems) in the trauma population: a retrospective study. **BMJ open**, British Medical Journal Publishing Group, v. 4, n. 5, p. e004738, 2014. Citado na página 23.

INEM. **MANUAL TAS EMERGÊNCIAS DE TRAUMA**. 2012. Disponível em: <www.inem.pt/wp-content/uploads/2017/06/Emerg%C3%Aancias-Trauma.pdf>. Citado na página 46.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning**. [S.l.]: Springer, 2013. v. 112. Citado nas páginas 28, 29, 33, 35 e 36.

JENNETT, B. Epidemiology of head injury. **Journal of neurology, neurosurgery, and psychiatry**, BMJ Publishing Group, v. 60, n. 4, p. 362, 1996. Citado na página 46.

JORGE, M. H. P. d. M.; KOIZUMI, M. S. Gastos governamentais do sus com internações hospitalares por causas externas: análise no estado de são paulo, 2000. **Revista Brasileira de Epidemiologia**, SciELO Public Health, v. 7, p. 228–238, 2004. Citado na página 15.

JORGE, M. H. P. d. M.; KOIZUMI, M. S. *et al.* Acidentes de trânsito no brasil: um atlas de sua distribuição. **ABRAMET. Associação Brasileira de Medicina de Tráfego**, São Paulo, v. 26, n. 1, p. 52–58, 2008. Citado na página 15.

JÚNIOR, C.; FOLCHINI, A.; RUEDIGER, R. Estudo comparativo entre o trauma em idosos e não idosos atendidos em um hospital universitário de curitiba. **Rev. Col. Bras. Cir.**, v. 40, n. 4, p. 281–286, 2013. Citado na página 48.

JÚNIOR, G. A. P.; LOVATO, W. J.; CARVALHO, J. B.; HORTA, M. F. V. Abordagem geral trauma abdominal. **Medicina (Ribeirao Preto. Online)**, v. 40, n. 4, p. 518–530, 2007. Citado na página 24.

KLUTHCOVSKY, A. C. G.; KLUTHCOVSKY, F. A. O whoqol-bref, um instrumento para avaliar qualidade de vida: uma revisão sistemática. **Rev. psiquiatr. Rio Gd. Sul**, v. 31, n. 3, supl. 0, p. 0–0, 2009. Citado na página 25.

KRUPPA, J.; SCHWARZ, A.; ARMINGER, G.; ZIEGLER, A. Consumer credit risk: Individual probability estimates using machine learning. **Expert Systems with Applications**, Elsevier, v. 40, n. 13, p. 5125–5131, 2013. Citado nas páginas 31 e 32.

- LANTZ, B. **Machine learning with R**. [S.l.]: Packt Publishing Ltd, 2013. Citado na página [32](#).
- LEE, Y.; NELDER, J. Generalized linear models for the analysis of quality-improvement experiments. **Canadian Journal of Statistics**, Wiley Online Library, v. 26, n. 1, p. 95–105, 1998. Citado nas páginas [29](#) e [30](#).
- LEFERING, R. Development and validation of the revised injury severity classification score for severely injured patients. **European Journal of Trauma and Emergency Surgery**, Springer, v. 35, n. 5, p. 437–447, 2009. Citado na página [24](#).
- _____. Trauma scoring systems. **Current opinion in critical care**, LWW, v. 18, n. 6, p. 637–640, 2012. Citado na página [21](#).
- LIANG, C.-C.; LIU, H.-T.; RAU, C.-S.; HSU, S.-Y.; HSIEH, H.-Y.; HSIEH, C.-H. Motorcycle-related hospitalization of adolescents in a level i trauma center in southern taiwan: a cross-sectional study. **BMC pediatrics**, BioMed Central, v. 15, n. 1, p. 105, 2015. Citado na página [49](#).
- LINDSEY, J. K. **Applying generalized linear models**. [S.l.]: Springer Science & Business Media, 2000. Citado na página [30](#).
- LOPES, M. C. B. T.; WHITAKER, I. Y. Mensuração da gravidade do trauma com as versões 1998 e 2005 da abbreviated injury scale. **Revista da Escola de Enfermagem da USP**, Universidade de São Paulo, v. 48, n. 4, 2014. Citado na página [16](#).
- LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007. Citado nas páginas [28](#), [34](#) e [35](#).
- LUZ, T. C. B.; MALTA, D. C.; SÁ, N. N. B. d.; SILVA, M. M. A. d.; LIMA-COSTA, M. F. Violências e acidentes entre adultos mais velhos em comparação aos mais jovens: evidências do sistema de vigilância de violências e acidentes (viva), brasil. **Cadernos de Saúde Pública**, SciELO Public Health, v. 27, p. 2135–2142, 2011. Citado na página [48](#).
- MACIEL, W. V.; MACIEL, S. S. S. V.; FARIAS, A. H. C.; SILVA, E. T. C. d.; GONDIM, L. A. M.; OLIVEIRA, T. d. F. Internações hospitalares por fraturas do crânio e dos ossos da face no nordeste brasileiro. **Rev. AMRIGS**, v. 53, n. 1, p. 28–33, 2009. Citado na página [15](#).
- MAGALHÃES, A. L. G.; SOUZA, L. C. de; FALEIRO, R. M.; TEIXEIRA, A. L.; MIRANDA, A. S. de. Epidemiologia do traumatismo cranioencefálico no brasil. **Revista Brasileira de Neurologia**, v. 53, n. 2, 2017. Citado na página [45](#).
- MALVESTIO, M. A. A.; SOUSA, R. M. Cardoso de. Análise do valor predeterminante dos procedimentos da fase pré-hospitalar na sobrevivência das vítimas de trauma. **Revista Latino-Americana de Enfermagem**, Universidade de São Paulo, v. 16, n. 3, 2008. Citado na página [48](#).
- MANTOVANI, M.; FONTELLES, M. J.; FRAGA, G. P. Trauma abdominal fechado: tratamento não-operatório das lesões esplênicas. **Rev. para. med**, v. 16, n. 2, p. 46–51, 2002. Citado na página [22](#).
- MANYIKA, J.; CHUI, M.; BROWN, B.; BUGHIN, J.; DOBBS, R.; ROXBURGH, C.; BYERS, A. H. Big data: The next frontier for innovation, competition, and productivity. 2011. Citado na página [29](#).

