

Classificação da Doença de Alzheimer a partir de Imagens de Ressonância Magnética utilizando Competição e Cooperação entre Partículas

Caio Carneloz,
Fabricio Breve
IGCE Unesp
Rio Claro, Brasil
caio.carneloz@fc.unesp.br, fabricio@rc.unesp.br

Resumo—Este projeto de pesquisa tem como objetivo utilizar técnicas de aprendizado de máquina para obter um classificador capaz de auxiliar profissionais da área da saúde a melhor identificarem a doença de Alzheimer. Primeiro, serão coletadas imagens médicas rotuladas e não-rotuladas de uma base de dados pública. O segundo passo será obter informações importantes presentes nessas imagens. Com as informações coletadas, o método de aprendizado semi-supervisionado chamado Competição e Cooperação entre Partículas será responsável por analisar os dados de forma a classificá-los como uma imagem de um cérebro com ou sem a doença de Alzheimer.

Área: Inteligência Computacional

I. INTRODUÇÃO

A doença de Alzheimer, chamada internacionalmente de *Alzheimer's Disease* ou abreviada por *AD*, é uma disfunção cerebral neurodegenerativa associada à perda de conexões cerebrais [1]. A doença de Alzheimer é também o tipo mais comum de demência [2] e atinge principalmente pessoas com mais de 65 anos de idade [3].

Um dos principais problemas que envolvem o tratamento da doença está logo nos primeiros passos, em seu diagnóstico, que é de intensa dificuldade, como Hyman aborda [4].

É conhecido que tal enfermidade está diretamente relacionada à perda da massa cinzenta presente no cérebro humano [5] e também a algumas outras mudanças cerebrais que poderiam ter seus padrões identificados através de Imagens de Ressonância Magnética (*Magnetic Resonance Imaging* ou *MRI*) exemplificada na Figura 1. Partindo deste pressuposto, diversos autores utilizaram métodos computacionais para classificarem automaticamente, através de *MRI's*, cérebros com ou sem a doença de Alzheimer [6] [7] [8] [9] [10].

Desde o início da utilização de máquinas para realização de trabalhos humanos houve uma constante evolução e cada vez mais tarefas podem ser executadas por computadores. Um bom exemplo de como este aperfeiçoamento evoluiu é a possibilidade de utilizar métodos computacionais para reconhecer padrões, como Turk [11] demonstra em seu trabalho no reconhecimento de faces humanas. A área de reconhecimento de




Figura 1. Exemplo de Imagem de Ressonância Magnética, onde na esquerda tem-se o cérebro de um paciente saudável e na direita o cérebro de um paciente com Alzheimer.

Fonte: bbc.com/news/health-31807961

padrões está diretamente ligada ao Aprendizado de Máquina, sub-campo da Ciência da Computação. No Aprendizado de Máquina, existem dois grandes métodos, o Aprendizado Supervisionado e o Aprendizado Não-Supervisionado. Cada um dos métodos utiliza técnicas de forma a possibilitarem a classificação automática de dados com uma boa taxa de precisão.

Baseado nas premissas anteriores, foi possível observar a possibilidade de aplicação do método de Competição e Cooperação entre Partículas para a classificação de imagens de ressonância magnética de forma a auxiliar no diagnóstico da doença de Alzheimer. O método a ser utilizado neste trabalho engloba características das duas técnicas citadas anteriormente e é categorizado como um método de aprendizado semi-supervisionado [12]. Espera-se obter uma ferramenta confiável que possa ser utilizada por médicos de forma a diminuir o número de diagnósticos errôneos.

II. CONCEITOS E TÉCNICAS

A. Aprendizado de Máquina

Esta área da Inteligência Artificial aborda o desenvolvimento de métodos computacionais que possam reproduzir a forma de aprender dos seres humanos [13]. Muitas vezes, o principal motivo dessa busca não é imitar sistematicamente os seres humanos a ponto de substituí-los em tarefas, mas sim, auxiliá-los [14]. Um dos maiores focos da área está

VII Workshop do Programa de Pós-Graduação em Ciência da Computação: "Interação entre Academia e Empresa", Unesp, Rio Claro, 14 e 15 de setembro de 2017.

em alcançar métodos que sejam capazes de reconhecerem padrões complexos [15]. No aprendizado supervisionado, são fornecidas ao método, entradas com rótulos que indicam sua classe ou tipo, de forma a ensinar ao algoritmo o padrão de cada um desses tipos. A abordagem não-supervisionada não recebe dados rotulados, portanto, a partir de padrões identificados nas entradas, o algoritmo faz um agrupamento das semelhantes.

