

Planejamento Cirúrgico de Estrabismo Horizontal Utilizando Regressores de Múltiplas Saídas

Thalles Alencar Silva, João Dallyson Sousa de Almeida,
Jorge Antonio Meireles Teixeira, Geraldo Braz Junior

¹ Núcleo de Computação Aplicada (NCA) – Universidade Federal do Maranhão (UFMA) Caixa Postal 65.085–580 - São Luís – MA - Brasil

thalles.al.slv@gmail.com, joao.dallyson@ufma.br

Abstract. *Strabismus is an ophthalmologic pathology that affects about 4% of the population, that may cause irreversible sensorial damage to vision. The treatment of more severe cases requires surgical intervention. The planning in such operations is complex and requires, besides vast knowledge on the subject, expertise from the specialist doctor. And so, the presented paper makes use of multi-output regressors and Support Vector Regression machines (SVR) to indicate the strabismus surgical planning. In our most precise method, of the three evaluated, it was obtained MAE of 0.798 millimeters and RMSE of 1.259 millimeters in the indication of the horizontal strabismus surgical planning.*

Resumo. *O estrabismo é uma patologia oftalmológica que afeta cerca de 4% da população, que pode causar danos sensoriais irreversíveis à visão. O tratamento dos casos mais graves requerem intervenção cirúrgica. O planejamento de tais operações é complexo e exige, além de vasto conhecimento na área, experiência por parte do médico especialista. Desta forma, este trabalho utiliza regressores com múltiplas saídas e Máquinas de Vetores de Suporte para Regressão (SVR) para indicar o planejamento de cirurgias de estrabismo. Em nosso método mais preciso, dos três avaliados, foi obtido EAM de 0.798 milímetros e REQM de 1.259 milímetros na indicação do plano cirúrgico de estrabismos horizontais.*

1. Introdução

Estrabismo é um problema oftalmológico que afeta negativamente a qualidade de vida através de disfunção visual e aparência anormal [Ziaei et al. 2016]. Identificado pela perda do paralelismo entre os olhos este pode ser vertical (hipotropia e hipertropia) e/ou horizontal (esotropia e exotropia).

A cirurgia de estrabismo é definida como procedimentos cirúrgicos incisivos executados nos músculos extraoculares para tratamento de estrabismo [Mills et al. 2004]. Na seção 2 faremos uma explanação mais detalhada com relação ao planejamento cirúrgico, descrevendo características que qualificam pacientes passíveis da operação bem como esclarecendo alguns conceitos úteis à nossa metodologia.

O procedimento cirúrgico é indicado para a maioria dos casos com desvios acima

de 15Δ , devido à presença de sinais e sintomas como diplopia¹, astenopia², torcicolo ocular, nistagmo³, redução de campo visual, comprometimento estético estigmatizante e alterações sensoriais [NOEL et al. 1997].

Os fatores envolvidos na operação de correção de desvios são diversos e, aqui, estaremos utilizando os parâmetros de avaliação para o planejamento definidos por [Almeida et al. 2015] para correção de desvios horizontais. Em seu trabalho foram utilizadas Máquinas de Vetores de Suporte para Regressão (SVR) treinando-se um modelo para cada variável-alvo – aqui este método será apresentado como "método *single-target*".

Neste artigo estarão sendo apresentadas novas abordagens com regressores de múltiplas saídas, descritos na Seção 3.1, objetivando o planejamento cirúrgico de correção de desvios horizontais, onde apenas dois músculos extraoculares (Reto Medial e Reto Lateral) em cada olho são responsáveis pela patologia.

A seção 3.2 apresenta o regressor utilizado na criação dos modelos baseados nos métodos descritos. A Seção 4 apresenta a base de dados utilizada neste trabalho, bem como a metodologia utilizada no treinamento dos modelos e os parâmetros que obtiveram os melhores resultados na execução da validação cruzada.