MARIK, P. E.; VARON, J.; TRASK, T. Management of head trauma. **Chest**, Elsevier, v. 122, n. 2, p. 699–711, 2002. Citado na página 45.

MARSLAND, S. **Machine learning: an algorithmic perspective**. [S.l.]: Chapman and Hall/CRC, 2011. Citado na página 28.

MARTINEZ, E. Z.; LOUZADA-NETO, F.; PEREIRA, B. d. B. A curva roc para testes diagnósticos. **Cad. saúde colet.,(Rio J.)**, v. 11, n. 1, p. 7–31, 2003. Citado na página 55.

MASCARENHAS, M. D. M.; BARROS, M. B. d. A. Evolução das internações hospitalares por causas externas no sistema público de saúde-brasil, 2002 a 2011. **Epidemiologia e Serviços de Saúde**, SciELO Public Health, v. 24, p. 19–29, 2015. Citado na página 15.

MASSAÚ, G. C.; ROSA, R. G. da. Acidentes de trânsito e direito à saúde: prevenção de vidas e economia pública. **Revista de Direito Sanitário**, v. 17, n. 2, p. 30–47, 2016. Citado na página 48.

MATOS, K.; MARTINS, C. B. de G. Mortalidade por causas externas em crianças, adolescentes e jovens: uma revisão bibliográfica. **Espaço para a Saúde-Revista de Saúde Pública do Paraná**, v. 14, n. 1/2, p. 82–93, 2013. Citado na página 16.

MATTHEWS, B. W. Comparison of the predicted and observed secondary structure of t4 phage lysozyme. **Biochimica et Biophysica Acta (BBA)-Protein Structure**, Elsevier, v. 405, n. 2, p. 442–451, 1975. Citado na página 38.

MELO, J. R. T.; SILVA, R. A. d.; JÚNIOR, E. D. M. Características dos pacientes com trauma cranioencefálico na cidade do salvador, bahia, brasil. 2004. Citado na página 50.

MENDONÇA, M. F. S. d.; SILVA, A. P. d. S. C.; CASTRO, C. C. L. d. Análise espacial dos acidentes de trânsito urbano atendidos pelo serviço de atendimento móvel de urgência: um recorte no espaço e no tempo. **Revista Brasileira de Epidemiologia**, SciELO Public Health, v. 20, p. 727–741, 2017. Citado na página 15.

METZ, C. E.; HERMAN, B. A.; ROE, C. A. Statistical comparison of two roc-curve estimates obtained from partially-paired datasets. **Medical Decision Making**, Sage Publications Sage CA: Thousand Oaks, CA, v. 18, n. 1, p. 110–121, 1998. Citado na página 55.

MIKHAIL, J. N.; RHIT, Y. D. H.; SORENSEN, V. J. Injury severity scoring: influence of trauma surgeon involvement on accuracy. **Journal of Trauma Nursing**, Society of Trauma Nurses, v. 10, n. 2, p. 43, 2003. Citado na página 21.

MITCHELL, T. M. *et al.* Machine learning. 1997. **Burr Ridge, IL: McGraw Hill**, v. 45, n. 37, p. 870–877, 1997. Citado na página 34.

MOORE, E. E.; MATTOX, K. L.; FELICIANO, D. V. **Manual del trauma**. [S.l.]: McGraw-Hill,, 2006. Citado na página 46.

MOORE, L.; LAVOIE, A.; LESAGE, N.; ABDOUS, B.; BERGERON, E.; LIBERMAN, M.; EMOND, M. Statistical validation of the revised trauma score. **Journal of Trauma and Acute Care Surgery**, LWW, v. 60, n. 2, p. 305–311, 2006. Citado na página 20.

MOORE, L.; LAVOIE, A.; SAGE, N. L.; BERGERON, E.; EMOND, M.; ABDOUS, B. Consensus or data-derived anatomic injury severity scoring? **Journal of Trauma and Acute Care Surgery**, LWW, v. 64, n. 2, p. 420–426, 2008. Citado na página 23.

