

Diagnosis of Headaches Types Using Artificial Neural Networks and Bayesian Networks

A. Fenerich, M. Steiner, J. Nievola, K. Mendes, D. Tsutsumi, and B. dos Santos

Abstract—The aim of this paper is to classify several types of headaches from patients, using different data analysis methods, with the application of two classifying algorithms, comparatively: Bayesian Networks (BN) and Artificial Neural Networks (ANN). The data was collected through a data survey process applied to 2,177 patients with headache diagnosis in Neurological Clinic of municipality of Joinville/SC, Brazil, from January 2010 to November 2014. It was constructed eight different Test Models, varying: the attributes codification (codification A and B); the network output (one and five) and the classifier algorithms (BN and ANN). It is presented the accuracy results obtained from the eight Test Models, using the software WEKA® (Waikato Environment for Knowledge Analysis). The results presented a good accuracy in all tests realized and they suggest that BNs give better accuracy when comparing to ANNs for this problem.

Index Terms—Artificial intelligence, Headache diagnosis, Machine learning.

I. INTRODUÇÃO

A INTELIGÊNCIA Artificial (IA) é um sistema que “pensa” e “auxilia” de forma racional, tentando não apenas compreender, mas também construir entidades inteligentes [1]. Atualmente, a IA abrange uma enorme variedade de subcampos dos conhecimentos multidisciplinares e vem sendo aplicada nas mais diversas áreas, tais como na Medicina. De modo geral, os sistemas desenvolvidos nesta área buscam aprender a identificar padrões em grandes quantidades de dados, com o objetivo de auxiliar na tomada de decisão clínica em situações repetitivas.

Alguns programas de IA vêm sendo efetivamente usados pelos especialistas na detecção e diagnóstico de doenças, como é o caso do sistema Watson, onde dentre os vários sistemas de IA criados pela IBM, um deles, por exemplo, é direcionado para o diagnóstico de câncer [2]. O Google também lançou recentemente um sistema baseado em *deep learning* (aprendizagem “profunda”) para analisar imagens de células cancerígenas [3].

Além destes casos, várias outras pesquisas têm sido desenvolvidas com o mesmo objetivo de detecção e diagnóstico das mais diversas doenças: problemas cardiovasculares [4], [5], [6], [7]; câncer [8] de pele [9] e de próstata [10]; mal de Alzheimer [11]; dengue [12]; dores de cabeça [13], [14]; entre outras. A IA também vem sendo usada para previsão da longevidade dos pacientes, por meio de imagens médicas e de técnicas de *deep learning* [15].

As revisões do estado da arte de sistemas baseados em aprendizado de máquina aplicados na Medicina [16] mostram melhoras promissoras na detecção, diagnóstico e monitoramento de doenças [17], dentre as quais destacam-se: Redes Bayesianas (*Bayesian Networks*; RBs) e Redes Neurais Artificiais (*Artificial Neural Networks*; RNAs) [18].

Embora os diagnósticos realizados por classificadores tenham tido alto nível de acurácia, eles jamais irão substituir o diagnóstico realizado por médicos especialistas em suas respectivas áreas [19], que serão sempre detentores da palavra final.

Portanto, a ideia de se utilizar este tipo de ferramenta, na prática, não está em produzir um diagnóstico final e definitivo, mas sim em economizar tempo com os casos mais fáceis de diagnosticar, separando os casos de pacientes possivelmente saudáveis daqueles que realmente necessitam atenção [6]. Além disso, estas ferramentas poderão melhor respaldar os diagnósticos realizados por médicos.

Vários pesquisadores mencionam a necessidade do constante aprimoramento das técnicas, de modo a proporcionar um diagnóstico mais preciso de detecção de doenças de forma mais ágil [18] [17]. Além do aprimoramento das técnicas em si, é necessário também que os dados utilizados sejam atualizados e processados de maneira correta.

Um estudo da *World Health Organization* (Organização Mundial da Saúde; OMS) [20] revelou que a cefaleia é um dos problemas de saúde mais comuns em todo o mundo: ela chega a afetar cerca de 92% da população e se constitui em uma das causas mais frequentes de absenteísmo e improdutividade no trabalho e escola. Trata-se de uma doença de alto custo pessoal, social e econômico. O diagnóstico das cefaleias se faz, em geral, através de consultas médicas, utilizando serviços de generalistas (clínicos, pediatras, ginecologistas) ou de especialistas (neurologistas, neurocirurgiões), dedicados exclusivamente a esta área de atuação, chamados cefaliatras.

Neste contexto, o objetivo deste artigo é realizar a classificação dos tipos de cefaleias de pacientes que sofrem deste mal, utilizando diferentes formas de tratamentos e análise dos dados, com a aplicação de dois algoritmos classificadores, comparativamente: RBs e RNAs. A Sociedade Internacional de Cefaleia (*Internacional Headache Society - IHS*) descreve mais de 200 diagnósticos de cefaleias. Na

A. T. Fenerich, Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, Paraná, Brasil, amanda.fenerich@gmail.com.

M. T. A. Steiner, Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, Paraná, Brasil, maria.steiner@pucpr.br.

J. C. Nievola, Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, Paraná, Brasil, julio.nievola@pucpr.br.

K. B. Mendes, Colégio Energia, Balneário Camboriú, Santa Catarina, kabormen@hotmail.com.

D. P. Tsutsumi, Universidade Tecnológica Federal do Paraná (UTFPR), Curitiba, Paraná, Brasil, diego.tsu@gmail.com.

B. S. dos Santos, Universidade Tecnológica Federal do Paraná (UTFPR), Londrina, Paraná, Brasil. Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, Paraná, Brasil, brunosantos@utfpr.edu.br.

prática médica cotidiana, porém, a mais utilizada é a Classificação Internacional das Doenças (CID-10) da OMS. O presente trabalho faz uso desta classificação simplificada (CID-10).

II. REFERENCIAL TEÓRICO

São aqui apresentados, resumidamente, os conceitos das RNAs, das RBs e alguns trabalhos correlatos ao tema proposto.

A. Redes Bayesianas

As RBs são bastante úteis na mineração de dados, pois são flexíveis e de rápida convergência, levando muitos pesquisadores em diferentes áreas de pesquisa a utilizarem esta técnica [21]. Uma RB é um modelo gráfico que consiste de duas partes, G e P , onde G é um Grafo Acíclico Dirigido (*Directed Acyclic Graph*; DAG), cujos nós representam variáveis aleatórias e os arcos, que ligam estes nós, representam dependência condicional das variáveis aleatórias; e P é um conjunto de distribuições de probabilidades condicionais (*Conditional Probability Distribution*; CPD) para cada nó condicionado a seus pais [22] [23].