2. Planejamento Cirúrgico de Estrabismo

Os fatores envolvidos no planejamento da estratégia cirúrgica em casos de estrabismo são muito complexos, envolvendo tanto a participação do conhecimento científico teórico como a experiência do cirurgião [Noorden and Campos 2001, Diaz and Dias 2000]. Existem diversas fórmulas e tabelas, baseadas em vários casos que fornecem valores para o planejamento cirúrgico de acordo com o grau do desvio observado [Noorden and Campos 2001, Diaz and Dias 2000]. Estas tabelas apresentam como desvantagem o fato de fornecerem valores médios, que muitas vezes não podem ser aplicados individualmente [Diaz and Dias 2000], já sendo bem estabelecida a grande variabilidade da correção cirúrgica obtida em termos de dioptrias prismáticas por milímetro de recuo e/ou ressecção [Diaz and Dias 2000]

A cirurgia envolve o enfraquecimento da força muscular, aumento da tensão muscular e realinhamento da ação do músculo. Existem basicamente dois tipos de procedimentos cirúrgicos: cirurgias de enfraquecimento dos músculos por meio da diminuição do torque muscular, que pode ser entendido como a capacidade de se converter a contração muscular em movimento rotacional; e cirurgia de aumento da tensão muscular por meio da ressecção do músculo.

No primeiro tipo, podem ser feitos recuos da posição original do músculo, sutura em redea, expansores musculares (faixa de silicone ou autotransplante do tendão). Já no segundo, realizam-se ressecções do comprimento do músculo, reposicionamento anterior da inserção e pregueamento do tendão muscular.

¹Visão dupla: ocorre quando a imagem de um objeto é formada sobre pontos não correspondentes na retina.

²Olhos cansados, que ocorrem geralmente quando se realiza um trabalho com olhar fixo a uma distância fixa. Sensação ocular desconfortável.

³Nistagmo são oscilações repetidas e involuntárias rítmicas de um ou ambos os olhos em algumas ou todas as posições de mirada.

Via de regra, no momento da decisão pela operação ou não de um certo músculo do olho, consideram-se os seguintes pontos:

- a) Todo músculo muito fraco ou muito tenso deve ser incluído no planejamento cirúrgico, fazendo-se ressecção (fortalecimento) ou recuo (enfraquecimento);
- b) Quando há visão boa nos dois olhos, deve-se dividir a cirurgia entre eles;
- c) Se não há visão boa, concentra-se a cirurgia em um só olho, na medida do possível. O mesmo vale para XT / X(T) e quando o paciente tem retardo do desenvolvimento neuropsicomotor (RDNPM).

Para planejar a cirurgia, o especialista normalmente examina o paciente para obter as seguintes informações:

- **Idade;**
- **Tipo de desvio:** Esotropia (ET), Exotropia (XT), Hipertropia (HT) ou Hipotropia (HoT);
- **Acuidade visual (AV).** Este tipo de exame é importante, pois a cirurgia pode ser dividida entre os dois olhos, caso o paciente apresente boa visão;
- **Exame de refração.** Do exame de refração são obtidas informações sobre o equivalente esférico do grau do paciente;
- **Fixação binocular (FB).** Do exame de fixação binocular o especialista obtém a informação de qual olho é o fixador.
- **Exame de fundoscopia (FOI).** Este exame permite a visualização da retina e de seus componentes: vasos, disco óptico e mácula.
- Medida do desvio nas posições primária e secundária do olhar;
- Medida das versões. A medida das versões avalia os movimentos binoculares conjugados dos músculos oculares: reto medial (RM), reto lateral (RL), reto inferior (RI), reto superior (RS), oblíquo inferior (OI) e oblíquo superior (OS).