- NASCIMENTO, C. D. L.; SILVA, S. D. d. S.; SILVA, T. A. d.; PEREIRA, W. C. d. A.; COSTA, M. G. F.; FILHO, C. F. F. C. Breast tumor classification in ultrasound images using support vector machines and neural networks. **Research on Biomedical Engineering**, SciELO Brasil, v. 32, n. 3, p. 283–292, 2016. Citado na página 34.
- NELDER, J. A.; BAKER, R. J. **Generalized linear models**. [S.l.]: Wiley Online Library, 1972. Citado na página 30.
- NOGUEIRA, L. d. S.; SOUSA, R. M. Cardoso de; DOMINGUES, C. de A. Gravidade das vítimas de trauma, admitidas em unidades de terapia intensiva: estudo comparativo entre diferentes índices. **Revista Latino-Americana de Enfermagem**, Universidade de São Paulo, v. 17, n. 6, 2009. Citado nas páginas 19 e 22.
- NUNES, M. N.; NASCIMENTO, L. F. C. Análise espacial de óbitos por acidentes de trânsito, antes e após a lei seca, nas microrregiões do estado de são paulo. **Revista da Associação Médica Brasileira**, Elsevier, v. 58, n. 6, p. 685–690, 2012. Citado na página 60.
- OLIVEIRA, C. d.; IKUTA, N.; REGNER, A. Biomarcadores prognósticos no traumatismo crânio-encefálico grave. **Revista Brasileira de Terapia Intensiva**, SciELO Brasil, v. 20, n. 4, p. 411–421, 2010. Citado na página 45.
- OLIVEIRA, D. M. d. P.; PEREIRA, C. U.; FREITAS, Z. M. d. P. Escalas para avaliação do nível de consciência em trauma cranioencefálico e sua relevância para a prática de enfermagem em neurocirurgia. Sociedade Brasileira de Neurocirurgia/Sociedades de Neurocirurgia de Língua Portuguesa, 2014. Citado nas páginas 19, 20 e 51.
- OLIVEIRA, P. C. d. Abordagem semi-supervisionada para detecção de módulos de software defeituosos. Universidade Federal de Pernambuco, 2015. Citado na página 55.
- OLSHANNIKOVA, E.; OMETOV, A.; KOUCHERYAVY, Y.; OLSSON, T. Visualizing big data with augmented and virtual reality: challenges and research agenda. **Journal of Big Data**, Springer, v. 2, n. 1, p. 22, 2015. Citado na página 29.
- OMS. **Relatório global sobre o estado da segurança viária 2015**. [S.l.]: Organização Mundial de Saúde Genebra, 2015. Citado nas páginas 15, 27, 48 e 49.
- ORGANIZATION, W. H. **World health statistics 2015**. [S.l.]: World Health Organization, 2014. Citado na página 15.
- OSLER, T.; BAKER, S. P.; LONG, W. A modification of the injury severity score that both improves accuracy and simplifies scoring. **Journal of Trauma and Acute Care Surgery**, LWW, v. 43, n. 6, p. 922–926, 1997. Citado nas páginas 18, 22 e 23.
- OSPINA, J.; GUEVARA, O.; PARRA, L.; DÍAZ, C.; CORTÉS, E.; FIGUEREDO, E.; RODRÍGUEZ, A. Uso práctico de los índices de trauma. **Rev. colomb. cir**, v. 8, n. 2, p. 86–96, 1993. Citado na página 16.
- PALMER, R.; KNIGHT, J. Assessment of altered conscious level in clinical practice. **British Journal of Nursing**, MA Healthcare London, v. 15, n. 22, p. 1255–1259, 2006. Citado na página 20.