As distribuições de probabilidades condicionais para cada nó podem ser obtidas de maneira prévia, a partir do conhecimento de especialistas ou, então, aprendidas, a partir de dados [24]. A aprendizagem Bayesiana “aprende” as distribuições de probabilidades da rede, identificando a sua estrutura e, desta forma, verifica quais são as relações de interdependência dadas pelos arcos [25].

Apesar do nome, as RBs não implicam necessariamente que elas dependam de estatísticas bayesianas. Pelo contrário, elas são assim chamadas porque usam a regra de Bayes para inferência probabilística. É possível usar estatísticas bayesianas para treinar uma RB, mas existem também muitas outras técnicas para este fim como, por exemplo, o método do gradiente descendente [22] [26].

B. Redes Neurais Artificiais

O aprendizado das RNAs é orientado pelos próprios dados e, portanto, não necessitam de pressuposições para a sua utilização, o que a torna uma técnica interessante para conjuntos de dados médicos [27]. Também pode-se ressaltar que elas são não-lineares e assim são indicadas para o processamento de dados com padrões complexos [28]. A concepção das RNAs tem inspiração no cérebro (neurônios e sinapses) para construção de modelos [29]. O interesse nas propriedades das RNAs está na habilidade para executar, tolerar entradas ruidosas e aprender, assim como nas RBs [1].

De modo geral, uma RNA é composta de nós ou unidades conectadas por vínculos (entrada/saída) orientados e constitui-se em funcionais matemáticos [30]. Um vínculo serve para propagar a ativação e possui um peso numérico associado, o qual determina a intensidade e o sinal da conexão. Em cada unidade é calculada a função de entrada e então aplicada à função de ativação para gerar a saída [1].

C. Trabalhos Correlatos

A RB foi amplamente utilizada nos últimos anos principalmente na área da saúde. Kasthurirathne *et al.* [24]

analisaram textos livres de relatórios patológicos na Rede de Indiana (Estados Unidos da América – EUA), utilizando RBs, Regressão Logística (RL; *Logistic Regression*), k -vizinhos mais próximos (*k-Nearest Neighbors*; KNN), Florestas Randômicas (FR; *Random Forest*) e Árvores de Decisão (AD; *Decision Trees*), em conjunto com a análise de Divergência de Kullback-Leibler. Ku *et al.* [21] construíram um *framework* para classificar autorrelatos em fóruns de internet como, por exemplo, *Yahoo! Knowledge and Taiwan AIDS Forum*, utilizando técnicas como ganho de informação, Máquinas de Vetor Suporte (*Support Vector Machines*; SVM), RBs e testes- t pareados.

Rao e Makkithaya [31] realizaram uma pesquisa na Índia com diversas técnicas de mineração, incluindo RBs, RL, AD, SVM, assembleias, entre outros, para identificar os melhores classificadores para bases de dados de saúde pública com classes desbalanceadas. RBs, SVM, RNAs, AD e outras técnicas também foram utilizadas por Zhang *et al.* [32] com o intuito de prever sobrepeso e obesidade na base de dados Wirral (Reino Unido). Zhang *et al.* [33] examinaram e classificaram notícias online para monitorar e classificar doenças de mão e pé na base utilizando técnicas de mineração de texto e KNN, SVM e RBs. Moreira e Namen [34] trabalharam com o diagnóstico de demência a partir de um modelo híbrido, envolvendo agrupamentos de textos não estruturados e classificadores como redes ingênuas de Bayes (*Naïve Bayes*; NB), *Bayesian Belief Networks* (BBN) e AD, com melhorias dos modelos gerados a partir de assembleias baseadas em *bagging*, *boosting* e FR.

Da mesma forma que as RBs, RNAs têm sido aplicadas em diversos contextos da área da saúde. Por exemplo, Sridar e Shanthi [35] analisaram o diagnóstico de pacientes com diabetes na Índia utilizando RNAs e regras de associação (*Association Rule Mining*; ARM). Adams *et al.* [36] trataram da identificação de variáveis e construção de um modelo preditivo sobre mortalidade em um levantamento nutricional dos EUA utilizando métodos como RNAs, FR, RL, SVM, entre outros. A base de dados sobre tireóide da Universidade da Califórnia em Irvine (UCI) foi usada para classificação por Nallamuth e Palanichamy [37], que aplicaram RNAs e AD para tal. Xu *et al.* [38] trabalharam com a previsão de novos casos de gripe em Hong Kong com métodos como RNAs e modelo linear geral. Chen *et al.* [39] procuraram explorar os fatores de risco em nascimentos prematuros no Taiwan, fazendo o uso de RNAs e AD.

Outros autores aplicaram técnicas diferentes que não as trabalhadas no presente artigo, porém também tiveram resultados satisfatórios. Högg *et al.* [40] caracterizam sintomas de esclerose múltipla com bases de dados de duas províncias do Canadá, utilizando a RL com penalização para classificação e a RL clássica para verificar as variáveis preditoras. Arslan *et al.* [41] classificaram acidentes vasculares cerebrais isquêmicos com dados do Turgut Ozal Medical Centre (Turquia) a partir das técnicas SVM, *Stochastic Gradient Boosting* (SGB) e RL com penalização, tendo os parâmetros dos modelos melhorados com *grid search*. Vandewiele *et al.* [42] propuseram um sistema de suporte à decisão para dados sobre dores de cabeça, avaliados pelo Hospital Universitário de Ghent (Bélgica). Técnicas como KNN e Algoritmos Genéticos (AG) para análise de

atributos e AD para classificação foram utilizados no sistema. Garcia-Chimeno *et al.* [43] realizaram a classificação de pacientes com enxaqueca por meio de imagens de difusão por ressonância magnética e testes psicológicos, utilizando para seleção de atributos as técnicas FR, L1, seleção univariada e *Gradient Tree Boosting* (GTB). Jackowski *et al.* [44] apresentaram um sistema de classificação de dores de cabeça com dados coletados na Universidade de Novi Sad (Sérvia), sendo que a tarefa de classificação foi baseada em assembleias. Por fim, Perveen *et al.* [45] realizaram um trabalho com base de dados da rede *Canadian Primary Care Centre Surveillance* com o objetivo de classificar pacientes com diabetes utilizando diferentes grupos de adultos a partir de assembleias com *adaboost* e *bagging*, com o algoritmo J48 de AD como técnica de base.

A Tabela I faz um resumo destes trabalhos correlatos, por ordem alfabética, dividindo-os em autores, áreas de aplicação e técnicas.

