

Um Sistema de Suporte ao Diagnóstico de Comprometimento Cognitivo Leve com Adaptação do Modelo de Decisão

Carolina Medeiros Carvalho¹, Flávio Seixas¹, Jerson Laks², Yolanda Boechat³,
Aura Conci¹, Débora Christina Muchaluat Saade¹,

¹Instituto de Computação – Universidade Federal Fluminense (UFF)

²Centro de Doenças de Alzheimer e outras Desordens Mentais na Velhice do Instituto de Psiquiatria, Universidade Federal do Rio de Janeiro (UFRJ)

³Hospital Universitário Antônio Pedro (HUAP), Setor de Geriatria, UFF

{carolmc, fseixas}@midia.com.uff.br, jersonlaks@gmail.com,
yolanda.boechat@gmail.com, aconci@ic.uff.br, debora@midia.com.uff.br

Resumo. Este artigo apresenta um sistema para auxiliar no diagnóstico de comprometimento cognitivo leve com capacidade de atualização do modelo de decisão usando os diagnósticos informados pelos médicos. O sistema proposto é flexível se adaptando a diferentes contextos clínicos, pois permite a inclusão de novos exames que subsidiam o diagnóstico tanto na interface do sistema como no modelo de decisão.

1. Introdução

O envelhecimento da população é um fenômeno que se acentua mundialmente. Dentre as doenças com alta prevalência na terceira idade, encontram-se os transtornos mentais e neurológicos dentre os quais se destacam a demência e transtornos relacionados. A Demência (D) é um estado clínico caracterizado por perda progressiva de funções em múltiplos domínios cognitivos. Existem vários subtipos de demência sendo o mais comum a Doença de Alzheimer (DA), responsável por 60% a 80% dos casos. Outro transtorno relacionado à demência é o Comprometimento Cognitivo Leve (CCL) que usualmente está associado a um estágio pré-clínico de DA.

Os Sistemas de Suporte à Decisão Clínica (CDSS – *Clinical Decision Support Systems*) são uma categoria importante de sistemas de informação projetados para melhorar a tomada de decisão através da redução das taxas de erros de diagnósticos. Tais sistemas não visam à substituição dos médicos especialistas, mas buscam subsidiá-los com uma opinião e, aos profissionais não especializados, podem fornecer uma indicação para auxiliar o diagnóstico, agilizando o encaminhamento do paciente a outro especialista e a antecipação do tratamento. Uma limitação da grande maioria dos sistemas de suporte a diagnóstico atuais é que estes se baseiam em modelos de decisão que não sofrem atualizações com o tempo. [Carvalho et al. 2017a] propõem um CDSS para auxiliar no diagnóstico de D, DA e CCL acessível por dispositivos móveis cujo modelo de decisão baseia-se em Redes Bayesianas. Porém, o modelo de decisão é estático, ou seja, não se modifica na medida em que novos casos clínicos contendo diagnóstico confirmado (positivo ou negativo) são registrados pelos médicos que utilizam o sistema, nem permite a inclusão de novos dados de exames no modelo de decisão. Alguns trabalhos descrevem uma atualização do modelo de decisão usando aprendizado incremental, dentre os quais destacam-se sistemas com atualização do modelo de decisão baseando-se em *streams* de dados [Sun et al. 2010, Zhang et al.

2012, Fong et al. 2013]. Contudo, estes trabalhos se propõem a diagnosticar doenças/condições de saúde que exigem o monitoramento contínuo, como em ambientes de UTI, coletando grandes quantidades de dados fisiológicos continuamente e atualizando o modelo de decisão em tempo real, diferente do presente artigo. Outros trabalhos descrevem o auxílio computacional ao diagnóstico de DA [Chan et al. 1993, Lee et al. 2014], DA e CCL [Cho et al. 2012] e tumores cerebrais [Tortajada Velert 2012] usando aprendizado incremental. Contudo, estes trabalhos não permitem a inclusão de novas *features* e utilizam imagens para o diagnóstico.

Este trabalho propõe um CDSS para auxiliar no diagnóstico de CCL com capacidade de atualizar seu modelo de decisão usando os diagnósticos informados pelos médicos para aprimorá-lo. No CDSS proposto, o modelo de decisão baseia-se em fatores predisponentes, sinais, sintomas e resultados de testes neuropsicológicos informados pelos médicos para cada paciente e assume-se que os dados utilizados em aprendizagens anteriores estão disponíveis. O CDSS proposto também permite a modificação dos critérios de diagnóstico com a inclusão de novos exames (*features*) no modelo de decisão na medida em que tais exames têm seus valores suficientemente informados pelos médicos para os casos clínicos diagnosticados.