- PARK, H. O.; KIM, J. W.; KIM, S. H.; MOON, S. H.; BYUN, J. H.; KIM, K. N.; YANG, J. H.; LEE, C. E.; JANG, I. S.; KANG, D. H. *et al.* Usability verification of the emergency trauma score (emtras) and rapid emergency medicine score (rems) in patients with trauma: A retrospective cohort study. **Medicine**, Wolters Kluwer Health, v. 96, n. 44, 2017. Citado nas páginas 21 e 22.
- PARREIRA, J. G.; KANAMORI, L. R.; VALINOTO, G. C.; PERLINGEIRO, J. A. G.; SOLDÁ, S. C.; ASSEF, J. C. Comparative analysis between identified injuries of victims of fall from height and other mechanisms of closed trauma. **Revista do Colégio Brasileiro de Cirurgiões**, SciELO Brasil, v. 41, n. 4, p. 285–291, 2014. Citado na página 19.
- PARREIRA, J. G.; RONDINI, G. Z.; BELOW, C.; TANAKA, G. O.; PELLUCHI, J. N.; ARANTES-PERLINGEIRO, J.; SOLDÁ, S. C.; ASSEF, J. C. Trauma mechanism predicts the frequency and the severity of injuries in blunt trauma patients. **Revista do Colégio Brasileiro de Cirurgiões**, SciELO Brasil, v. 44, n. 4, p. 340–347, 2017. Citado nas páginas 15, 22 e 23.
- PAULA, G. A. Modelos de regressão com apoio computacional. 2013. **Citado na pág.**, v. 1, n. 9, p. 10, 2013. Citado na página 30.
- PAVANITTO, D. R.; MENEZES, R. A. d. M.; NASCIMENTO, L. F. C. Accidents involving motorcycles and potential years of life lost. an ecological and exploratory study. **Sao Paulo Medical Journal**, SciELO Brasil, n. AHEAD, p. 0–0, 2018. Citado na página 60.
- PAYAMPS, R. A. C.; CARTAYA, J. A. E.; ACOSTA, J. R. P.; FERNÁNDEZ, Z. R. Algunas especificidades concernientes al paciente politraumatizado grave. **Revista Cubana de Cirugía**, 2002, Editorial Ciencias Médicas, v. 55, n. 3, p. 220–233, 2016. Citado na página 18.
- PEREZ, A.; LARRANAGA, P.; INZA, I. Supervised classification with conditional gaussian networks: Increasing the structure complexity from naive bayes. **International Journal of Approximate Reasoning**, Elsevier, v. 43, n. 1, p. 1–25, 2006. Citado na página 36.
- POWERS, D. M. Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. Bioinfo Publications, 2011. Citado na página 39.
- PRATI, R.; BATISTA, G.; MONARD, M. Curvas roc para avaliação de classificadores. **Revista IEEE América Latina**, v. 6, n. 2, p. 215–222, 2008. Citado nas páginas 39 e 55.
- RAMOS, P. L.; ACHCAR, J. A.; MOALA, F. A.; RAMOS, E.; LOUZADA, F. Bayesian analysis of the generalized gamma distribution using non-informative priors. **Statistics**, Taylor & Francis, v. 51, n. 4, p. 824–843, 2017. Citado na página 30.
- RASSLAN, S.; BIROLINI, D. O trauma como modelo de doença. **Revista do Colégio Brasileiro de Cirurgiões**, SciELO Brasil, v. 25, n. 5, p. III–III, 1998. Citado na página 15.
- RAUM, M. R.; NIJSTEN, M. W.; VOGELZANG, M.; SCHURING, F.; LEFERING, R.; BOUILLON, B.; RIXEN, D.; NEUGEBAUER, E. A.; HENK, J.; SOCIETY, P. S. G. of the G. T. *et al.* Emergency trauma score: an instrument for early estimation of trauma severity. **Critical care medicine**, LWW, v. 37, n. 6, p. 1972–1977, 2009. Citado na página 23.
- RESMINI, R.; BORCHARTT, T. B.; CONCI, A.; LIMA, R. C. Auxílio ao diagnóstico precoce de patologias da mama usando imagens térmicas e técnicas de mineração de dados. **Anais do Computer on the Beach**, p. 305–314, 2012. Citado na página 55.

- RESTREPO-ÁLVAREZ, C. A.; VALDERRAMA-MOLINA, C. O.; GIRALDO-RAMÍREZ, N.; CONSTAIN-FRANCO, A.; PUERTA, A.; LEÓN, A. L.; JAIMES, F. Trauma severity scores. **Revista Colombiana de Anestesiología**, SCARE-Sociedad Colombiana de Anestesiología y Reanimación, v. 44, n. 4, p. 317–323, 2016. Citado nas páginas 16, 21 e 23.
- RIECHERS, R. G.; RAMAGE, A.; BROWN, W.; KALEHUA, A.; RHEE, P.; ECKLUND, J. M.; LING, G. S. Physician knowledge of the glasgow coma scale. **Journal of neurotrauma**, Mary Ann Liebert, Inc. 2 Madison Avenue Larchmont, NY 10538 USA, v. 22, n. 11, p. 1327–1334, 2005. Citado nas páginas 19 e 20.
- RODRIGUES, F. A.; AMARAL, L. R. d. Aplicacao de metodos computacionais de mineracao de dados na classificacao e selecao de oncogenes medidos por microarray. **Rev bras cancerol**, v. 58, n. 2, p. 241–249, 2012. Citado nas páginas 31 e 32.
- RODRÍGUEZ, J. R.; VERA, R. N. El politraumatizado. aspectos generales. **Alfageme Michavilla I, Álvarez MA, Álvarez Fernández JÁ, Álvarez Márquez E, Arias Garrido JJ, Arnedillo Muñoz A, et al. Principios de urgencias, emergencias y cuidados críticos. Madrid: Editorial: Alhulia**, 2014. Citado na página 18.
- ROWELL, S. E.; BARBOSA, R. R.; DIGGS, B. S.; SCHREIBER, M. A.; GROUP, T. O. *et al.* Specific abbreviated injury scale values are responsible for the underestimation of mortality in penetrating trauma patients by the injury severity score. **Journal of Trauma and Acute Care Surgery**, LWW, v. 71, n. 2, p. S384–S388, 2011. Citado na página 23.
- RUSSOM, P. Managing big data. **TDWI Best Practices Report, TDWI Research**, p. 1–40, 2013. Citado na página 29.
- SANT’ANNA, Â. M. O. Método de orientação à modelagem de dados mensurados em proporção. 2006. Citado na página 30.
- SANTOS, A. M. Ribeiro dos; RODRIGUES, R. A. P.; DINIZ, M. A. Trauma por acidente de trânsito no idoso: Fatores de risco e consequências. **Texto & Contexto Enfermagem**, v. 26, n. 2, 2017. Citado na página 48.
- SANTOS, C. d. S. d. **Construção de atributos binários baseada em análise de interações**. Tese (Doutorado) — Universidade de São Paulo, 2010. Citado na página 37.
- SANTOS, F. d.; CASAGRANDA, L. P.; LANGE, C.; FARIAS, J. C. d.; PEREIRA, P. M.; JARDIM, V. M. d. R.; TORRES, A. A. P. Traumatismo cranioencefálico: causas e perfil das vítimas atendidas no pronto-socorro de pelotas/rio grande do sul, brasil. **Revista Mineira de Enfermagem**, Revista Mineira de Enfermagem, v. 17, n. 4, p. 882–893, 2013. Citado na página 47.
- SANTOS, J. A. D.; GOSSELIN, P.-H.; PHILIPP-FOLIGUET, S.; TORRES, R. d. S.; FALAO, A. X. Multiscale classification of remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 50, n. 10, p. 3764–3775, 2012. Citado na página 29.
- SARMIENTO, C. M.; RAMIREZ, G. M.; COLTRI, P. P.; SILVA, L. F. L.; NASSUR, O. A. C.; SOARES, J. F. Comparação de classificadores supervisionados na discriminação de áreas cafeieiras em campos gerais–minas gerais. **Coffee Science**, v. 9, n. 4, p. 546–557, 2014. Citado na página 29.