TABELA I
RESUMO DOS TRABALHOS CORRELATOS

Autores	Áreas de aplicação	Técnicas
Adams <i>et al.</i> [36]	Nutrição e mortalidade	RNA, FR, RL, SVM
Arslan <i>et al.</i> [41]	Acidente Vascular Cerebral	SVM, SGB e RL Penalizada; <i>grid search</i>
Chen <i>et al.</i> [39]	Nascimentos prematuros	RNA e AD
Garcia-Chimeno [43]	Enxaquecas	GTB; L1; FR; análise univariada; SVM; NB; <i>Adaboost</i>
Högg <i>et al.</i> [40]	Esclerose Múltipla	RL com penalização e RL clássica
Jackowski <i>et al.</i> [44]	Dores de cabeça	Assembleias
Kasthurirathne <i>et al.</i> [46]	Relatórios patológicos	RB; RL; KNN; FR; AD
Ku <i>et al.</i> [47]	Autorrelatos em fóruns de internet	Ganho de informação; SVM; RB; testes-t pareados
Moreira e Namen [34]	Demência	NB; BBN; AD; assembleias baseadas em <i>bagging</i> , <i>boosting</i> e FR.
Nallamuth e Palanichamy [37]	Tireoide	RNA e AD
Perveen <i>et al.</i> [45]	Diabetes	<i>Adaboost</i> e <i>bagging</i> com AD como método base
Rao e Makkithaya [31]	Saúde pública	RB; RL; AD; SVM; assembleias
Sridar e Shanthi [35]	Diabetes	RNA e ARM
Vanderwiele <i>et al.</i> [42]	Dores de cabeça	KNN; Algoritmos genéticos; AD
Xu <i>et al.</i> [38]	Gripe	RNA e modelo linear geral
Zhang <i>et al.</i> [32]	Obesidade	RB; SVM; RNA; AD
Zhang <i>et al.</i> [33]	Doenças de mão e pé	KNN; SVM; RB

Legenda: Árvores de Decisão (AD); *Association Rule Mining* (ARM); *Bayesian Belief Networks* (BBN); Florestas Randômicas (RF); *Gradient Tree Boosting* (GTB); *K-Nearest Neighbor* (KNN); *Naïve Bayes* (NB); Redes Bayesianas (BN); Regressão Logística (RL); Redes Neurais Artificiais (RNA); *Stochastic Gradient Boosting* (SGB); *Support Vector Machines* (SVM).

Após a revisão da literatura e dos trabalhos correlatos, verificou-se que este artigo pode contribuir para a área de

Medicina, Engenharia Biomédica, Ciência da Computação, entre outros, diferenciando-se principalmente na escolha e tratamento dos atributos para a tarefa de classificação (sumarizados na seção III) e na criação de diferentes modelos com abordagens distintas para verificar aquele(s) que tenham a maior capacidade de generalização para o problema aqui tratado.

III. MATERIAIS E MÉTODOS

A. Descrição das Variáveis

Foram consideradas 14 variáveis de entrada, que definem os atributos referentes às características pessoais de um paciente e as condições de sua cefaleia, sendo elas (Anexo A): sexo; faixa etária; início da dor; localização da dor; intensidade da dor; tipo de dor; surgimento da dor; evolução da dor; frequência da dor; duração do episódio; sintomas associados; agravantes da dor; atenuantes da dor; e uso de analgésicos.

Além disso, foi considerada uma variável de saída, que define o diagnóstico do tipo de cefaleia, conforme o CID-10, podendo ser: cefaleia tensional (CA); enxaqueca sem aura (ESA); enxaqueca com aura (ECA); cefaleia por uso excessivo de medicamentos (CM); ou outros tipos de cefaleias (OC), que engloba todos os demais tipos considerados menos comuns (que englobam cerca de 200 tipos). Desta forma, trabalhou-se com cinco classes.

B. Coleta e Análise dos Dados

Foi elaborado um questionário semi-estruturado, composto por perguntas relacionadas às variáveis descritas anteriormente, de tal forma que estas preenchessem os critérios necessários para o diagnóstico das principais causas de cefaleias. O diagnóstico, ou seja, a classificação do tipo de dor foi feito a partir da experiência clínica de um médico, que atua na área de cefaliatria e que após algum tempo obteve a confirmação (ou não) do referido diagnóstico.

O questionário foi aplicado com 2.177 pacientes com diagnóstico de cefaleia, de uma Clínica Neurológica do município de Joinville/SC, Brasil, no período de Janeiro de 2010 a Novembro de 2014. Destes 2.177 pacientes, 1.252 possuem “cefaleia tensional”, 307 possuem “enxaqueca sem aura”; 99 “enxaqueca com aura”; 100 “cefaleia por uso excessivo de medicamento” e 419 “outros tipos de cefaleias”, com todos os referidos cinco diagnósticos já comprovados.

As respostas obtidas com a aplicação dos questionários foram codificadas na tentativa de maximizar as acurácias dos oito modelos aplicados (serão mostrados mais adiante).

Assim, estas as variáveis de entrada foram codificadas de duas formas: a) Codificação A, utilizando variáveis em sequência numérica, como por exemplo “1” corresponde ao paciente do sexo “feminino” e “2”, ao sexo “masculino”; b) Codificação B, na forma binária, atribuindo-se o valor “1” quando o paciente possui a característica e o valor “0” caso contrário; por exemplo, o vetor (1, 0) será a representação para o paciente do sexo “feminino” e (0, 1), para o sexo “masculino”.

Para a variável de saída, que determina o diagnóstico do paciente, foram consideradas duas diferentes formas para a classificação: A) classificação com cinco saídas (cinco classes), cada uma correspondendo a um dos diagnósticos de

cefaleia; B) classificação com uma saída (duas classes), com resultados possíveis contidos no intervalo de (0; 1), sendo que desta forma, um resultado contido em (0; 0,5) implicará na resposta “Sim” (possui a cefaleia em questão) e um resultado em [0,5; 1) na resposta “Não” (não possui). Vale destacar que neste caso “B” foram necessárias cinco redes, uma para cada um dos cinco tipos de diagnóstico. Ou seja, no caso “B” faremos uso do método *one-against-all* (também chamado de *one-vs-all*, ou seja, “um contra todos”) usado em classificações com múltiplas classes (três ou mais classes) [48].

Com as duas formas de codificação (A e B), com os as duas possíveis formas de classificação (com cinco: A ou com duas classes: B) e com os dois algoritmos classificadores (código “1” para RB e código “2” para RNAs) ficaram definidos oito tipos de testes, aqui denominados A.A.1; A.A.2; A.B.1; A.B.2; B.A.1; B.A.2; B.B.1 e B.B.2.

IV. RESULTADOS E DISCUSSÃO

Os resultados foram obtidos com o auxílio do *software* WEKA® (*Waikato Environment for Knowledge Analysis*, disponível em: <http://www.cs.waikato.ac.nz/ml/weka>) e os testes realizados tanto para as RBs, quanto para as RNAs, foram aplicados com a opção de validação cruzada com 10 partições e com a configuração padrão em todos os parâmetros. Mais especificamente, no caso das RBs, foi utilizado o método *SimpleEstimator* com α igual a 0,5 para determinar os valores das tabelas de probabilidade condicional, e o método K2 para determinar a estrutura da rede. Já para as RNAs foram utilizados a neurônios escondidos, sendo que $a = (\text{número de atributos} + \text{número de classes})/2$, taxa de aprendizagem de 0,3, e *momentum* de 0,2. Os resultados obtidos são apresentados em forma de matrizes de confusão e o consequente nível de acurácia, medida pela Taxa de Erro, para cada modelo.