3. Regressão

A análise de regressão tem o objetivo de verificar a existência de uma relação funcional entre uma variável com uma ou mais variáveis, obtendo-se uma equação que explique a variação da variável dependente Y , pela variação dos níveis das variáveis independentes X_1, X_2, \dots, X_p [Queiroz 2010]. Em outras palavras, consiste na obtenção de uma função capaz de representar o relacionamento entre um conjunto de dados x com l instâncias e um conjunto de valores-alvo (discretos) y com d instâncias, com $l, d \geq 1$.

Quando $d > 1$, ou seja quando temos uma função de relação com mais de uma variável-alvo a ser obtida a partir dos dados em x , temos regressão *multi-output* (ou regressão com múltiplas saídas), podendo também ser conhecida por *multi-target*, *multi-variate* e *multi-response*.

3.1. Regressão com Múltiplas Saídas

Considere um grupo de dados de treinamento D com N instâncias contendo um valor determinado para cada variável $X_1, \dots, X_m, Y_1, \dots, Y_d$, i.e., $D = \{(x^1, y^1), \dots, (x^N, y^N)\}$. Cada instância é caracterizada por um vetor de entrada com m variáveis descritivas, ou preditivas, $x^l = (x_1^l, \dots, x_j^l, \dots, x_m^l)$ e um vetor de saída com d variáveis-alvo $y^l = (y_1^l, \dots, y_i^l, \dots, y_d^l)$, com $i \in \{1, \dots, d\}$, $j \in \{1, \dots, m\}$, e

$l \in \{1, \dots, N\}$. O objetivo é obter, a partir dos dados de treinamento D , uma função h que seja capaz de gerar, para cada vetor x de características, um vetor y com d variáveis-alvo [Borchani et al. 2015].

Ou seja, a partir dessa base de treinamento D obtém-se uma função que correlaciona os dados de entrada x em um conjunto de saídas y . Neste trabalho serão discutidos três dentre os diversos métodos existentes atualmente para regressão com múltiplos valores-alvo. Estes estão divididos dois grupos: Métodos de Transformada de Problema e Métodos de Transformada de Algoritmo.

O primeiro grupo baseia-se na ideia de transformar o problema de múltiplas saídas, isto é com d variáveis alvo, em múltiplos (d) problemas de único valor-alvo, gerando para cada um destes um modelo, e, por fim, concatenando todos os valores-alvo como o conjunto de saídas y descrito anteriormente.

O segundo baseia-se na criação de modelos únicos capazes de produzir os d valores-alvo a partir dos dados em x . Estes modelos são mais complexos, uma vez que calculam simultaneamente todos os valores, levando em consideração, também, os relacionamentos entre eles.

O primeiro, e mais simples, destes métodos é o método *Single-Target* (ST). Consiste em uma abordagem de transformada de problema definida pela geração de d modelos de regressores com única saída – uma para cada valor-alvo – a partir da uma versão levemente alterada da base de treinamento. Cada h_i é dada pelo treinamento de um regressor a partir da base $D_i = \{(x^1, y_i^1), \dots, (x^N, y_i^N)\}$, $i \in \{1, \dots, d\}$, e cada um destes resulta em um único valor y_i , como descrito por [Spyromitros-Xioufis et al. 2012].

Já a abordagem Multi-Target Regressor Stacking (MTRS) é um processo em duas etapas baseado no conceito de *stacked generalization* (generalização empilhada) definida por [Spyromitros-Xioufis et al. 2012]. Inicialmente os modelos de primeiro estágio são treinados, da mesma forma que os valores obtidos no método ST, de onde obtém-se um primeiro conjunto de valores y' . Na segunda etapa, d novos metamodelos serão gerados para que se obtenha os valores finais $Y_i, i \in \{1, \dots, d\}$

Cada um destes metamodelos gerados nesta segunda etapa do MTRS é treinado sobre um conjunto de características transformado dado por $D_i = \{(x^1, y_i^1), \dots, (x^N, y_i^N)\}$ onde $x^l = \{(x_1^l, \dots, x_N^l, y_1^l, \dots, y_N^l)\}$, ou seja com x composto dos valores anteriores acrescidos das previsões de primeira instância do primeiro modelo.

