

Planejamento automático de cirurgias de estrabismo utilizando Extra Tree Regressor

Fernando H. F. Leite¹, João D. S. de Almeida¹, Jorge A. M. Teixeira¹
Geraldo B. Junior¹

¹Núcleo de Computação Aplicada – Universidade Federal do Maranhão (UFMA)
São Luís – MA – Brasil

{fernandohenrique, jdallyson, jorge, geraldo}@nca.ufma.br

Resumo. *Buscando automatizar o processo de planejamento cirúrgico para estrabismo horizontal, este trabalho utiliza Extra Tree Regressor em uma abordagem de múltiplas saídas para prever medidas de correção. Como resultado, foi obtido o MAE de 0,69 e RMSE de 1,79 em milímetros.*

1. Introdução

O estrabismo consiste em qualquer desvio do alinhamento binocular e ocorre entre 1,55% e 3,6% da população. Sua incidência pode estar associada ao desalinhamento resultante de trauma, cirurgia, distúrbios da visão ou neurológicos [Repka et al. 2018].

Como um dos tratamentos, o procedimento cirúrgico busca alinhar os olhos, para preservar o desenvolvimento visual adequado [Rohr et al. 2017]. Neste trabalho são abordadas as previsões para procedimentos de recuo e ressecção no eixo horizontal.

Dessa forma, propõe-se um método de previsão capaz de considerar as inter-relações entre os músculos, para prever as medidas de correção e reduzir o erro absoluto.

2. Metodologia

A base de dados utilizada neste trabalho é uma extensão da base de dados utilizada no trabalho de Almeida et al. (2015). É composta por 153 pacientes, com 24 características e 8 medidas¹ de recuo e ressecção. No pré-processamento faz-se uso da técnica de *One Hot Encoder* [Potdar et al. 2017] para tratar variáveis categóricas, assim como a normalização entre [-1, 1] para padronizar a distribuição. No estágio de treinamento e otimização utiliza-se o regressor Extra Tree Regressor (ETR) [Geurts et al. 2006], seguindo uma abordagem de múltiplas saídas predizendo as 8 medidas. Na otimização foram realizadas 3000 estimações a partir do Hyperopt [Bergstra et al. 2013]. É importante ressaltar que, validação cruzada foi aplicada com *v-fold* igual a 10, na proporção de 90/10% para treinamento/testes, utilizando todo o conjunto de dados com amostras intercaladas e aleatórias. Ao final, o melhor modelo é comparado com os dados definidos pelo especialista para determinar o desempenho através do Erro Absoluto Médio (MAE) e da Raiz do Erro Quadrático Médio (RMSE).

¹Recuo do músculo reto medial do olho direito (RcRMD); Ressecção do músculo reto medial do olho direito (RsRMD); Recuo do músculo reto lateral do olho direito (RcRLD); Ressecção do músculo reto lateral do olho direito (RsRLD); Recuo do músculo reto medial esquerdo (RcRME); Ressecção do músculo reto medial do olho esquerdo (RsRME); Recuo do músculo reto lateral esquerdo (RcRLE); e Ressecção do músculo reto lateral do olho esquerdo (RsRLE).

3. Resultados e Discussão

A Tabela 1 mostra os resultados alcançados na predição de medidas para a correção. Para o menor MAE e RMSE têm-se 0,495 e 1,496, ambos no mesmo procedimento, graças ao correto aprendizado da baixa incidência de paciente submetidos a este procedimento. Quanto aos piores MAE e RMSE obteve-se 0,854 e 2,092 em RcRMD e RcRLE respectivamente. Onde no pior MAE, verificou-se que a alta variabilidade das medidas de correção tenham impactado na capacidade de predição do regressor mesmo que 43% tenha realizado este procedimento. Já para o pior RMSE atribui-se o desempenho a incidência de apenas 30% neste procedimento, com prevalência de duas medidas de correção.

Tabela 1. MAE e RMSE para o método ETR. D, olho direito; E, olho esquerdo.

Métrica	RcRM		RsRM		RcRL		RsRL		Média
	D	E	D	E	D	E	D	E	
MAE	0.667	0.854	0.600	0.724	0.817	0.853	0.495	0.542	0.694 ± 0.208
RMSE	1.502	1.846	1.738	1.968	1.962	2.092	1.496	1.759	1.796

4. Conclusão

Este estudo apresentou a viabilidade quanto a predição de medidas de correção para estrabismo utilizando o regressor Extra Tree numa abordagem de múltiplas saídas. As contribuições deste trabalho estão na redução dos erros MAE, pela aplicação de algoritmos de regressão com múltiplas saídas, sem a necessidade de transformação do problema. Demonstrando uma melhora de até 29,18% para o MAE. Vale salientar que houve uma perda de desempenho no RMSE. Para melhorar a validação dos resultados visa-se ampliar a base de dados, incluindo dados provenientes de outros especialistas, de forma a melhorar a generalização das características. Além disso, pretende-se investigar o planejamento cirúrgico para os desvios verticais.

Referências

- Bergstra, J., Yamins, D., and Cox, D. D. (2013). Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures.
- de Almeida, J. D. S., Silva, A. C., Teixeira, J. A. M., Paiva, A. C., and Gattass, M. (2015). Surgical planning for horizontal strabismus using support vector regression. *Computers in biology and medicine*, 63:178–186.
- Geurts, P., Ernst, D., and Wehenkel, L. (2006). Extremely randomized trees. *Machine learning*, 63(1):3–42.
- Potdar, K., Pardawala, T. S., and Pai, C. D. (2017). A comparative study of categorical variable encoding techniques for neural network classifiers. *International journal of computer applications*, 175(4):7–9.
- Repka, M. X., Lum, F., and Burugapalli, B. (2018). Strabismus, strabismus surgery, and reoperation rate in the united states: analysis from the iris registry. *Ophthalmology*, 125(10):1646–1653.
- Rohr, J. T. D., Isaac, C. R., and Correia, C. d. S. (2017). Epidemiology of strabismus surgery in a public hospital of the brazilian federal district. *Revista Brasileira de Oftalmologia*, 76(5):250–254.