A. Resultados do Modelo de Teste A.A.1

O modelo A.A.1 foi elaborado considerando os dados das variáveis de entrada com a Codificação A, ou seja, os 14 atributos que descrevem as características pessoais e condições da dor de cada paciente, juntamente com a variável de saída (diagnóstico da dor) dividida nas cinco classes definidas. Nesta configuração dos dados, foi aplicado o algoritmo de RBs.

O resultado deste modelo para as 2.177 instâncias está apresentado na matriz de confusão da Tabela II (com as linhas sendo a classificação real e as colunas como elas foram classificadas pelo modelo). Já na Tabela III estão apresentados os resultados para os todos os modelos (A.A.1; A.B.1; B.A.1; B.B.1).

Como pode-se verificar, um total de 1.638 instâncias (soma dos valores da diagonal principal da matriz, para as linhas com a denominação “A.A.1”) foram classificadas corretamente, sendo que 1.086 correspondem a correta classificação da cefaleia tensional, 259 a enxaqueca sem aura, 61 a enxaqueca com aura, 38 a cefaleia por medicamento e 194 a classe correspondente aos outros tipos de cefaleias. Desta forma, a acurácia para este caso é de 75,24% (1638/2177).

TABELA II
MATRIZ DE CONFUSÃO PARA O MODELO A.A.1 - RBs

	CT	ESA	ECA	CM	OC
CT	1086	39	4	39	84
ESA	25	259	6	8	9
ECA	15	15	61	2	6
CM	47	10	0	38	6
OC	147	65	7	6	194

TABELA III
MATRIZ DE CONFUSÃO PARA AS RBs

	CT	ESA	ECA	CM	OC
C	AA1: 1086	AA1: 39	AA1: 4	AA1: 39	AA1: 84
	AB1: 1129	AB1: 46	AB1: 4	AB1: 8	AB1: 65
	BB1: 1015	BB1: 50	BB1: 3	BB1: 59	BB1: 125
T	AA1: 1093	AA1: 54	AA1: 3	AA1: 23	AA1: 79
	AB1: 1015	AB1: 50	AB1: 3	AB1: 59	AB1: 125
	BB1: 1093	BB1: 54	BB1: 3	BB1: 23	BB1: 79
E	AA1: 25	AA1: 259	AA1: 6	AA1: 8	AA1: 9
	AB1: 28	AB1: 265	AB1: 6	AB1: 1	AB1: 7
	BB1: 17	BB1: 268	BB1: 6	BB1: 8	BB1: 8
S	AA1: 19	AA1: 276	AA1: 3	AA1: 2	AA1: 7
	AB1: 19	AB1: 276	AB1: 3	AB1: 2	AB1: 7
	BB1: 19	BB1: 276	BB1: 3	BB1: 2	BB1: 7
A	AA1: 15	AA1: 15	AA1: 61	AA1: 2	AA1: 6
	AB1: 14	AB1: 20	AB1: 60	AB1: 1	AB1: 4
	BB1: 7	BB1: 15	BB1: 71	BB1: 1	BB1: 5
M	AA1: 9	AA1: 29	AA1: 57	AA1: 1	AA1: 3
	AB1: 9	AB1: 29	AB1: 57	AB1: 1	AB1: 3
	BB1: 9	BB1: 29	BB1: 57	BB1: 1	BB1: 3
O	AA1: 47	AA1: 10	AA1: 0	AA1: 38	AA1: 5
	AB1: 63	AB1: 12	AB1: 0	AB1: 21	AB1: 4
	BB1: 42	BB1: 9	BB1: 0	BB1: 42	BB1: 7
C	AA1: 62	AA1: 13	AA1: 0	AA1: 19	AA1: 6
	AB1: 62	AB1: 13	AB1: 0	AB1: 19	AB1: 6
	BB1: 62	BB1: 13	BB1: 0	BB1: 19	BB1: 6
O	AA1: 147	AA1: 65	AA1: 7	AA1: 6	AA1: 194
	AB1: 175	AB1: 67	AB1: 8	AB1: 7	AB1: 162
	BB1: 113	BB1: 68	BB1: 6	BB1: 11	BB1: 221
C	AA1: 134	AA1: 74	AA1: 3	AA1: 4	AA1: 204
	AB1: 134	AB1: 74	AB1: 3	AB1: 4	AB1: 204
	BB1: 134	BB1: 74	BB1: 3	BB1: 4	BB1: 204

Legenda: CT (Cefaleia tensional); ESA (Enxaqueca sem aura); ECA (Enxaqueca com aura); CM (Cefaleia por medicamento); OC (Outros tipos de cefaleia).

B. Resultados do Modelo de Teste A.B.1

O Modelo A.B.1 foi testado com as RBs, diferindo-se do primeiro modelo pelo fato de se ter uma saída (duas classes ao invés de cinco). Para os modelos com esta configuração de variável de saída, como já mencionado anteriormente, foi necessário realizar um teste para cada uma das cinco classes, utilizando o método *one-against-all* para classificadores de múltiplas classes (disponível no WEKA® como *Classifiers*; *Meta*; *MultiClassClassifier*).

Similarmente ao resultado do Modelo de Teste mostrado anteriormente, a classificação das 2.177 instâncias para este modelo está apresentada na matriz de confusão da Tabela II, nas linhas com a denominação “A.B.1”. Pode-se notar que 1.637 instâncias foram classificadas corretamente (1.129 casos classificados corretamente para cefaleia tensional; 265 para enxaqueca sem aura; 60 casos para enxaqueca com aura; 21 para cefaleia por medicamento e 162 para os outros tipos de cefaleias), tendo uma acurácia geral de 75,20%.

C. Resultados do Modelo de Teste B.A.1

Neste modelo, o teste foi realizado aplicando-se as RBs com os dados de entrada binarizados (Codificação B), sendo a variável de saída dividida nas cinco classes. O resultado do teste, apresentado na Tabela III, indica que 1.617 instâncias foram classificadas corretamente (1.015 casos classificados corretamente para cefaleia tensional; 268 para enxaqueca sem aura; 71 casos para enxaqueca com aura; 42 para cefaleia por

medicamento e 221 para os outros tipos de cefaleias). A acurácia geral foi de 74,27%.

D. Resultados do Modelo de Teste B.B.1

O Modelo B.B.1 considera as variáveis de entrada binarizadas (Codificação B) e a variável de saída em duas classes. O teste realizado utilizou o algoritmo das RBs. Na Tabela III, na linha denominada “B.B.1”, estão apresentados todos os resultados deste Modelo de Teste, e tem-se que o resultado (instâncias classificadas corretamente) e sua acurácia são, respectivamente, de 1649 e 75,75%.

