

Association for Information Systems
AIS Electronic Library (AISeL)

CAPSI 2020 Proceedings

Portugal (CAPSI)

10-2020

Decision Tree Algorithm Application for Diagnosis of Mental Disorders Symptoms

Gustavo Lemos

Instituto Politécnico de Coimbra, Instituto Superior de Engenharia de Coimbra, a21250089@isec.pt

Rodrigo Silva

CISUC – Centro de Informática e Sistemas da Universidade de Coimbra, rochas@dei.uc.pt

Jorge Bernardino

Polytechnic of Coimbra –ISEC, jorge@isec.pt

Follow this and additional works at: <https://aisel.aisnet.org/capsi2020>

Recommended Citation

Lemos, Gustavo; Silva, Rodrigo; and Bernardino, Jorge, "Decision Tree Algorithm Application for Diagnosis of Mental Disorders Symptoms" (2020). *CAPSI 2020 Proceedings*. 2.

<https://aisel.aisnet.org/capsi2020/2>

This material is brought to you by the Portugal (CAPSI) at AIS Electronic Library (AISeL). It has been accepted for inclusion in CAPSI 2020 Proceedings by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact elibrary@aisnet.org.

Aplicação de Algoritmo de Árvore de Decisão para Diagnóstico de Sintomas de Transtornos Mentais

Decision Tree Algorithm Application for Diagnosis of Mental Disorders Symptoms

Gustavo Lemos, Instituto Politécnico de Coimbra, Instituto Superior de Engenharia de Coimbra, Coimbra, Portugal, a21250089@isec.pt

Rodrigo Rocha Silva, CISUC – Centro de Informática e Sistemas da Universidade de Coimbra, Coimbra, Portugal, rrochas@dei.uc.pt

Jorge Bernardino, Instituto Politécnico de Coimbra, Instituto Superior de Engenharia de Coimbra, Coimbra, Portugal, jorge@isec.pt

Resumo

Atualmente, a incidência de doenças mentais na população mundial tem vindo a crescer, pelo que se torna necessário aprimorar as formas de diagnóstico. Métodos de diagnóstico estruturados em formato de entrevista são considerados os melhores para a recolha e análise de sintomas. Porém, a maioria dos profissionais de saúde revela não utilizar tais métodos, devido a ser necessário uma grande quantidade de tempo para os administrar e interpretar. Para ajudar na resolução deste problema, alguns trabalhos propõe a utilização de árvores de decisão. Neste trabalho criaram-se dois questionários para auxiliar o diagnóstico de distúrbios de humor e distúrbios de ansiedade. Estes questionários foram aplicados a um algoritmo de árvore de decisão, tendo como resultado, que ambos os testes passaram a precisar, em média, de apenas metade das perguntas para chegar a uma classificação. Por fim, desenvolveu-se uma aplicação que permite administrar facilmente os testes obtidos.

Palavras-chave: doenças mentais; diagnóstico; árvores de decisão.

Abstract

Nowadays, the incidence of mental illness in the world population has been growing, so it is necessary to improve how the diagnosis is made. Diagnostic methods structured in an interview format are considered the best for collecting and analyzing symptoms. However, most health professionals reveal that they do not use such methods since it takes a large amount of time to administer and interpret them. In order to help solve this problem, the use of decision trees is proposed. In this project, two questionnaires were created for the diagnosis of two different types of mental illness, and a decision tree algorithm was applied. As a result, both tests required, on average, only half the questions to reach a certain rating. Finally, an application was developed that allows us to easily administer the obtained tests.

Keywords: mental illness; diagnosis; decision trees.

1. INTRODUÇÃO

Estima-se que cerca de 792 milhões de pessoas, mais de 10% da população mundial, sofrem de algum tipo de doença mental, o que cria graves consequências em termos de miséria humana (Ritchie & Roser, 2018). Porém, na maior parte do mundo, está-se ainda longe de atribuir à saúde mental e às perturbações mentais a mesma importância dada à saúde física (World Health Organization, 2002).

A Organização Mundial de Saúde define saúde mental como “um estado de bem-estar em que cada indivíduo reconhece o seu próprio potencial, consegue lidar com as adversidades normais da vida, é capaz de trabalhar produtivamente e de gerar resultados, e é capaz de contribuir para o seu próprio bem ou para o bem da sua comunidade” (World Health Organization, 2004). A doença mental, por outro lado, refere-se a sofrimento, incapacidade ou morbidade por distúrbios mentais, neurológicos ou de uso de substâncias, que podem ser provocados por fatores genéticos, biológicos e psicológicos, bem como por fatores ambientais e condições sociais adversas.