B. Aprendizado Semi-Supervisionado

O aprendizado semi-supervisionado faz uso tanto de dados rotulados quanto de dados não rotulados [16], ou seja, é um meio termo entre o aprendizado supervisionado e não-supervisionado [17]. O maior motivo desta característica se deve ao fato de que a quantidade de dados não rotulados que encontra-se disponível é grande e rotular os mesmos não é algo viável. Portanto, o aprendizado semi-supervisionado proporciona a possibilidade da utilização de uma grande quantidade de dados não-rotulados e apenas uma pequena quantidade de rotulados, obtendo uma boa classificação e utilizando menos trabalho humano nas rotulagens [15].

III. METODOLOGIA DE DESENVOLVIMENTO

O modelo de competição e cooperação entre partículas a ser aplicado neste trabalho utiliza o aprendizado semi-supervisionado e se baseia em uma busca por território em um grafo. O grafo representa o conjunto de dados onde as arestas conectam nós semelhantes. Os nós, por sua vez, representam as amostras utilizadas. Durante a execução do método, partículas competem e cooperam entre si para propagarem sua classe e determinarem as bordas das demais classes.

Inicialmente, tem-se uma certa quantidade de nós que possui rótulo. Partículas são geradas na posição desses nós rotulados e caminham através do grafo cooperando com outras partículas que possuem o mesmo rótulo para classificarem amostras que ainda não estão rotuladas. Em contrapartida, partículas de rótulos diferentes, competem para possuir a maior quantidade de nós e também para evitarem que seus territórios sejam invadidos [12]. As amostras necessárias para a geração do grafo serão obtidas após a extração de características das *MRI's* de pacientes. Diferente da maioria dos modelos baseados em grafo, que possuem complexidade cúbica ($O(n^3)$) [18], o modelo de competição e cooperação entre partículas tem complexidade linear ($O(n)$) no laço principal [19].

IV. CONSIDERAÇÕES FINAIS

Como foi abordado neste resumo, encontrar uma maneira de auxiliar médicos no diagnóstico da doença de Alzheimer é extremamente necessário e de suma importância para os futuros casos da doença. Espera-se que através dos métodos computacionais aqui citados, seja possível trazer uma ferramenta com utilidade para o meio.

O próximo passo para o andamento do projeto consiste em utilizar um extrator de características para obter uma boa extração dos dados presentes nas imagens de ressonância magnética. Desta forma, será obtida uma base de dados

consistente para que o modelo de competição e cooperação entre partículas possa realizar a classificação dos dados.