E. Resultados do Modelo de Teste A.A.2

Com uma configuração dos dados similar ao Modelo A.A.1, este modelo altera somente o algoritmo utilizado para classificar as instâncias, sendo neste caso, as RNAs. O resultado do teste, apresentado na Tabela IV, linhas com denominações “A.A.2”, indica que 1.455 instâncias foram classificadas corretamente, ou seja, 66,83% de acurácia (1.097 casos classificados corretamente para cefaleia tensional; 154 para enxaqueca sem aura; 19 para enxaqueca com aura; 4 para cefaleia por medicamento e 181 para outros tipos de cefaleias).

TABELA IV
MATRIZ DE CONFUSÃO PARA AS RNAs

	CT	ESA	ECA	CM	OC
C	AA2: 1097	AA2: 30	AA2: 18	AA2: 3	AA2: 104
	AB2: 1112	AB2: 32	AB2: 0	AB2: 16	AB2: 92
	BA2: 1039	BA2: 29	BA2: 5	BA2: 30	BA2: 149
	BB2: 1147	BB2: 24	BB2: 7	BB2: 17	BB2: 57
E	AA2: 63	AA2: 154	AA2: 29	AA2: 9	AA2: 52
	AB2: 49	AB2: 229	AB2: 7	AB2: 2	AB2: 20
	BA2: 24	BA2: 234	BA2: 6	BA2: 7	BA2: 36
	BB2: 52	BB2: 238	BB2: 5	BB2: 3	BB2: 9
A	AA2: 26	AA2: 31	AA2: 19	AA2: 1	AA2: 22
	AB2: 22	AB2: 12	AB2: 54	AB2: 0	AB2: 11
	BA2: 8	BA2: 10	BA2: 75	BA2: 0	BA2: 6
	BB2: 14	BB2: 9	BB2: 72	BB2: 2	BB2: 2
C	AA2: 76	AA2: 13	AA2: 1	AA2: 4	AA2: 6
	AB2: 67	AB2: 13	AB2: 0	AB2: 11	AB2: 9
	BA2: 56	BA2: 13	BA2: 2	BA2: 19	BA2: 10
	BB2: 70	BB2: 12	BB2: 0	BB2: 13	BB2: 5
O	AA2: 192	AA2: 30	AA2: 14	AA2: 2	AA2: 181
	AB2: 175	AB2: 33	AB2: 12	AB2: 0	AB2: 199
	BA2: 170	BA2: 42	BA2: 8	BA2: 8	BA2: 191
	BB2: 205	BB2: 36	BB2: 5	BB2: 4	BB2: 169

Legenda: CT (Cefaleia tensional); ESA (Enxaqueca sem aura); ECA (Enxaqueca com aura); CM (Cefaleia por medicamento); OC (Outros tipos de cefaleia)

F. Resultados do Modelo de Teste A.B.2

O Modelo A.B.2 é similar ao A.B.1 com relação a codificação das variáveis de entrada e saída, porém sendo testado com as RNAs. Os resultados, dispostos na Tabela IV, indicam que 1.605 das instâncias foram classificadas corretamente, resultando em uma acurácia de 73,73% (1.112 para cefaleia tensional; 229 para enxaqueca sem aura; 54 para enxaqueca com aura; 11 para cefaleia por medicamento; 199 para outros tipos de cefaleias).

G. Resultados do Modelo de Teste B.A.2

O resultado do teste deste modelo (Tabela IV), utilizando RNAs, dados binarizados (Codificação B) e cinco classes na

variável de saída, indica que 1.558 instâncias foram classificadas corretamente, sendo que a acurácia foi de 71,56% (1.039 para cefaleia tensional; 234 para enxaqueca sem aura; 75 para enxaqueca com aura; 19 para cefaleia por medicamento; 191 para outros tipos de cefaleias).

H. Resultados do Modelo de Teste B.B.2

O Modelo B.B.2 utilizou as RNAs, com os dados binarizados (Codificação B) para as variáveis de entrada, e a variável de saída em duas classes. Os resultados, mostrados na Tabela IV, indicam que 1.147 instâncias foram classificadas corretamente para cefaleia tensional; 238 para enxaqueca sem aura; 72 para enxaqueca com aura; 13 para cefaleia por medicamento; e 169 para outros tipos de cefaleias. Isso fornece uma acurácia de 75,29% para o modelo (1.639/2.177).

I. Comparativo do Desempenho dos Modelos de Testes

As taxas de erro, bem como a porcentagem de instâncias classificadas corretamente, estão resumidas na Tabela V.

TABELA V
QUADRO COMPARATIVO DO DESEMPENHO DOS MODELOS

Modelo de Teste	Taxa de Erro	Acurácia
A.A.1	0,2476	75,24%
A.B.1	0,2480	75,20%
B.A.1	0,2573	74,27%
B.B.1	0,2573	75,75%
A.A.2	0,3317	66,83%
A.B.2	0,2627	73,73%
B.A.2	0,2844	71,56%
B.B.2	0,2471	75,29%

Os resultados encontrados no presente estudo apresentaram um bom nível de acurácia em todos os testes realizados, não tendo uma diferenciação significativa entre os modelos testados. Os resultados sugerem que as RBs (A.A.1; A.B.1; B.A.1; B.B.1) proporcionam melhores porcentagens de acurácias em relação às RNAs.

Dentre os testes utilizando as RNAs, aquele que apresentou melhor resultado foi o modelo com a configuração de dados binarizados (Codificação B) e uma saída em duas classes (*one against all*). A menor acurácia entre todos os modelos testados, foi no que utilizou as RNAs nos dados de entrada com a Codificação 1 e saída com cinco classes (Modelo de Teste A.A.2). Isso sugere que, quando utilizado o algoritmo das RNAs como classificador, é preferível que os dados sejam tratados de forma binarizada, tendo apenas duas classes (uma saída), uma vez que essa diferenciação na forma de tratamento dos dados proporcionou um aumento de 8,46% na acurácia do modelo (75,29 – 66,83).

Este aumento na acurácia do modelo, proporcionado pela forma de tratamento dos dados, não foi evidente quando se trata do uso das RBs, uma vez que a maior diferença na acurácia entre os modelos testados com esse algoritmo classificador foi de apenas 1,48% na acurácia (75,75 – 74,27).

V. CONCLUSÃO

O presente trabalho apresentou diferentes abordagens para o problema de classificação de dores de cabeça (cefaleia) em uma Clínica Neurológica do município de Joinville/SC, Brasil.

Os métodos utilizados (RBs e RNAs) se mostraram efetivos para este tipo de análise fazendo jus ao seu extensivo uso em diferentes aplicações na área da saúde.