Os distúrbios mentais e comportamentais são identificados e diagnosticados por métodos clínicos que incluem uma descrição pormenorizada de sintomas colhida junto do indivíduo e de outros, inclusive da família, um exame clínico para definir o estado mental, e os testes e exames especializados que sejam necessários (American Psychiatric Association, 2013). Registaram-se, nas últimas décadas, avanços na padronização da avaliação clínica e aumentou a fiabilidade dos diagnósticos. Graças a esquemas estruturados de questionários, a definições uniformes de sinais e sintomas e a critérios padronizados de diagnóstico, é possível hoje em dia atingir um maior grau de fiabilidade e de validade no diagnóstico das perturbações mentais.

Os esquemas estruturados e as listas de verificação de sinais e sintomas permitem, aos profissionais de saúde, colher informações, usando perguntas padronizadas (World Health Organization, 2002). Os sinais e sintomas foram definidos minuciosamente para permitir uma aplicação uniforme. Finalmente, os critérios de diagnóstico para perturbações mentais foram padronizados internacionalmente (World Health Organization, 2002). Atualmente, os critérios de diagnóstico e classificação pelos quais os profissionais de saúde se baseiam estão definidos em dois manuais, o *International Classification of Diseases 11th Revision (ICD-11)* da autoria da Organização Mundial de Saúde, e o *Diagnostic and Statistical Manual of Mental Disorders (DSM-5)* escrito pela American Psychiatric Association (Stein et al., 2020).

Embora existam variadas evidências que comprovam os benefícios do uso de diagnósticos estruturados, apenas uma pequena percentagem de profissionais em saúde mental revela usar tais guias e questionários padronizados para a identificação e diagnóstico de distúrbios mentais. A principal razão para isso é a elevada quantidade tempo necessária para a administração dos testes e para a interpretação dos resultados (Garland et al., 2003). Em ambientes clínicos, particularmente

aqueles que dependem de horas faturáveis para obter receita, o tempo gasto para conduzir procedimentos de diagnóstico estruturados e abrangentes é bastante dispendioso. Assim, esses procedimentos nem sempre são facilmente viáveis em contextos de prática clínica. Portanto, existe a necessidade de otimizar as estruturas de diagnóstico para que sejam mais objetivas e para que demorem menos tempo a administrar.

Uma técnica com potencialidade para fazer essa otimização é o uso de um algoritmo de árvore de decisão. A árvore de decisão é uma técnica de *machine learning*, por meio da qual um problema complexo é decomposto em problemas mais simples e, recursivamente, a mesma estratégia é aplicada a cada um dos problemas simplificados (Silva et al., 2008).

Um questionário, quando aplicado a uma árvore de decisão, representa um modelo adaptativo e contingente, no qual as perguntas específicas a serem feitas dependem das respostas dadas às perguntas anteriores (Steadman et al., 2000). Dessa forma, o algoritmo define o caminho mais eficiente para obter uma classificação. Ao aplicar um diagnóstico padronizado em forma de questionário a uma árvore de decisão, as perguntas a serem feitas seriam para avaliar os sintomas clinicamente significativos presentes e ausentes. É importante salientar que o processo é completamente empírico, com base nas respostas às questões e no critério identificado nos dados da amostra.

Neste trabalho é proposta uma ferramenta que aplica diagnósticos estruturados em forma de questionário por meio de uma árvore de decisão, com o objetivo de reduzir o tempo de realização e classificação dos diagnósticos. Foram contruídos dois questionários para a aplicação do algoritmo de árvore de decisão, o primeiro tem o objetivo de auxiliar o diagnóstico de distúrbios de humor e outro pretende identificar distúrbios de ansiedade. Optou-se por estes dois tipos de questionários por terem doenças que partilham vários sintomas em comum, sendo por vezes difíceis de distinguir. Por exemplo, um caso de bipolaridade pode apresentar os mesmo sintomas do que um caso de depressão, onde a distinção está apenas na ocorrência de episódios maníacos no caso de bipolaridade (Angst, 2013). Ambos os questionários foram criados com base nos critérios de diagnóstico descritos no manual Diagnostic and Statistical Manual of Mental Disorders (DSM-5) (American Psychiatric Association, 2013). É de salientar que os questionários criados não têm o objetivo de fazer um diagnóstico, mas sim servir de auxílio para chegar a um. De seguida, aplicaram-se ambos os questionários a um algoritmo de árvore de decisão. Onde se verificou com sucesso a otimização de ambos os questionários.