Já a terceira abordagem, baseada no método de *Classifier Chains* introduzido por [Read et al. 2011], dá-se pelo encadeamento de modelos ST através de uma permutação das variáveis-alvo de forma a construir um para cada valor desejado.

Assumindo que a cadeia padrão $C = \{Y_1, Y_2, \dots, Y_N\}$ (onde C é dado por um grupo ordenado) é selecionado, o primeiro modelo diz respeito a previsão de Y_1 tem a forma $h_1 : X \rightarrow R$ e é o mesmo modelo *Single-Target* para esta variável. A diferença em *Regressor Chains* é que os modelos subsequentes $h_j, j > 1$ são treinados sobre conjuntos de dados transformados $D_j = \{(x_j^1, y_j^1), \dots, (x_j^N, y_j^N)\}$ onde $x_j^i = (x_1^i, \dots, x_N^i, y_1^i, \dots, y_{j-1}^i)$ são vetores de entrada transformados consistentes do vetor original de entrada dos exemplos de treinamento acrescidos dos valores reais de todos os valores-alvo anteriores da cadeia [Spyromitros-Xioufis et al. 2012].

Entretanto os valores reais que devem ser utilizados nas cadeias não estão disponíveis no momento da predição e portanto o método passa a se basear nos valores estimados pelas funções h_1, \dots, h_{j-1} por meio de validação cruzada, em uma técnica introduzida como *Regressor Chains Corrected* (RCC) por [Spyromitros-Xioufis et al. 2012], sendo este nosso terceiro método.

3.2. Support Vector Regression

Máquinas de Vetores de Suporte (SVMs, do inglês *Support Vector Machines*), como introduzida por [Vapnik 1998], é um método de aprendizagem supervisionada utilizada para estimar uma função capaz de classificar dados de entrada entre duas classes a partir de um espaço de características de alto valor dimensional, e vêm recebendo crescente atenção da comunidade de Aprendizado de Máquina nos últimos anos, apresentando grande capacidade de generalização e robustez diante de volumes extensos de dados.

As SVMs foram originalmente desenvolvidas para resolver problemas de classificação, isto é, definir através de uma função se um objeto com características x pertencem a uma classe A ou a uma classe B ($-1, +1$), mas [Vapnik et al. 1997] ampliou o método de forma que este viesse a resolver, também, problemas de regressão.

O algoritmo de SVR é uma adaptação da SVC, aplicando-se uma função de perda e permitindo o seu uso para regressão. Esta função pode ser Quadrática, Laplace, Huber, ϵ -insensível e ϵ -quadrática, com as três primeiras não produzindo vetores dispersos o que fez com que [Vapnik et al. 1997] propusesse as funções ϵ -insensíveis.

O objetivo do SVR é encontrar uma função $f(x)$ que retorne o maior valor de desvio ϵ relacionado aos valores-alvo. Isto é, busca uma função capaz de produzir uma margem de erro $y_i - \epsilon, y_i + \epsilon$, utilizando de variáveis de perda, não-negativas, ξ_i, ξ_i^* de forma a penalizar os dados fora da margem $|f(x) - y_i| \leq \epsilon$. Esta abordagem pode ser descrita por: $|\xi|_\epsilon = 0$, se $|\xi| \leq \epsilon$, e $|\xi|_\epsilon = |\xi| - \epsilon$ se $|\xi| \geq \epsilon$.