Diante dos resultados obtidos (Tabela V), pode-se recomendar para a classificação de novas instâncias para as quais deseja-se conhecer o tipo de cefaleia, o modelo B.B.1 (dados categorizados; saída com duas classes em cada uma das cinco RNAs) ou, então o modelo A.B.1 (dados categorizados; saída com duas classes em cada uma das cinco RBs). A acurácia para este modelo, para o problema aqui abordado, foi de cerca de 76%.

Vale destacar que melhores resultados poderiam ser obtidos com um banco de dados mais robusto, com uma quantidade semelhante (mais homogênea) de instâncias em cada uma das classes, evitando assim o desbalanceamento no número de instâncias em cada classe, pois, conforme a literatura da área, isto torna o problema mais complexo e difícil de obter acurácias elevadas.

Novamente, enfatiza-se que, mesmo o estudo tendo resultados promissores, o diagnóstico fornecido pela técnica (caso a mesma viesse a ser implementada) apenas irá respaldar o diagnóstico de um médico, visto que o mesmo poderá levar em consideração observações subjetivas não contempladas pela técnica. Ou seja, estas técnicas apenas auxiliam os médicos, dando-lhes um respaldo adicional na tarefa de decisão.

Como sugestões para dar continuidade a esta pesquisa tem-se, dentre outras, as seguintes possibilidades: fazer análises mais aprofundadas com os resultados obtidos com as RBs como, por exemplo, extrair informações de sua “arquitetura aprendida” investigando quais os atributos que mais influenciam na classificação. Sugere-se, ainda, realizar testes com outros algoritmos classificadores, dentre os quais pode-se citar as AD e/ou as SVM que, como visto, têm sido bastante utilizados em problemas de diagnósticos médicos.

AGRADECIMENTOS

Os autores agradecem à Clínica Neurológica do município de Joinville/SC pela concessão dos dados para o desenvolvimento do trabalho. Além disso, a 1ª, a 2ª. e o 6º. autores agradecem à CAPES/Fundação Araucária, ao CNPq e à PUC, respectivamente, pelas bolsas que lhes vêm sendo concedidas.

REFERENCIAS

- [1] S. J. Russel and P. Norvig, *Artificial Intelligence: A Modern Approach*, 3 ed., Upper Saddle River, NJ, USA: Prentice Hall Press, 2009.
- [2] IBM Watson Health. Disponível em: <https://www.ibm.com/watson/health/>. Acesso em: maio 2017.
- [3] CNNMoney (Washington). Google uses AI to help diagnose breast cancer. First published March 3, 2017. Disponível em: <http://money.cnn.com/2017/03/03/technology/google-breast-cancer-ai/index.html>. Acesso em: maio, 2017.
- [4] W. G. Baxt, “Use of an artificial neural network for data analysis in clinical decision-making: the diagnosis of acute coronary occlusion,” *Neural Comput.*, vol. 2, no. 4, pp. 480-489, 1990.
- [5] A. Gharehbaghi, M. Borga, B. J. Sjöberg, and P. Ask, “A novel method for discrimination between innocent and pathological heart murmurs,” *Med. Eng. Phys.*, vol. 37, no. 7, pp. 674-682, 2015.
- [6] A. Gharehbaghi, T. Dutoit, P. Ask, and L. Sörmmo, “Detection of systolic ejection click using time growing neural network,” *Med. Eng. Phys.*, vol. 36, no. 4, pp. 477-483, 2014.

ANEXO A – VARIÁVEIS CONSIDERADAS E SUAS CODIFICAÇÕES

Variável		Codificação							
		A	B						
Sexo	Feminino	1	1	0					
	Masculino	2	0	1					
Idade	Até 12 anos	1	1	0	0	0			
	12 a 19 anos	2	0	1	0	0			
	20 a 39 anos	3	0	0	1	0			
	Acima de 40 anos	4	0	0	0	1			
Início da Dor	Dias	1	1	0	0	0			
	Semanas	2	0	1	0	0			
	Meses	3	0	0	1	0			
	Anos	4	0	0	0	1			
Localização da Dor	Hemicraniana	1	1	0	0	0	0		
	Holocraniana	2	0	1	0	0	0		
	Frontal	3	0	0	1	0	0		
	Occipital	4	0	0	0	1	0		
	Bem localizada	5	0	0	0	0	0	1	
Intensidade da Dor	Forte	1	1	0	0	0			
	Muito Forte	2	0	1	0	0			
	Moderada	3	0	0	1	0			
	Fraca	4	0	0	0	1			
Tipo de Dor	Latejante	1	1	0	0	0			
	Peso	2	0	1	0	0			
	Pontada	3	0	0	1	0			
	Atípica	4	0	0	0	1			
Surgimento da Dor	Crise	1	1	0	0	0			
	Contínua	2	0	1	0	0			
	Episódica	3	0	0	1	0			
	Salvas	4	0	0	0	1			
Evolução da Dor	Estável	1	1	0	0				
	Mudando	2	0	1	0				
	Progressiva	3	0	0	1				
Frequência da Dor	Diária	1	1	0	0	0	0		
	Quase diária	2	0	1	0	0	0		
	1 a 2 vezes por semana	3	0	0	1	0	0		
	1 a 3 vezes ao mês	4	0	0	0	1	0		
	Algumas vezes ao ano	5	0	0	0	0	1		
Duração do Episódio	Segundos	1	1	0	0	0	0		
	Minutos	2	0	1	0	0	0		
	Horas	3	0	0	1	0	0		
	Dias	4	0	0	0	1	0		
	Semanas	5	0	0	0	0	1		
	Sintomas Associados	Náusea	1	1	0	0	0	0	0
Vômito		2	0	1	0	0	0	0	0
Fotofobia		3	0	0	1	0	0	0	0
Fonofobia		4	0	0	0	1	0	0	0
Transtornos visuais		5	0	0	0	0	1	0	0
Tontura		6	0	0	0	0	0	1	0
Febre		7	0	0	0	0	0	0	1
Agravantes da Dor		Nervosismo	1	1	0	0	0	0	0
	Menstruação	2	0	1	0	0	0	0	0
	Alimentos	3	0	0	1	0	0	0	0
	Bebidas	4	0	0	0	1	0	0	0
	Sono	5	0	0	0	0	1	0	0
	Esforço Físico	6	0	0	0	0	0	1	0
	Sexo	7	0	0	0	0	0	0	1
	Movimentos do pescoço	8	0	0	0	0	0	0	1
Atenuantes da Dor	Deitar ou dormir	1	1	0	0	0	0		
	Relaxar	2	0	1	0	0	0		
	Distrair-se	3	0	0	1	0	0		
	Caminhadas	4	0	0	0	1	0		
	Gravidez	5	0	0	0	0	1		
Uso de analgésicos	Nunca	1	1	0	0	0	0	0	0
	Raramente	2	0	1	0	0	0	0	0
	Sempre que dói	3	0	0	1	0	0	0	0
	Quase diariamente	4	0	0	0	1	0	0	0
	Diariamente	5	0	0	0	0	1	0	0
	Vários ao dia	6	0	0	0	0	0	1	0