REFERÊNCIAS

- [1] A. B. Tufail, A. Abidi, A. M. Siddiqui, and M. S. Younis, "Automatic classification of initial categories of alzheimer's disease from structural mri phase images: a comparison of psvm, knn and ann methods," in *Proceedings of World Academy of Science, Engineering and Technology*, no. 72. World Academy of Science, Engineering and Technology (WASET), 2012, p. 1731.
- [2] S.-T. Yang, J.-D. Lee, T.-C. Chang, C.-H. Huang, J.-J. Wang, W.-C. Hsu, H.-L. Chan, Y.-Y. Wai, and K.-Y. Li, "Discrimination between alzheimer's disease and mild cognitive impairment using som and psvm," *Computational and mathematical methods in medicine*, vol. 2013, 2013.
- [3] L. E. Hebert, P. A. Scherr, J. L. Bienias, D. A. Bennett, and D. A. Evans, "Alzheimer disease in the us population: prevalence estimates using the 2000 census," *Archives of neurology*, vol. 60, no. 8, pp. 1119–1122, 2003.
- [4] G. W. Small, P. V. Rabins, P. P. Barry, N. S. Buckholtz, S. T. DeKosky, S. H. Ferris, S. I. Finkel, L. P. Gwyther, Z. S. Khachaturian, B. D. Lebowitz *et al.*, "Diagnosis and treatment of alzheimer disease and related disorders: consensus statement of the american association for geriatric psychiatry, the alzheimer's association, and the american geriatrics society," *Jama*, vol. 278, no. 16, pp. 1363–1371, 1997.
- [5] G. Karas, E. Burton, S. Rombouts, R. Van Schijndel, J. O'Brien, P. Scheltens, I. McKeith, D. Williams, C. Ballard, and F. Barkhof, "A comprehensive study of gray matter loss in patients with alzheimer's disease using optimized voxel-based morphometry," *Neuroimage*, vol. 18, no. 4, pp. 895–907, 2003.
- [6] R. S. Desikan, H. J. Cabral, C. P. Hess, W. P. Dillon, C. M. Glastonbury, M. W. Weiner, N. J. Schmansky, D. N. Greve, D. H. Salat, R. L. Buckner *et al.*, "Automated mri measures identify individuals with mild cognitive impairment and alzheimer's disease," *Brain*, vol. 132, no. 8, pp. 2048–2057, 2009.
- [7] D. Zhang, Y. Wang, L. Zhou, H. Yuan, D. Shen, A. D. N. Initiative *et al.*, "Multimodal classification of alzheimer's disease and mild cognitive impairment," *Neuroimage*, vol. 55, no. 3, pp. 856–867, 2011.
- [8] C. Davatzikos, Y. Fan, X. Wu, D. Shen, and S. M. Resnick, "Detection of prodromal alzheimer's disease via pattern classification of magnetic resonance imaging," *Neurobiology of aging*, vol. 29, no. 4, pp. 514–523, 2008.
- [9] P. Vemuri, J. L. Gunter, M. L. Senjem, J. L. Whitwell, K. Kantarci, D. S. Knopman, B. F. Boeve, R. C. Petersen, and C. R. Jack, "Alzheimer's disease diagnosis in individual subjects using structural mr images: validation studies," *Neuroimage*, vol. 39, no. 3, pp. 1186–1197, 2008.
- [10] S. Klöppel, C. M. Stonnington, J. Barnes, F. Chen, C. Chu, C. D. Good, I. Mader, L. A. Mitchell, A. C. Patel, C. C. Roberts *et al.*, "Accuracy of dementia diagnosis? a direct comparison between radiologists and a computerized method," *Brain*, vol. 131, no. 11, pp. 2969–2974, 2008.
- [11] M. A. Turk and A. P. Pentland, "Face recognition using eigenfaces," in *Computer Vision and Pattern Recognition, 1991. Proceedings CVPR'91., IEEE Computer Society Conference on*. IEEE, 1991, pp. 586–591.
- [12] F. A. Breve, L. Zhao, and M. G. Quiles, "Particle competition and cooperation for semi-supervised learning with label noise," *Neurocomputing*, vol. 160, pp. 63–72, 2015.
- [13] B. K. Natarajan, *Machine learning: a theoretical approach*. Morgan Kaufmann, 2014.
- [14] D. Barber, *Bayesian reasoning and machine learning*. Cambridge University Press, 2012.
- [15] B. R. d. Silva and F. A. Breve, "Segmentação de imagens utilizando competição e cooperação entre partículas," *Interciência & Sociedade*, pp. 75–85, 2015.
- [16] X. Zhu, "Semi-supervised learning," in *Encyclopedia of machine learning*. Springer, 2011, pp. 892–897.
- [17] O. Chapelle, B. Scholkopf, and A. Zien, "Semi-supervised learning (chapelle, o. et al., eds.; 2006)[book reviews]," *IEEE Transactions on Neural Networks*, vol. 20, no. 3, pp. 542–542, 2009.
- [18] X. Zhu, "Semi-supervised learning literature survey," 2005.
- [19] F. Breve, L. Zhao, M. Quiles, W. Pedrycz, and J. Liu, "Particle competition and cooperation in networks for semi-supervised learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 24, no. 9, pp. 1686–1698, 2012.