2. TRABALHOS RELACIONADOS

Existem algumas abordagens (Stewart et al., (2016); Martínez et al., (2009); Priscilla Dooshima, (2018); Sumathi & Poorna, (2016)) sobre a aplicação de técnicas de *machine learning* ao diagnóstico

de doenças mentais, como o trabalho apresentado por Stewart et al., (2016), onde foi aplicado um algoritmo de árvore de decisão a um teste para o diagnóstico de transtorno de stress pós-traumático. O teste em causa foi o *Clinically Administered PTSD Scale (CAPS)*, que consiste num teste em formato de entrevista constituído por 30 itens, usado por profissionais de saúde mental para a identificação da doença assim como a sua gravidade. O CAPS pode ser dividido em dois tipos de perguntas, 17 para o diagnóstico de transtorno de stress pós-traumático e 13 para medir a sua intensidade. Para desenvolver o modelo de árvore de decisão foi usado o algoritmo *Chi-Squared Automatic Interaction Detector (CHAID)*, que é um algoritmo que deteta relações entre os atributos e as possíveis classificações finais, em cada nível da árvore. Este tipo de algoritmo precisa de amostras bastante grandes para funcionar com eficiência (Milanović & Stamenković, 2017). Como resultado, conseguiu-se reduzir as 17 perguntas do CAPS necessárias para um diagnóstico para, em média, 5 perguntas. Embora este teste esteja limitado apenas ao diagnóstico de uma só doença, tem a vantagem de ter sido utilizada uma amostra real para treino do algoritmo, e consequentemente, obtiveram-se classificações mais próximas da realidade.

No trabalho apresentado por Martínez et al. (2009) é estudado a possibilidade de usar árvores de decisão como ferramenta no diagnóstico de cancro da mama. Foram utilizadas duas bases de dados diferentes que continham informação sobre os sintomas que os médicos têm em conta quando fazem o diagnóstico de um caso de cancro da mama. Foram testados 3 algoritmos diferentes, o ID3 (Iterative Dichotomiser 3), o algoritmo J48 e Naive Bayes. Depois de finalizadas, as árvores de decisão foram testadas quanto à sua precisão. Em relação à primeira base de dados utilizada foi registada uma precisão de 93%, enquanto a árvore de decisão gerada com base na segunda base de dados apresentou uma precisão de aproximadamente 82%.

O trabalho apresentado por Metting et al. (2016) procura avaliar a precisão de algoritmos de árvores de decisão no diagnóstico de doenças pulmonares obstrutivas crónicas. A doença pulmonar obstrutiva crónica (DPOC) é a limitação do fluxo de ar provocada por resposta inflamatória a toxinas inalatórias, em que os sintomas são tosse e dispneia, que se desenvolvem durante anos. O método utilizado para desenvolver a árvore de decisão foi o CHIAD. Como dados de treino foi utilizada uma base de dados com as respostas de 9297 pacientes ao *Clinical COPD Questionnaire*. Como resultados, o algoritmo obteve uma taxa de 85% de acerto no diagnóstico de pacientes com casos de doença pulmonar obstrutiva crónica. Tendo em conta que foi utilizada uma base de dados com informações reais, os resultados obtidos foram muito positivos, e deixam uma previsão de futuro na utilização destes algoritmos.

Já o trabalho desenvolvido por Priscilla Dooshima (2018) utiliza algoritmos de *machine learning*, não para diagnosticar, mas sim para fazer uma avaliação do risco de uma pessoa contrair algum tipo de doença mental. Este trabalho foi desenvolvido na Nigéria onde foram recolhidos dados sobre 30 pacientes. Um estudo feito sobre doenças mentais na Nigéria aponta que estas não são bem aceites

pela população. Neste projeto fez-se uma análise de dados através de uma árvore de decisão e do algoritmo Naive Bayes, para avaliar o risco de contração de uma doença mental, com o objetivo de ajudar em algum tipo de prevenção. Para a construção da árvore de decisão foi usado o método C4.5 e os resultados foram de 83.3% de precisão. Já os resultados obtidos com o uso do Naive Bayes foram de apenas 76.7%.