SCHNEIDER, A.; FRIEDL, M. A.; POTERE, D. A new map of global urban extent from modis satellite data. **Environmental Research Letters**, IOP Publishing, v. 4, n. 4, p. 044003, 2009. Citado na página 29.

SCLIAR, M. História do conceito de saúde. **Physis: Revista de saúde coletiva**, SciELO Public Health, v. 17, p. 29–41, 2007. Citado na página 24.

SHUTTERSTOCK. **ID do Pedido SSTK-074AB-4990**. 2018. Disponível em: <www.shutterstock.com/pt/image-illustration/3d-render-depicting-human-anatomy-muscles-125648?src=library>. Citado na página 23.

SILVA, A.; CARVALHO, P.; GATTASS, M. Diagnosis of solitary lung nodule using texture e geometry in computerized tomography images: Preliminary results. **IEEE Latin America Transactions**, IEEE, v. 2, n. 2, p. 75–80, 2004. Citado na página 55.

SILVA, T. H. d.; MASSETTI, T.; SILVA, T. D. d.; PAIVA, L. d. S.; PAPA, D. C. R.; MONTEIRO, C. B. d. M.; CAROMANO, F. A.; VOOS, M. C.; SILVA, L. D. S. Influence of severity of traumatic brain injury at hospital admission on clinical outcomes. **Fisioterapia e Pesquisa**, SciELO Brasil, v. 25, n. 1, p. 3–8, 2018. Citado na página 51.

SOLER, V. R.; BENÍTEZ, H. J.; GREGORIO, G. G. Evaluación pronóstica en el traumatizado. **Trabajo original. CUBA**, 2010. Citado na página 16.

SOUZA, E. A. d. Uma proposta para combinar classificadores e colaboração de usuários na resolução do problema de ambiguidade de nomes de autores. 2014. Citado na página 35.

SOUZA, T. R. R.; PEREIRA, E. B. F.; FREIRE, D. d. A.; MATIAS, T. M.; MOURA, R. N. d.; AMORIM, C. d. S. Probabilidade de sobrevivência dos pacientes vítima de trauma, atendidos em um hospital de emergência. **Nursing (São Paulo)**, v. 19, n. 223, p. 1515–1520, 2016. Citado na página 52.

SPACKMAN, K. A. Signal detection theory: Valuable tools for evaluating inductive learning. In: ELSEVIER. **Proceedings of the sixth international workshop on Machine learning**. [S.l.], 1989. p. 160–163. Citado na página 39.

TAKAHASHI, A. Máquina de vetores-suporte intervalar. Universidade Federal do Rio Grande do Norte, 2012. Citado na página 34.

TAVARES, K. **Avaliação da qualidade de vida em pacientes com traumatismo crânio encefálico: correlações funcionais, sociais e cognitivas na fase hospitalar e tardia**. Tese (Doutorado) — Universidade de São Paulo, 2006. Citado nas páginas 25, 46 e 51.

TEASDALE, G.; JENNETT, B. Assessment of coma and impaired consciousness: a practical scale. **The Lancet**, Elsevier, v. 304, n. 7872, p. 81–84, 1974. Citado na página 20.

TELOKEN, A. *et al.* Estudo comparativo entre os algoritmos de mineração de dados random forest e j48 na tomada de decisão. **Simpósio de Pesquisa e Desenvolvimento em Computação**, v. 2, n. 1, 2016. Citado nas páginas 31, 32 e 33.

TIBSHIRANI, R.; JAMES, G.; WITTEN, D.; HASTIE, T. **An introduction to statistical learning-with applications in R**. [S.l.]: New York, NY: Springer, 2013. Citado na página 32.