2. CDSS Proposto

O CDSS proposto possui alguns componentes principais: uma interface de comunicação, um modelo de decisão, um mecanismo de inferência e um processo automático de aquisição de conhecimento. Com base no diagnóstico sugerido pelo sistema, o médico pode inserir o seu diagnóstico para o paciente. Além disso, o médico pode ainda atualizar os critérios de diagnóstico, configurando o sistema com novos testes neuropsicológicos a serem aplicados. O processo automático de aquisição de conhecimento periodicamente verifica a existência de novos casos clínicos com diagnóstico informado pelo médico e atualiza o modelo de decisão. Este processo segue as seguintes etapas: (1) Separação da base de casos clínicos em três sub-bases para diagnóstico respectivo de D, DA e CCL; (2) Para cada sub-base: (a) Pré-processamento: com a exclusão dos atributos com percentual não informado superior a 70% e ganho de informação inferior a 0,0001 [Seixas et al 2014]; (b) escolha do melhor classificador dentre classificadores bayesianos e outros muito utilizados na área médica usando o método de avaliação *leave-one-out* e quatro medidas de desempenho para quatro cenários incluindo a aplicação ou não dos seguintes pré-processamentos adicionais: discretização supervisionada dos atributos contínuos; e balanceamento usando *oversampling* a 100% para as sub-bases de treinamento quando estiverem desbalanceadas; (3) Armazenamento dos classificadores de melhor desempenho, um para cada doença, treinados com as respectivas sub-bases após pré-processamento usando os respectivos cenários de melhor desempenho. Os classificadores passíveis de serem escolhidos são configurados com parâmetros default e, para os cenários com discretização, são: RB (Rede Bayesiana com a modelagem proposta por [Seixas et al 2014], NB (*Naive Bayes*), A1DE (*Averaged One Dependence Estimators* [Webb et al 2012]), k-NN (*k Nearest Neighbours*), Árvore de Decisão C4.5, RF (*Random Forest*) e SVM (*Support Vectors Machine*). As medidas de desempenho escolhidas foram: acc (acurácia), F1 score, AUC (área embaixo da curva ROC) e RMSE probabilístico (raiz quadrada do erro probabilístico quadrático médio) [Han et al 2011]. O processo de aquisição de conhecimento, que atualiza o modelo de decisão a partir de toda a base de casos clínicos, automaticamente leva em consideração os testes neuropsicológicos

recém-adicionados, desde que apresentem ganho de informação mínimo e sejam suficientemente informados.

3. Resultados

Foram utilizadas duas bases: a base do CDA (Centro de Doenças de Alzheimer e outras Desordens Mentais na Velhice do Instituto de Psiquiatria, UFRJ) para testar o processo automático de aquisição do conhecimento e a base do HUAP (Hospital Universitário Antônio Pedro, UFF) para testar o desempenho dos classificadores escolhidos por este processo com dados não utilizados no treinamento. A base do CDA possui 35 casos diagnosticados como positivo para CCL e 32 casos diagnosticados como negativo para CCL. A base do HUAP possui 19 casos diagnosticados como negativo para CCL e 36 casos diagnosticados como positivo para CCL. Os exames mais utilizados por cada um desses hospitais para o diagnóstico de CCL não são os mesmos: existem 6 exames em comum, mas existem 5 exames apenas presentes na base do CDA e 3 exames apenas presentes na base do HUAP. A Tabela 1 ilustra o desempenho estimado obtido pelos classificadores para CCL em que o classificador de melhor desempenho está destacado. São mostrados apenas os resultados do cenário de melhor desempenho que incluiu a discretização. O cenário de melhor desempenho foi escolhido levando-se em o conjunto das medidas de desempenho (acc, F1, AUC e RMSE). O balanceamento não foi aplicado, pois a base de CCL já estava balanceada. A Tabela 2 ilustra a matriz de confusão gerada pelos testes usando a base do HUAP para o classificador automaticamente escolhido (A1DE). Nestes testes, exames presentes apenas na base do HUAP foram desconsiderados e exames presentes apenas na base do CDA foram considerados como não informados. Para CCL, os resultados foram: acurácia de 85%, F1 de 0,86, AUC de 0,77 e RMSE de 0,32, desempenho inferior ao estimado pelo *leave-one-out*: 93%, 0,93, 0,95 e 0,28, respectivamente.