O estudo realizado por Sumathi & Poorna (2016) está focado na utilização de técnicas de *machine learning* para o diagnóstico precoce de distúrbios mentais, nomeadamente em crianças. Problemas de saúde mental simples em crianças, quando não identificados e tratados, podem vir a revelar-se problemas bastante complexos no futuro, pelo que é de elevada importância o diagnóstico deste tipo de problemas em crianças. Neste estudo foram testadas 8 técnicas de classificação de *machine learning* para o diagnóstico de distúrbios mentais em crianças: *Averaged One-Dependence Estimator* (AODE), que é uma técnica de classificação probabilística; *Multilayer Perceptron* que consiste numa rede neuronal que mapeia um conjunto de dados de entrada num conjunto de resultados apropriados; *Radial Basis Function Network* que também é uma rede neuronal que baseia as suas funções de ativação em funções de classificação; IB1 que é uma técnica de classificação que usa uma medida simples de distância para encontrar a instância mais próxima; KStar que também consiste numa técnica de classificação que usa a entropia como medida de distância; *Multiclass Classifier* que consiste numa técnica que classifica uma instância em duas ou mais classes; *Functional Trees* que é um tipo de árvore de decisão; Por último, *Logical Analysis of Data Tree* que é um classificador que gera uma árvore de decisão. Depois de testados todos os algoritmos com a mesma base de dados, verificou-se que os algoritmos *Multilayer Perceptron*, *Multiclass Classifier* e *Logical Analysis of Data Tree* são os algoritmos que apresentaram melhores resultados quanto à sua correção.

3. FERRAMENTA PROPOSTA

Neste projeto elaboraram-se dois questionários distintos, um para o auxílio de diagnóstico de distúrbios de humor e outro para o auxílio de diagnóstico de distúrbios de ansiedade. O teste de distúrbios de humor tem como possíveis diagnósticos, depressão e transtorno bipolar. O teste para o diagnóstico de distúrbios de ansiedade tem como possíveis classificações, transtorno de ansiedade, transtorno de stress pós-traumático, transtorno obsessivo compulsivo e transtorno de pânico. Neste último, todas as classificações possíveis têm sintomas em comum. O facto de haver sintomas em comum torna menos óbvia a classificação de cada doença, pelo que permite observar os resultados do algoritmo de árvore de decisão numa situação mais complexa.

3.1. Questionários

Os questionários criados são direcionados às pessoas a serem diagnosticadas. Todas as perguntas são de resposta sim/não, e cada uma destina-se à avaliação da presença ou ausência de um determinado sintoma.

O primeiro questionário tem como objetivo o auxílio no diagnóstico de distúrbios relacionados com o humor, nomeadamente, a depressão e o transtorno bipolar. O questionário criado foi o seguinte:

1. Os sintomas experienciados poderão estar ligados a uma condição médica anteriormente identificada?
2. Os sintomas experienciados poderão ser provocados pelo efeito psicológico de alguma substância? (p. ex. medicação, bebidas alcoólicas, drogas, ...)
3. Nos últimos 6 meses sofreu algum episódio maníaco?

(Um episódio maníaco é definido como uma mudança de humor, geralmente para humor persistentemente elevado, expansivo ou irritável. Normalmente estes episódios vêm acompanhados de pelo menos três dos seguintes sintomas:

- Sentimento de grandiosidade;
- Diminuição da necessidade de dormir;
- Falar mais do que o habitual;
- Pensamentos acelerados;
- Distrair-se com facilidade;
- Aumento das atividades direcionadas a objetivos;
- Envolvimento excessivo em atividades com alto potencial para consequências negativas).

4. Os sintomas de mania duraram mais de quatro dias?
5. Sente-se deprimido a maior parte do tempo?
6. Perdeu o interesse ou o prazer por atividades das quais costumava gostar?
7. Experimenta regularmente sentimentos como inutilidade ou culpa inapropriada?
8. Tem pensamentos recorrente sobre morte ou suicídio? Ou já teve alguma tentativa de suicídio?
9. Sofre de alguma perturbação do sono, como insónia ou hipersónia?

Segundo o DMS-5 (American Psychiatric Association, 2013) para fazer o diagnóstico de um distúrbio de humor é necessário garantir que os sintomas não são provocados por fatores externos ao distúrbio, pelo que é abordado pelas perguntas 1 e 2. Para fazer o diagnóstico de um transtorno bipolar é necessário identificar o aparecimento de um episódio de mania, onde é avaliado pelas perguntas 3 e 4. As restantes perguntas seguem o critério de diagnóstico de depressão do DMS-5 no qual, durante um período mínimo de 2 semanas, pelo menos um dos seguintes sintomas deve estar presente: humor depressivo e falta de interesse ou de prazer. Deve ainda estar presente outro tipo de sintomas, como insónias, fadiga, pensamentos de morte e suicídio, entre outros.