- TURKMAN, M. A. A.; SILVA, G. L. Modelos lineares generalizados-da teoria à prática. In: **VIII Congresso Anual da Sociedade Portuguesa de Estatística, Lisboa**. [S.l.: s.n.], 2000. Citado na página 30.
- TZOTSOS, A.; ARGIALAS, D. Support vector machine classification for object-based image analysis. In: **Object-Based Image Analysis**. [S.l.]: Springer, 2008. p. 663–677. Citado na página 34.
- VAPNIK, V. **The nature of statistical learning theory**. [S.l.]: Springer science & business media, 2013. Citado na página 28.
- VAPNIK, V. N. An overview of statistical learning theory. **IEEE transactions on neural networks**, IEEE, v. 10, n. 5, p. 988–999, 1999. Citado na página 28.
- VIANA, R. F. *et al.* Técnicas de classificação aplicadas a credit scoring: revisão sistemática e comparação. Universidade Federal de São Carlos, 2015. Citado nas páginas 37 e 38.
- WALKER, S. J. **Big data: A revolution that will transform how we live, work, and think**. [S.l.]: Taylor & Francis, 2014. Citado na página 29.
- WANG, G.; GUNASEKARAN, A.; NGAI, E. W.; PAPADOPOULOS, T. Big data analytics in logistics and supply chain management: Certain investigations for research and applications. **International Journal of Production Economics**, Elsevier, v. 176, p. 98–110, 2016. Citado na página 28.
- WHITAKER, I. Y. **Gravidade do trauma e probabilidade de sobrevida em pacientes internados**. Tese (Doutorado) — Universidade de São Paulo, 2000. Citado na página 24.
- WHITAKER, I. Y.; GUTIÉRREZ, M. G. R. d.; KOIZUMI, M. Gravidade do trauma avaliada na fase pré-hospitalar. **Revista da Associação Médica Brasileira**, SciELO Brasil, 1998. Citado na página 48.
- WHO. **Global status report on road safety: time for action**. [S.l.]: World Health Organization, 2009. Citado nas páginas 47 e 48.
- WISNER, D. H. History and current status of trauma scoring systems. **Archives of Surgery**, American Medical Association, v. 127, n. 1, p. 111–117, 1992. Citado nas páginas 20 e 52.
- ZAKIR, J.; SEYMOUR, T.; BERG, K. Big data analytics. **Issues in Information Systems**, v. 16, n. 2, 2015. Citado na página 28.
- ZHANG, H. The optimality of naive bayes. **AA**, v. 1, n. 2, p. 3, 2004. Citado na página 36.
- ZHAO, X.-g.; ZHANG, M.; GAN, J.-x.; XU, S.-w.; JIANG, G.-y. *et al.* Comparison of the new injury severity score and the injury severity score in multiple trauma patients. **Chinese Journal of Traumatology (English Edition)**, Elsevier, v. 11, n. 6, p. 368–371, 2008. Citado na página 23.
- ZHOU, X.-H.; MCCLISH, D. K.; OBUCHOWSKI, N. A. **Statistical methods in diagnostic medicine**. [S.l.]: John Wiley & Sons, 2009. v. 569. Citado na página 55.

SUMÁRIO DESCRITIVO DAS COVARIÁVEIS

SUMÁRIO DESCRITIVO DAS COVARIÁVEIS									
AIS	n	Sexo	n	T. IOT	n	I. CTI	n		
1	28,00	F	6,00	Não	34,00	Não	25,00		
0	22,00	M	44,00	SIM	16,00	Sim	25,00		
Etiologia	n	Idade	n	I. Hosp.	n	T. IOT	n		
Automob.	22,00	Mínimo	15,00	Mínimo	2,00	Mínimo	0,00		
Moto	3,00	Q1 - 25%	24,25	Q1 - 25%	8,25	Q1 - 25%	0,00		
Ag. física	6,00	Mediana	35,50	Mediana	18,50	Mediana	2,00		
Ag. Física	6,00	Média	39,86	Média	27,48	Média	4,62		
Ar. fogo	1,00	Q3 - 75%	51,50	Q3 - 75%	34,00	Q3 - 75%	8,00		
Queda	12,00	Máximo	85,00	Máximo	133,00	Máximo	17,00		
Inter. no CTI	n	I. enf. Neu.	n	GCS inicial	n	GCS	n		
Mínimo	0,00	Mínimo	1,00	Mínimo	3,00	Mínimo	3,00		
Q1 - 25%	0,00	Q1 - 25%	5,00	Q1 - 25%	6,00	Q1 - 25%	12,75		
Mediana	1,50	Mediana	10,00	Mediana	8,00	Mediana	14,00		
Média	7,92	Média	18,30	Média	9,00	Média	13,12		
Q3 - 75%	13,00	Q3 - 75%	19,75	Q3 - 75%	13,00	Q3 - 75%	15,00		
Máximo	43,00	Máximo	112,00	Máximo	15,00	Máximo	15,00		
Auto-estima	n	Im. corporal	n	Dep. Med.	n	Sup. social	n		
Mínimo	1,00	Mínimo	1,00	Mínimo	1,00	Mínimo	1,00		
Q1 - 25%	3,00	Q1 - 25%	3,00	Q1 - 25%	3,00	Q1 - 25%	1,00		
Mediana	4,00	Mediana	4,00	Mediana	3,68	Mediana	2,00		
Média	3,73	Média	3,46	Média	5,00	Média	2,60		
Q3 - 75%	4,00	Q3 - 75%	5,00	Q3 - 75%	5,00	Q3 - 75%	4,00		
Máximo	5,00	Máximo		Máximo		Máximo	5,00		
Áreas afet.	n	Seg. f. e p.	n	Amb. lar	n	Amb. físico	n		
Mínimo	2,00	Mínimo	1,00	Mínimo	1,00	Mínimo	2,00		
Q1 - 25%	2,00	Q1 - 25%	3,00	Q1 - 25%	3,00	Q1 - 25%	4,00		
Mediana	3,00	Mediana	4,00	Mediana	4,00	Mediana	4,00		
Média	3,32	Média	3,87	Média	3,70	Média	4,05		
Q3 - 75%	4,00	Q3 - 75%	5,00	Q3 - 75%	5,00	Q3 - 75%	4,00		
Máximo	6,00	Máximo	5,00	Máximo	5,00	Máximo	5,00		