- [7] S. F. Weng, J. Reys, J. Kai, J. M. Garibaldi, and N. Qureshi, “Can machine-learning improve cardiovascular risk prediction using routine clinical data?” *PLoS ONE*, vol. 12, no. 4, pp. e0174944, 2017.
- [8] G. Schwarzer, W. Vach, and M. Schumacher, “On the misuses of artificial neural networks for prognostic and diagnostic classification in oncology,” *Stat. Med.*, vol. 19, no. 4, pp. 541-561, 2000.
- [9] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau, and S. Thrun, “Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 542, no. 7639, pp. 115-118, 2017.
- [10] M. Han, P. B. Snow, J. M. Brandt, and A. W. Partin, “Evaluation of artificial neural networks for the prediction of pathologic stage in prostate carcinoma,” *Cancer*, vol. 91, no. S8, pp. 1661-1666, 2001.

- [11] L. E. Collij, F. Heeman, J. P. A. Kuijter, R. Ossenkoppele, M. R. Benedictus, C. Möller, S. C. J. Verfaillie, E. J. Sanz-Arigitá, B. N. M. van Berckel, W. M. van der Flier, P. Scheltens, F. Barkhof, and A. M. Wink, "Application of machine learning to arterial spin labeling in mild cognitive impairment and Alzheimer disease," *Radiology*, vol. 281, no. 3, pp. 865-875, 2016.
- [12] A. C. dos Santos, "Aprendizado de máquina aplicado ao diagnóstico de dengue," in 13th Encontro Nacional de Inteligência Artificial e Computacional (SBC ENIAC-2016), Recife, PE, Brasil, 2016, pp. 8-12.
- [13] R. V. Toledo, "Sistema de Apoio ao Diagnóstico Diferencial de Cefaleia," Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Informática Aplicada, PUC-Paraná, 2000.
- [14] K. B. Mendes, "O uso de redes neurais artificiais no diagnóstico preditivo dos tipos mais frequentes de cefaleia," Dissertação de mestrado, Programa de Pós-graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná, 2008.
- [15] L. Oakden-Rayner, G. Carneiro, T. Bessen, J. C. Nascimento, A. P. Bradley, and L. J. Palmer, "Precision Radiology: Predicting longevity using feature engineering and deep learning methods in a radiomics framework," *Sci Rep-UK*, vol. 7, no. 1, pp. 1648, 2017.
- [16] T. J. Cleophas and A. H. Zwinderman, *Machine Learning in Medicine - a Complete Overview*, Suíça: Springer, 2015.
- [17] P. Sajda, "Machine learning for detection and diagnosis of disease," *Annu. Rev. Biomed. Eng.*, vol. 8, pp. 537-565, 2006.
- [18] I. Kononenko, "Machine learning for medical diagnosis: history, state of the art and perspective," *Artif. Intell. Med.*, vol. 23, no. 1, pp. 89-109, 2001.
- [19] H. L. Semigran, D. M. Levine, S. Nundy, and A. Mehrotra, "Comparison of physician and computer diagnostic accuracy," *JAMA Intern. Med.*, vol. 176, no. 12, pp. 1860-1861, 2016.
- [20] World Health Organization, WHO. Publicações da OMS. Disponível em: <http://www.who.int/pt/publications/pt/>. Acesso em: mai, 2017.
- [21] B. G. Marcot and T. D. Penman, "Advances in Bayesian network modelling: Integration of modelling technologies," *Environ. Modell. software*, vol. 111, pp. 386-393, 2019.
- [22] J. Dean, *Big data, data mining, and machine learning: value creation for business leaders and practitioners*, Hoboken, New Jersey, USA: John Wiley & Sons, 2014.
- [23] M. B. Sales, A. A. dos S. Schwaab, and S. M. Nassar, "Application of Bayesian Networks to Assist the Expansion of the Digital Inclusion of Elderly People.," *IEEE Lat. Am. Trans.*, vol. 8, no. 3, pp. 275-279, 2010.
- [24] D. Koller and N. Friedman, *Probabilistic graphical models: principles and techniques*, Cambridge, MA, USA: MIT press, 2009.
- [25] A. J. Q. Carita, L. C. Leite, A. P. P. Medeiros, R. Barros, and L. Sauer, "Bayesian Networks applied to Failure Diagnosis in Power Transformer," *IEEE Lat. Am. Trans.*, vol. 11, no. 4, pp. 1075-1082, 2013.
- [26] S. Russel, J. Binder, D. Koller, and K. Kanazawa, "Local learning in probabilistic networks with hidden variables," in *IJCAI*, Berkeley, CA, USA, 1995, pp. 1146-1152.
- [27] P. Fergus, I. Idowu, A. Hussain, and C. Dobbins, "Advanced artificial neural network classification for detecting preterm births using EHG records," *Neurocomputing*, vol. 188, pp. 42-49, 2016.
- [28] V. Pergialiotis, A. Pouliakis, C. Parthenis, V. Damaskou, C. Chrelias, N. Papantoniou, and I. Panayiotides, "The utility of artificial neural networks and classification and regression trees for the prediction of endometrial cancer in postmenopausal women," *Public Health*, vol. 164, pp. 1-6, 2018.
- [29] E. Alpaydin, *Introduction to machine learning*, Cambridge, MA, USA: MIT press, 2014.
- [30] P. A. Morais Júnior, E. O. do Nascimento, M. G. F. Neto, and L. N. de Oliveira, "Characterization of Automobile Acoustic Insulation Performance based on Artificial Neural Networks via Sensitivity Analysis," *IEEE Lat. Am. Trans.*, vol. 16, no. 1, pp. 222-231, 2018.
- [31] R. R. Rao and K. Makkithaya, "Learning from a Class Imbalanced Public Health Dataset: a Cost-based Comparison of Classifier Performance," *Int. J. Electr. Comput. Eng.*, vol. 7, no. 4, pp. 2215-2222, 2017.
- [32] S. Zhang, C. Tjortjijis, X. Zeng, H. Qiao, I. Buchan, and J. Keane, "Comparing data mining methods with logistic regression in childhood obesity prediction," *Inf. Syst. Front.*, vol. 4, no. 11, pp. 449-460, 2009.
- [33] Y. Zhang, Y. Dang, H. Chen, M. Thurmond, and C. Larson, "Automatic online news monitoring and classification for syndromic surveillance," *Decis. Support Syst.*, vol. 47, no. 4, pp. 508-517, 2009.
- [34] L. B. Moreira and A. A. Namen, "A hybrid data mining model for diagnosis of patients with clinical suspicion of dementia," *Comput. Methods Programs Biomed.*, vol. 165, pp. 139-149, 2018.
- [35] K. Sridar and D. Shanthi, "Medical diagnosis system for the diabetes mellitus by using back propagation-Apriori algorithms," *J. Theor. Appl. Inf. Technol.*, vol. 68, no. 1, pp. 36-43, 2014.
- [36] L. J. Adams, G. Bello, and G. G. Dumancas, "Development and Application of a Genetic Algorithm for Variable Optimization and Predictive Modeling of Five-Year Mortality Using Questionnaire Data," *Bioinf. Biol. Insights*, vol. 9, no. 3, pp. 31-41, 2015.
- [37] R. Nallamuth and J. Palanichamy, "Optimized construction of various classification models for the diagnosis of thyroid problems in human beings," *Kuwait J. Sci.*, vol. 42, no. 2, pp. 189-205, 2015.
- [38] Q. Xu, Y. R. Gel, L. L. R. Ramirez, K. Nezafati, Q. Zhang, and K-L. Tsui, "Forecasting influenza in Hong Kong with Google search queries and statistical model fusion," *PLoS ONE*, vol. 12, no. 5, pp. 1-17, 2017.
- [39] H-Y. Chen C-H. Chuang, Y. J. Yang, and T. P. Wu, "Exploring the risk factors of preterm birth using data mining," *Expert Syst. Appl.*, vol. 38, no. 5, pp. 5384-5387, 2011.
- [40] T. Högg, J. M. A. Wijnands, E. Kingwell, F. Zhu, X. Lu, C. Evans, J. D. Fisk, R. A. Marrie, Y. Zhao, and H. Tremlett, "Mining healthcare data for markers of the multiple sclerosis prodrome," *Mult. Scler. Relat. Dis.*, vol. 25, pp. 232-240, 2018.
- [41] A. K. Arslan, C. Colak, and E. Sarihan, "Different Medical Data Mining Approaches Based Prediction of Ischemic Stroke," *Comput. Methods Programs Biomed.*, vol. 130, pp. 87-92, 2016.
- [42] G. Vandewiele, F. De Backere, K. Lannoye, M. Vanden Berghe, O. Janssens, S. Van Hoecke, V. Keereman, K. Paemeleire, F. Ongenaes, and F. De Turck, "A decision support system to follow up and diagnose primary headache patients using semantically enriched data," *BMC Med. Inf. Decis. Making*, vol. 18, no. 1, pp. 98-112, 2018.
- [43] Y. Garcia-Chimeno, B. Garcia-Zapirain, M. Gomez-Beldarrain, B. Fernandez-Ruanova, and J. C. Garcia-Monco, "Automatic migraine classification via feature selection committee and machine learning techniques over imaging and questionnaire data," *BMC Med. Inf. Decis. Making*, vol. 17, no. 1, pp. 38-47, 2017.
- [44] K. Jackowski, D. Jankowski, D. Simić, and S. Simić "Migraine Diagnosis Support System Based on Classifier Ensemble," In: A. Bogdanova and D. Gjorgjević (eds) *ICT Innovations 2014: Advances in Intelligent Systems and Computing*, vol 311, 2014.
- [45] Perveen, S.; Shahbaz, M.; Guergachi, A.; Keshavjee, K. Performance Analysis of Data Mining Classification Techniques to Predict Diabetes. *Procedia Comp. Sci.*, vol. 82, pp. 115-121, 2016.
- [46] S. N. Kasthurirathne, B. E. Dixon, J. Gichoya, H. Xu, Y. Xia, B. Mamlin, and S. J. Grannis, "Toward better public health reporting using existing off the shelf approaches: A comparison of alternative cancer detection approaches using plaintext medical data and non-dictionary based feature selection," *J. Biomed. Inf.*, vol. 60, pp. 145-152, 2016.
- [47] Y. Ku, C. Chiu, Y. Zhang, H. Chen, and H. Su, "Text mining self-disclosing health information for public health service," *J. Assoc. Inf. Sci. Technol.*, vol. 65, pp. 928-947, 2014.
- [48] L. Zhou and H. Fujita, "Posterior probability-based ensemble strategy using optimizing decision directed acyclic graph for multi-class classification," *Inf. Sci.*, vol. 400-401, pp. 142-156, 2017.