O segundo questionário construído, tem como objetivo o auxílio de diagnóstico de distúrbios de ansiedade. As questões são as seguintes:

1. Os sintomas experienciados prejudicam a sua vida pessoal ou profissional?
2. Sente ansiedade e preocupação excessivas sobre algumas atividades ou eventos?
3. Sente-se frequentemente angustiado/a?
4. Procura frequentemente evitar certos pensamentos ou sentimentos?
5. Tem pensamentos recorrentes que causam ansiedade ou agitação?
6. Costuma sofrer ataques de pânico com alguma frequência?
7. Costuma fazer alguma ação ou atividade repetitiva com o objetivo de reduzir ou prevenir a ansiedade?
8. Tem pensamentos ou recordações frequentes acerca de um determinado evento traumático?
9. Tem alguma reação quando na presença de algum objeto ou local que traga recordações de um determinado evento?

Como as doenças relacionadas com os distúrbios de ansiedade têm bastantes sintomas em comum, procurou-se perguntar pelos sintomas diferenciadores. Em relação ao transtorno obsessivo compulsivo, procurou-se saber a presença de alguma obsessão e de comportamentos ritualizados para atenuar a ansiedade abordada pelas perguntas 5 e 7. As perguntas 8 e 9 estão relacionadas com traumas, para a identificação de transtorno de stress pós-traumático. A pergunta 6 tem como objetivo distinguir os distúrbios de pânico. As restantes perguntas abordam sintomas comuns (American Psychiatric Association, 2013).

Após a construção dos dois questionários, criou-se um algoritmo que permitisse gerar dados que simulassem vários preenchimentos dos questionários para servirem de dados de amostra. Os dados

gerados correspondem apenas a várias combinações possíveis de resposta aos questionários, e não a uma simulação da realidade. Cada uma das simulações geradas, foi posteriormente classificada individualmente com base nos critérios de diagnóstico descritos no DMS-5. Depois de os dados terem sido todos classificados, foram aplicados como dados de amostra a um algoritmo de árvore de decisão.

Como os dados utilizados para o treino do algoritmo foram gerados, não tendo qualquer relação com a realidade, não será possível avaliar e validar o conteúdo dos questionários. Porém, este tipo de dados é suficiente para analisar o comportamento do algoritmo.

3.2. Algoritmo

O algoritmo utilizado para construir uma árvore de decisão foi o algoritmo CART (Classification and Regression Trees). Foi escolhido o algoritmo CART pela sua capacidade de gerar árvores de reduzidas dimensões e do elevado desempenho, possuindo grande capacidade de generalização (Garcia, 2003). Com a metodologia empregada pelo CART para a construção de árvores de decisão é possível trabalhar com atributos categóricos ou quantitativos (Stewart et al., 2016). O algoritmo recebe um conjunto de dados necessário para treino e a árvore resultante é baseada na técnica recursiva de divisão binária. O processo é binário porque cada nó é separado sempre em exatamente dois subconjuntos, e à medida que se percorre a árvore, da raiz às folhas são respondidas questões simples do tipo sim/não. A recursividade dá-se em cada subconjunto de dados gerado, até que não seja possível ou não seja necessário efetuar mais partições na árvore. Durante o processo de construção da árvore, o algoritmo precisa de saber que perguntas fazer e quando as fazer. Portanto, para isso é necessário quantificar qual a pergunta que divide melhor os dados em cada instante. Ao calcular a *Gini Impurity* obtém-se o grau de incerteza presente em cada nó, e através do método *Information Gain* consegue-se saber qual a pergunta que irá subdividir melhor os dados presentes em cada nó.

O método *Gini Impurity* calcula a probabilidade de estar errado se for atribuída uma classificação aleatória a um objeto do conjunto de dados. Tem-se:

- Se C for o total de classificações distintas presentes num conjunto de dados e $p(i)$ a probabilidade de escolher um elemento classificado como i , calcula-se a *Gini Impurity* (G):

$$G = \sum_{i=1}^C p(i) * (1 - p(i))$$

Figura 1- Fórmula de cálculo de Gini Impurity

Para calcular a *Information Gain* de cada questão, calcula-se a *Gini Impurity* de cada subconjunto de dados que essa questão iria gerar, e de seguida subtrai-se o resultado obtido ao valor da *Gini Impurity* do conjunto de dados do nó atual. A questão que obtiver o maior valor será a escolhida.

4. RESULTADOS

Na avaliação experimental foram gerados dois testes em forma de questionário com uma estrutura de árvore binária. Ambas as árvores de decisão geradas estão representadas nas Figuras 2 e 3. Nas figuras as perguntas estão representadas pelo seu número correspondente, consoante os questionários apresentados na secção anterior.