Fonte: autor (2018)

CÓDIGO EM R SCRIPT

```

1
2 library(data.table); library(dplyr); library(corrplot)
3 library(MASS); library(plotROC); library(ggfortify)
4 library(ROCR); library(InformationValue); library(e1071)
5 library(caret); library(pROC); library(kernlab); library(DMwR)
6 library(mccr); library(survival); library(ggplot2)
7 set.seed(240487)
8
9 data=read.csv("Dados1.csv", sep=";")
10 head(data); names(data)
11
12 #####
13 ## Descritiva
14 #####
15 table(data$Sexo) #PIE GRAPH
16 sort(table(data$Escolaridade))
17
18 hist(data$Idade, prob=T, xlab="Idade", ylab="Densidade", main="
    Distribuição dos Pacientes por Idade")
19 lines(density(data$Idade, na.rm=T))
20
21 plot(density(data$Número.de.áreas.afetadas), main="Número de á
    reas afetadas", ylab="Densidade")
22
23 boxplot(data$Tempo.de.internação.hospitalar~data$Classificação.
    do.AIS, ylab="Dias", main="Tempo de internação Hospitalar")

```

```
24 boxplot(data$Tempo.de.internação.na.enf.neurológica~
          data$Classificação.do.AIS,ylab="Dias",main="Tempo de interna
          ção Enf. Neurológica")
25
26 sm.density.compare(data$ECG.inicial,data$Classificação.do.AIS,
          xlab="EEG Inicial")
27 legend(y=0.015,x=7,c("Risco","Não Risco"),col = c("red","green
          "),lwd = c(1,1),box.col = "white")
28
29 table(data$VM) #Escrever resultado
30 table(data$TQT) #Escrever resultado
31
32 par(mfrow=c(3,1))
33 plot(data$ISS~data$Tempo.de.internação.hospitalar,ylab="ISS",
          xlab="Tempo – Internação Hospitalar")
34 plot(data$RTS~data$Tempo.de.internação.hospitalar,ylab="RTS",
          xlab="Tempo – Internação Hospitalar")
35 plot(data$Indice.de.Barthel.1~data$Tempo.de.internação.
          hospitalar,ylab="Indice de Barthel",xlab="Tempo – Internação
          Hospitalar")
36
37 boxplot(data$ISS~data$Classificação.do.AIS,main="ISS")
38 t.test(data$ISS~data$Classificação.do.AIS)
39 kruskal.test(data$ISS~data$Classificação.do.AIS)
40
41 boxplot(data$RTS~data$Classificação.do.AIS,main="RTS")
42 t.test(data$RTS~data$Classificação.do.AIS)
43 kruskal.test(data$RTS~data$Classificação.do.AIS)
44
45 #####
46 ## Modelagem – Classificação
47 #####
48 result=matrix(NA,nrow=5,ncol=4)
49 colnames(result)=c("GLM","RF","NB","SVM")
50 rownames(result)=c("ACC","AUC","SEN","SPE","MCC")
51
52 #KNN imputation Q1–Q26
53 data.ready=knnImputation(data[,c
          (25,2,3,7,9,11:19,27,28,31,33,36:61)],k=1)
```

```
54
55 #####
56 # Divisao em treino e teste
57 #####
58 smp=floor(0.8*nrow(data.ready))
59 testIndexes=sample(seq_len(nrow(data.ready)), size=smp)
60 test <- data.ready[-testIndexes, ]
61 train <- data.ready[testIndexes, ]
62
63 ##Modelo logístico
64 mod_logistic_completo <- glm(Classificação.do.AIS~., data =
    train, family=binomial(link = "logit"))
65 mod_logistic_completo_AIC <- stepAIC(mod_logistic_completo)
66 summary(mod_logistic_completo_AIC)
67
68 predicted_logistico <- predict(mod_logistic_completo_AIC, test,
    type="response")
69 optCutOff_glm <- optimalCutoff(test$Classificação.do.AIS,
    predicted_logistico, returnDiagnostics=T)[1]
70 tpred=rep(0,length(predicted_logistico))
71 tpred[predicted_logistico>optCutOff_glm]=1
72
73 t1=table(factor(test[,1], levels=0:1), factor(tpred, levels=0:1))
74 result[1,1]=sum(diag(t1))/sum(t1)
75 result[2,1]=roc(test[,1], predicted_logistico)$auc
76 result[3,1]=t1[1]/sum(t1[1]+t1[2])
77 result[4,1]=t1[4]/sum(t1[3]+t1[4])
78 result[5,1]=mccr(test$Classificação.do.AIS, tpred)
79
80 ##Random Forest completo
81 mod_rf_completo <- train(Classificação.do.AIS~., data = train,
    method = "rf", preProcess = c("scale", "center"), trControl
    = trainControl(method = "repeatedcv", number = 10, repeats
    = 10, savePredictions = TRUE, verboseIter = FALSE))
82 importance <- varImp(mod_rf_completo, scale = TRUE)