Amanda Trojan Fenerich possui Graduação em Engenharia de Produção Agroindustrial pela Universidade Estadual do Paraná (UNESPAR, 2012); Mestrado em Engenharia de Produção pela Universidade Federal de Pernambuco (UFPE, 2015) e atualmente é doutoranda do Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS) da Pontifícia Universidade Católica do Paraná (PUCPR).



Maria Teresinha Arns Steiner possui Pós-Doutorado pelo Instituto Tecnológico da Aeronáutica (ITA, 2005) e também pelo Instituto Superior Técnico de Lisboa (IST; 2014). Atuou na Universidade Federal do Paraná (UFPR) de agosto de 1978 a outubro de 2010. Desde fevereiro de 2011 vem atuando na PUCPR, junto ao PPGEPS. Tem experiência em temas da área de Pesquisa Operacional.



Júlio Cesar Nievola possui Pós-Doutorado pela Universidade de Kent at Canterbury (UK; 2008). Atualmente é Professor Titular da PUCPR e líder do Grupo de Pesquisas em Descoberta do Conhecimento e Aprendizagem de Máquina, no Programa de Pós-Graduação em Informática (PPGIA) da PUCPR. Tem experiência na área de Ciência da Computação, atuando principalmente nos seguintes temas: *Data Mining*, Inteligência Artificial, Redes Neurais e Computação Evolucionária.



Karina Borges Mendes possui Graduação em Engenharia Civil pela Universidade do Estado de Santa Catarina (UDESC, 1998); Pós-graduação em Engenharia de Produção (UDESC, 2002); Mestrado no Programa de Pós-Graduação em Métodos Numéricos em Engenharia (PPGMNE) pela Universidade Federal Paraná (UFPR) na área de Programação Matemática. Atualmente é professora no Colégio Energia em Balneário Camboriú, SC, Brasil.



Diego Paolo Tsutsumi possui Graduação em Engenharia Industrial Eletrônica pela Universidade Tecnológica Federal do Paraná (UTFPR) e atualmente é mestrando do curso de Pós-Graduação em Computação Aplicada (PPGCA), também pela UTFPR – Campus de Curitiba. Possui conhecimentos em métodos e técnicas de inteligência artificial e aprendizagem de máquina.



Bruno Samways dos Santos possui Graduação em Engenharia de Produção em Controle e Automação e Mestrado em Engenharia de Produção (UTFPR; 2012; 2014, respectivamente). É docente do Departamento de Engenharia de Produção da UTFPR – Câmpus Londrina desde 2014 e Doutorando do PPGEPS da PUCPR.