A função de regressão é definida por:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (1)$$

onde $K(x, x_i) = \phi(x) \cdot \phi(x_i)$ e α_i, α_i^*, b são soluções da equação

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (2)$$

e

$$y_i - (w \cdot x_i) - b \leq \epsilon + \xi_i(w \cdot x_i) + b - y_i \leq \epsilon + \xi_i^* \xi_i, \quad \xi_i^* \geq 0, \forall i \in 1, \dots, l \quad (3)$$

4. Materiais e Métodos

Esta seção apresenta a base de dados utilizada nos testes dos métodos propostos neste artigo, sua origem e como são utilizados. Descreve-se ainda os procedimentos aplicados na criação dos modelos *multi-output* destinados à indicação automática do plano cirúrgico de estrabismo.

4.1. Base de Dados

Os dados utilizados neste trabalho são oriundos do estudo realizado por [Almeida et al. 2015], tendo sido obtidos em colaboração com uma clínica médica especializada em oftalmologia em São Luís, no Maranhão, através da análise de prontuários de pacientes examinados por um oftalmologista especialista em estrabismo.

A base é formada por dados extraídos de prontuários de 114 pacientes divididos em grupo de treinamento, etapa inicial onde criamos os regressores que farão a estimação dos valores para o plano cirúrgico, e teste, onde é feita uma estimação dos valores utilizando os regressores gerados durante o treinamento.

Os dados (seção 2), fornecidos pelo especialista e pertinentes ao planejamento cirúrgico, consistem das medidas de desvio, dada em dioptrias prismáticas, nas posições primárias (PPO) e secundárias (INFRA, SUPRA, LEVO e DEXTRO), o tipo de desvio, o olho fixador, equivalentes esféricos, versões dos músculos oculares de ambos os olhos (RM, RL, RI, RS, OI e OS) e os resultados do exame de fundoscopia, totalizando 23 características.

Este também fornece dados referentes aos planejamentos cirúrgicos para cada um dos casos. Os dados referentes ao planejamento são dados de recuo e ressecção, dados em milímetros, para os músculos Reto Medial (RM) e Reto Lateral (RL), tanto do olho direito (D) quanto do olho esquerdo (E).

4.2. Método Proposto

As técnicas aqui utilizadas foram: *Single-Target*, *Multi-Target Regressor Stacking* e *Regressor Chains Corrected*. O treinamento dos modelos de regressores foram realizados sobre 75% das instâncias da base, escolhidas aleatoriamente, os testes foram realizados sobre as instâncias restantes.

Os dados passaram por um processo de normalização antes do treinamento dos modelos de forma que os valores fossem reduzidos ao intervalo $[-1, 1]$. O treinamento dos modelos foram realizados na linguagem R, utilizando o pacote `e1071`. Utiliza-se as SVR, descritas na seção 3.2, com o *kernel* de função básica radial (RBF, do inglês *radial basis function*) dado por $k(x, y) = e^{-\gamma \|x-y\|^2}$, como regressor na geração dos modelos.

Durante o treinamento foi necessário estimar os valores de C , γ e ϵ , uma vez que estes não são previamente conhecidos. Para tanto, utiliza-se a validação cruzada *v-fold*, onde inicialmente o conjunto de treinamento é dividido em v subconjuntos de tamanhos iguais e, em seguida, um subconjunto é testado usando o classificador treinado no restante do conjunto $v - 1$. Aqui utilizou-se $v = 10$, um valor comumente utilizado por proporcionar estimativas mais confiáveis [Witten and Frank 2005].

O treinamento do modelo *Single-Target* (ST) consiste em gerar um regressor para cada variável-alvo. Isto é, para cada Y_i com $i \in 1, \dots, d$ treina-se um SVR com os as características X_j , onde $j \in 1, \dots, l$. Este método é o mesmo utilizado por [Almeida et al. 2015] em seu trabalho. Os valores utilizados para os parâmetros C , γ e ϵ do SVR, para os oito valores-alvo, são como dados na tabela 1.