83
84 predicted_rf <- predict(mod_rf_completo, test, type='prob')[,1]
85 optCutOff_rf <- optimalCutoff(test$Classificação.do.AIS,
    predicted_rf, returnDiagnostics=T)[1]
```



```
86 tpred2=rep(0,length(predicted_rf))
87 tpred2[predicted_rf>optCutOff_rf]=1
88
89 t2=table(factor(test[,1],levels=0:1),factor(tpred2,levels=0:1))
90 result[1,2]=sum(diag(t2))/sum(t2)
91 result[2,2]=roc(test[,1],predicted_rf)$auc
92 result[3,2]=t2[1]/sum(t2[1]+t2[2])
93 result[4,2]=t2[4]/sum(t2[3]+t2[4])
94 result[5,2]=mccr(test$Classificação.do.AIS,tpred2)
95
96 ##Naive bayes completo
97 mod_nb_completo <- naiveBayes(Classificação.do.AIS~., data =
    train)
98
99 predicted_nb <- predict(mod_nb_completo, test, type='raw')[,1]
100 optCutOff_nb <- optimalCutoff(test$Classificação.do.AIS,
    predicted_nb, returnDiagnostics=T)[1]
101 tpred3=rep(0,length(predicted_nb))
102 tpred3[predicted_nb>optCutOff_nb]=1
103
104 t3=table(factor(test[,1],levels=0:1),factor(tpred3,levels=0:1))
105 result[1,3]=sum(diag(t3))/sum(t3)
106 result[2,3]=roc(test[,1],predicted_nb)$auc
107 result[3,3]=t3[1]/sum(t3[1]+t3[2])
108 result[4,3]=t3[4]/sum(t3[3]+t3[4])
109 result[5,3]=mccr(test$Classificação.do.AIS,tpred3)
110
111 ##SVM completo
112 mod_svm_completo <- ksvm(Classificação.do.AIS~., data = train,
    kernel="polydot", type="nu-svc", probability = TRUE)
113 tpred4 <- predict(mod_svm_completo, test)
114 table(factor(test[,1],levels=0:1),factor(tpred4,levels=0:1))
115
116 t4=table(factor(test[,1],levels=0:1),factor(tpred4,levels=0:1))
117 result[1,4]=sum(diag(t4))/sum(t4)
118 result[2,4]=roc(test[,1],predicted_svm)$auc
119 result[3,4]=t4[1]/sum(t4[1]+t4[2])
120 result[4,4]=t4[4]/sum(t4[3]+t4[4])
121 result[5,4]=mccr(test$Classificação.do.AIS,tpred4)
```

```
122
123 #curva ROC
124 roc(test[,1], predicted_logistico, plot=T, lty=2, col="darkgreen")
125 roc(test[,1], predicted_rf, add=T, plot=T, lty=3, col="blue")
126 roc(test[,1], predicted_nb, add=T, plot=T, lty=4, col="red")
127 roc(test[,1], predicted_svm, add=T, plot=T, lty=5, col="orange")
128 legend(x=0.2, y=.4, c("GLM", "RF", "NB", "SVM"), col=c("darkgreen", "
    blue", "red", "orange"), lty=2:5, box.col = "white")
129
130 #Comparação de Desempenhos (NOVO, ISS, RTS, Barthel)
131 par(mfrow=c(1,4))
132 boxplot(predicted_rf~test$Classificação.do.AIS, ylab="Novo
    Classificador", xlab="Tempo – Internação Hospitalar")
133 boxplot(data$ISS[-testIndexes]~data$Classificação.do.AIS[-
    testIndexes], ylab="ISS", xlab="Tempo – Internação Hospitalar
    ")
134 boxplot(data$RTS[-testIndexes]~data$Classificação.do.AIS[-
    testIndexes], ylab="RTS", xlab="Tempo – Internação Hospitalar
    ")
135 boxplot(data$Indice.de.Barthel.1[-testIndexes]~data$Classificaç
    ão.do.AIS[-testIndexes], ylab="Indice de Barthel", xlab="Tempo
    – Internação Hospitalar")
136
137 #####
138 ## Analise de Sobrevivencia – Nao parametrica
139 #####
140 delta<-rep(1, length(data$Tempo.de.internação.hospitalar))
141 survobj<-Surv(data$Tempo.de.internação.hospitalar, delta)
142 kappa.1<-survfit(survobj~data$Etiologia.do.Trauma) #OBSERVAR
    GRUPOS
143 plot(kappa.1, col = c(1,2,3,4,5,6), main="Etiologia do Trauma")
144 legend("topright", 1.1, lty=c(1,1,1,1,1,1), c("acidente automobilí
    stico", "acidente motocicleta",
145     "acidente bicicleta", "agressão física", "ferimento por arma
    de fogo", "queda"), bty="n", col = c(1,2,3,4,5,6), cex=0.9)
146
147 kappa.2<-survfit(survobj~data$Local.da.lesão)
148 plot(kappa.2, col = c(1,2,3,4,5,6), main="Local da lesão")
```

```
149 legend("topright",1.1,lty=c(1,1,1,1,1,1),c("Boa Recuperação", "
    Estado Vegetativo Persistente", "Limitações Graves","Limitaç
    ões Moderadas" , "Óbito","Outra"),bty="n",col = c
    (1,2,3,4,5,6),cex=0.9)
```