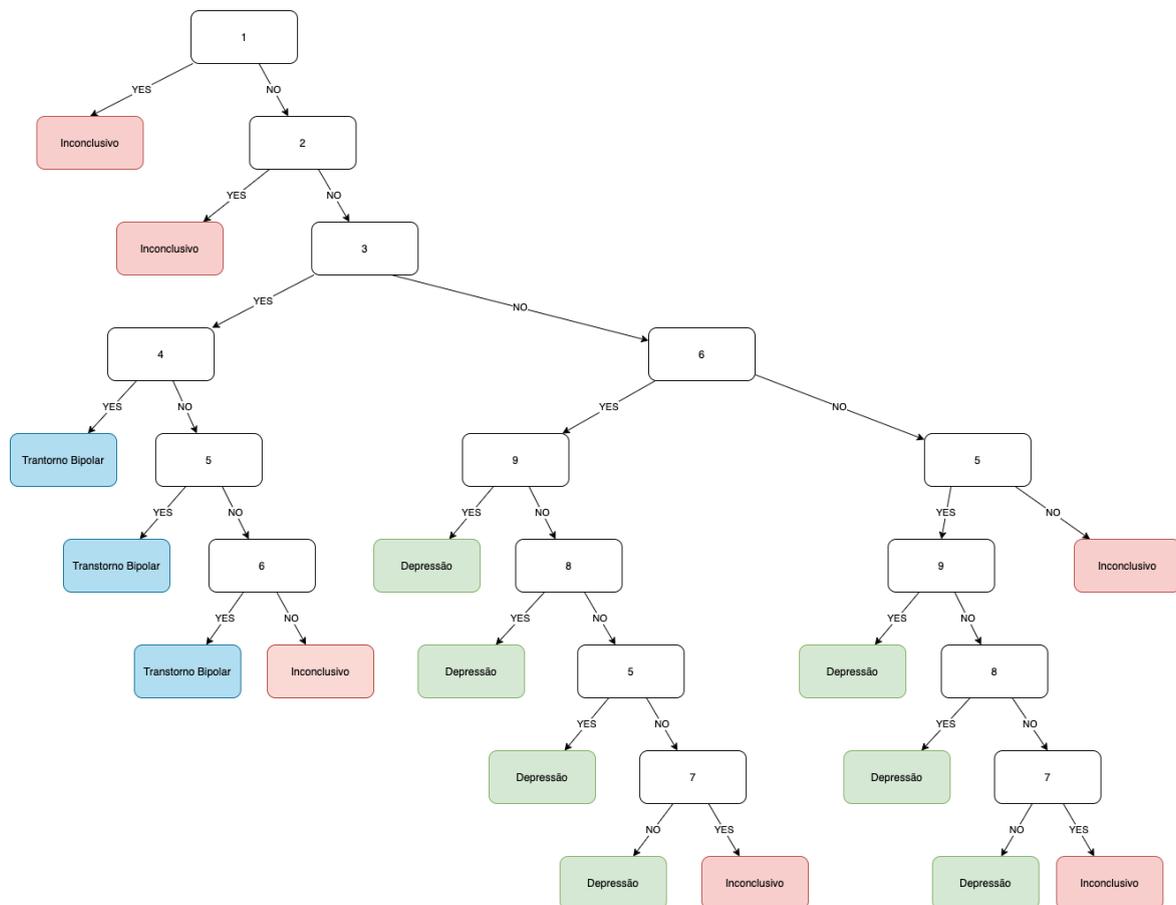


Figura 2 – Árvore de decisão relativa ao questionário para auxílio de diagnóstico de distúrbios de humor

Ao observar a árvore de decisão representada na Figura 2, conclui-se que houve uma melhoria significativa relativamente ao número de questões necessárias para chegar a uma classificação. O questionário para diagnóstico de distúrbios de humor tem 9 perguntas. Com a aplicação do algoritmo de árvore de decisão passou a ser necessário entre 4 a 8 perguntas para chegar a um diagnóstico. Por exemplo, respondendo negativamente às perguntas 1 e 2, é depois apresentada a pergunta 3. Se a resposta for positiva é apresentada a pergunta 4, se for negativa é apresentada a pergunta número 6.

Imagine-se que a resposta é positiva à pergunta 3 e de seguida é positiva também à pergunta 4. Neste cenário, a árvore classifica como Transtorno Bipolar.