Tabela 1. Desempenho estimado obtido para os classificadores para CCL

CCL	RB	NB	A1DE	1-NN	3-NN	5-NN	7-NN	C4.5	RF	SVM
acc (%)	90	90	93	88	90	90	90	84	81	82
F1	0,90	0,90	0,93	0,88	0,90	0,90	0,90	0,84	0,81	0,82
AUC	0,96	0,97	0,95	0,88	0,91	0,93	0,95	0,85	0,92	0,82
RMSE	0,28	0,29	0,28	0,35	0,33	0,32	0,3	0,38	0,35	0,42

Tabela 2. Matriz de confusão gerada pelos testes para CCL usando a base do HUAP

CCL	Ground Truth	
Predito	Positivo	Negativo
Positivo	29	1
Negativo	7	18

4. Conclusões e Trabalhos Futuros

O presente trabalho apresentou um sistema de suporte ao diagnóstico de CCL que permite a atualização de seu modelo de decisão utilizando os diagnósticos informados pelos médicos especialistas para cada paciente. Ele visa subsidiar os usuários do sistema com sugestões de diagnóstico e exames a serem realizados, sendo flexível e adaptável para diferentes contextos clínicos permitindo a inclusão de novos exames na interface do sistema e no modelo de decisão. Como trabalho futuro, deseja-se inserir no sistema os diagnósticos e os exames ainda não presentes na base de casos clínicos e contidos na base do HUAP, para testar o processo de aquisição do conhecimento e a inclusão automática de novos exames. Além disso, pretende-se aprimorar a escolha dos

classificadores configurando automaticamente parâmetros específicos para cada classificador de forma a otimizar o desempenho.

Referências

- Carvalho, C. M., Muchaluat-Saade, D. C., Conci, A., Seixas, F. L., and Laks, J. (2017). A clinical decision support system for aiding diagnosis of Alzheimer's disease and related disorders in mobile devices. ICC 2017, Paris.
- Carvalho, C. M.; Seixas, F.L.; Muchaluat-Saade, D. C.; Conci, A.; and Laks, J. (2017). Improving a Bayesian Decision Model for Supporting Diagnosis of Alzheimer's Disease and Related Disorders. In *13th International Conference on Machine Learning and Data Mining*, julho 2017, New York, USA.
- Chan, M., Andre, B., Herrera, A., and Celsis, P. (1993). Incremental learning in a multilayer neural network as an aid to Alzheimer's disease diagnosis. In *Systems, Man and Cybernetics, 1993.'Systems Engineering in the Service of Humans', Conference Proceedings., International Conference on*, Vol. 4, pages 1-4. IEEE.
- Cho, Y., Seong, J. K., Jeong, Y., Shin, S. Y., and Alzheimer's Disease Neuroimaging Initiative. (2012). Individual subject classification for Alzheimer's disease based on incremental learning using a spatial frequency representation of cortical thickness data. *Neuroimage*, 59(3): 2217-2230.
- Fong, S., Zhang, Y., Fiaidhi, J., Mohammed, O., and Mohammed, S. (2013). Evaluation of stream mining classifiers for real-time clinical decision support system: a case study of blood glucose prediction in diabetes therapy. *BioMed Research International*, 2013.
- Han, J., Kamber, M., Pei, J (2011), *Data Mining: Concepts and Techniques*, Elsevier.
- Lee, G. Y., Kim, J., Kim, J. H., Kim, K., and Seong, J. K. (2014). Online learning for classification of Alzheimer disease based on cortical thickness and hippocampal shape analysis. *Healthcare informatics research*, 20(1):61-68.
- Seixas, F. L., Zadrozny, B., Laks, J., Conci, A., Muchaluat-Saade, D. C. (2014) “A Bayesian network decision model for supporting the diagnosis of dementia, Alzheimer’s disease and mild cognitive impairment”. *Computers in biology and medicine*, 51:140-158.
- Sun, J., Sow, D., Hu, J., Ebadollahi, S. (2010, December). A system for mining temporal physiological data streams for advanced prognostic decision support. In *Data Mining (ICDM), 2010 IEEE 10th International Conference on*. IEEE.
- Tortajada Velert, S. (2012) “Incremental Learning approaches to Biomedical decision problems”. Tese de Doutorado, Universidade de Valencia, Espanha.
- Webb, G. I., Boughton, J. R., Zheng, F., Ting, K. M., Salem, H. (2012) Learning by extrapolation from marginal to full-multivariate probability distributions: decreasingly Naïve Bayesian classification. *Machine Learning* 86 (2):233-272.
- Zhang, Y., Fong, S., Fiaidhi, J., Mohammed, S. (2012). Real-time clinical decision support system with data stream mining. *BioMed Research International*, 2012.