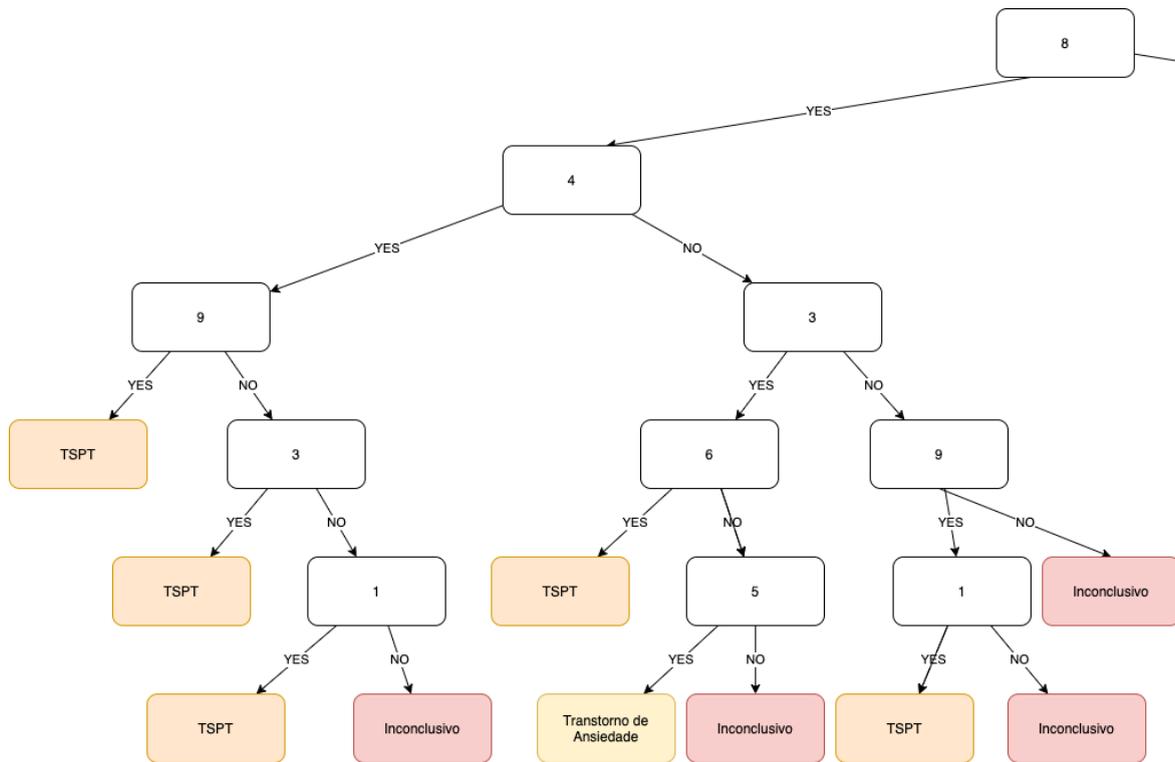


Figura 3 – Trecho da árvore de decisão relativa ao questionário para auxílio de diagnóstico de distúrbios de ansiedade

Na Figura 3 está representado um excerto da árvore de decisão gerada para o questionário relativo aos distúrbios de ansiedade. Pode-se observar que numa situação ideal a árvore necessita apenas de 3 perguntas para chegar a uma decisão. Por exemplo, o questionário inicia com a questão número 8, à qual, se a resposta for positiva, avança para a pergunta 4. Se a resposta for positiva à pergunta 4 avança-se para a 9, se não, segue-se para a pergunta 3. Imagine-se que a resposta é positiva à pergunta 4 e de seguida também é positiva à pergunta 9, neste caso a árvore de decisão classifica como transtorno de stress pós-traumático. Assim foram necessárias apenas 3 perguntas para uma decisão.

5. CONCLUSÃO

Atualmente, existem inúmeras ferramentas para análise e classificação de dados que podem ser aplicadas a diversas áreas, sendo uma delas a medicina. Ferramentas e técnicas de *machine learning* trazem diversas vantagens como, fazer previsões com elevada precisão e otimizar e agilizar certos processos. Este trabalho mostra que os algoritmos de árvores de decisão produzem bons resultados, e poderão ser uma mais-valia quando aplicados ao diagnóstico de doenças mentais. Para que estas

ferramentas se tornem uma realidade no funcionamento da medicina moderna, é preciso uma recolha e aplicação de dados vasta e criteriosa.

Como trabalho futuro pretendemos fazer a recolha dados reais, relativamente aos dois questionários propostos neste trabalho, para o treino do algoritmo, o que irá permitir avaliar o seu conteúdo e fazer melhorias se necessário. Outra proposta é a aplicação de outros algoritmos e fazer uma análise comparativa.

REFERÊNCIAS

- American Psychiatric Association. (2013). *Manual de Diagnóstico Estatístico de Transtornos Mentais - DMS-5*. http://dislex.co.pt/images/pdfs/DSM_V.pdf
- Angst, J. (2013). Bipolar disorders in DSM-5: Strengths, problems and perspectives. *International Journal of Bipolar Disorders*, 1(1), 1–3. <https://doi.org/10.1186/2194-7511-1-12>
- Garcia, S. C. (2003). *O Uso de Árvores de Decisão na Descoberta de Conhecimento na Área da Saúde*. Dissertação de mestrado. <http://hdl.handle.net/10183/4703>
- Garland, A. E., Kruse, M., & Aarons, G. A. (2003). Clinicians and Outcome Measurement: What's the Use? In *Journal of Behavioral Health Services and Research* (Vol. 30, Issue 4, pp. 393–405). *J Behav Health Serv Res*. <https://doi.org/10.1007/BF02287427>
- Martínez, R. E. B., Ramírez, N. C., Mesa, H. G. A., Suárez, I. R., Trejo, M. del C. G., León, P. P., & Morales, S. L. B. (2009). Decision trees as a tool in the medical diagnosis. In *Revista Médica de la Universidad Veracruzana* (Vol. 9, Issue 2). www.uv.mx/rm
- Metting, E. I., In 'T Veen, J. C. C. M., Richard Dekhuijzen, P. N., van Heijst, E., Kocks, J. W. H., Muilwijk-Kroes, J. B., Chavannes, N. H., & van der Molen, T. (2016). Development of a diagnostic decision tree for obstructive pulmonary diseases based on real-life data. *ERJ Open Research*, 2(1). <https://doi.org/10.1183/23120541.00077-2015>
- Milanović, M., & Stamenković, M. (2017). CHAID Decision Tree: Methodological Frame and Application. *Economic Themes*, 54(4), 563–586. <https://doi.org/10.1515/ethemes-2016-0029>
- Priscilla Dooshima, M. (2018). A Predictive Model for the Risk of Mental Illness in Nigeria Using Data Mining. *International Journal of Immunology*, 6(1), 5. <https://doi.org/10.11648/j.iji.20180601.12>
- Ritchie, Hannah & Roser, Max (2018) "Mental Health". *Published online at OurWorldInData.org*. Retrieved from: '<https://ourworldindata.org/mental-health>
- Silva, W. V. da, Corso, J. M. del, Welgacz, H. T., & Peixe, J. B. (2008). Avaliação da escolha de um fornecedor sob condição de riscos a partir do método de Árvore de Decisão. *Revista de Gestão*, 15(3), 77–94. <https://doi.org/10.5700/rege340>
- Steadman, H. J., Silver, E., Monahan, J., Appelbaum, P. S., Robbins, P. C., Mulvey, E. P., Grisso, T., Roth, L. H., & Banks, S. (2000). A classification tree approach to the development of actuarial violence risk assessment tools. *Law and Human Behavior*, 24(1), 83–100. <https://doi.org/10.1023/A:1005478820425>
- Stein, D. J., Szatmari, P., Gaebel, W., Berk, M., Vieta, E., Maj, M., de Vries, Y. A., Roest, A. M., de Jonge, P., Maercker, A., Brewin, C. R., Pike, K. M., Grilo, C. M., Fineberg, N. A., Briken, P., Cohen-Kettenis, P. T., & Reed, G. M. (2020). Mental, behavioral and neurodevelopmental disorders in the ICD-11: An international perspective on key changes and controversies. In *BMC Medicine* (Vol. 18, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s12916-020-1495-2>
- Stewart, R. W., Tuerk, P. W., Metzger, I. W., Davidson, T. M., & Young, J. (2016). A decision-tree approach to the assessment of posttraumatic stress disorder: Engineering empirically rigorous and ecologically valid assessment measures. *Psychological Services*, 13(1), 1–9. <https://doi.org/10.1037/ser0000069>

- Sumathi, M., & Poorna, B. (2016). Prediction of Mental Health Problems Among Children Using Machine Learning Techniques. In *IJACSA International Journal of Advanced Computer Science and Applications* (Vol. 7, Issue 1). www.ijacsa.thesai.org
- World Health Organization. (2002). *The World Health Report 2001. Mental Health: New Understanding, New Hope*. https://www.who.int/whr/2001/en/whr01_en.pdf?ua=1.pdf
- World Health Organization. (2004). *Promoting Mental Health: concepts, emerging evidence, practice*. https://www.who.int/mental_health/evidence/en/promoting_mhh.pdf