Já no modelo do *Multi-Target Regressor Stacking* (MTRS) o treinamento é realizado em duas etapas: a criação dos modelos iniciais (idêntica ao modelo ST), e, após concatenar os valores obtidos aos valores em X – fazendo com que cada X^k com $k \in 1, \dots, N$

Tabela 1. Valores C , γ e ϵ para o método *Single-Target*

	RcRM		RsRM		RcRL		RsRL	
	D	E	D	E	D	E	D	E
C	64	512	512	128	8	64	8	256
γ	0.02	0.07	0.09	0.01	0.05	0.01	0.06	0.09
ϵ	0	0.01	0.2	0.01	0.13	0.38	0	0.08

contenha também os valores de Y^k –, treinamos os regressores de segundo estágio que resultarão nos modelos finais. Assim temos agora, além das 23 características do primeiro modelo, mais 8, referentes às predições dos modelos iniciais, para compor os modelos finais.

Os modelos MTRS do primeiro estágio foram os mesmos ST obtidos anteriormente. Já para o segundo estágio os valores C , γ e ϵ foram novamente adquiridos, conforme mostra a tabela 2.

Tabela 2. Valores C , γ e ϵ para o método *Multi-Target Regressor Stacking*, utilizados nos modelos de segundo estágio.

	RcRM		RsRM		RcRL		RsRL	
	D	E	D	E	D	E	D	E
C	32	64	64	8	8	4	16	8
γ	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
ϵ	0	0	0.03	0.05	0.04	0.11	0	0

No método *Regressor Chains Corrected* (RCS) treina-se os regressores de forma encadeada obedecendo uma sequência escolhida aleatoriamente. Então para cada regressor h_i , com $i \geq 1$, referente a uma variável-alvo Y_i , treina-se este com os dados X^k , com $k \in 1, \dots, N$, acrescidos de Y_{i-1}^k .

No RCS utiliza-se a sequência, aleatoriamente escolhida, dada por $\{RsRLE, RcRME, RsRME, RsRMD, RsRLD, RcRMD, RcRLD, RcRLE\}$, com os valores C , γ e ϵ dados na tabela 3:

Tabela 3. Valores C , γ e ϵ para o método *Regressor Chains Corrected*.

	RcRM		RsRM		RcRL		RsRL	
	D	E	D	E	D	E	D	E
C	4	128	8	256	8	16	128	128
γ	0.01	0.03	0.02	0.01	0.01	0.01	0.03	0.13
ϵ	0.19	0.05	0.24	0.07	0	0	0.08	0.17

5. Resultados

Esta seção apresenta os resultados obtidos através dos métodos aplicados sobre a base de dados. Os modelos gerados a partir do treinamento com os dados da seção anterior serão aplicados sobre os 25% restantes da base, previamente isolados, e seus desempenhos serão avaliados em comparação com o plano elaborado pelo médico especialista.

Foram utilizadas duas medidas durante a avaliação deste estudo: o Erro Absoluto Médio (EAM) e a Raiz do Erro Quadrático Médio (REQM). A primeira, dada pela Equação 4, calcula a média absoluta da distância entre os valores previstos e os valores reais.

Já o REQM representa o desvio médio padrão do todo a partir da amostra utilizada, e é dado pela Equação 5.

$$EAM = \frac{1}{n} \sum_{i=1}^n |p_i - a_i| \quad (4) \quad REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - a_i)^2} \quad (5)$$

Em ambas as equações n é o número de amostras levadas em consideração na avaliação (em nosso caso, 25% da base), p_i é a predição feita pelo regressor para a i -ésima amostra e a_i é o valor real da amostra estabelecido pelo médico especialista.

Com os modelos treinados, executamos os testes sobre as instâncias de teste obtendo-se, para cada uma, oito valores referentes ao tamanho da operação em milímetros que deve ser executada sobre músculos de ambos os olhos. Assim, calculamos os valores de EAM e REQM para os resultados obtidos em relação aos dados dos planos sugeridos pelo médico especialista. As tabelas 4, 5 e 6 mostram os erros médios para cada procedimento cirúrgico planejado e os erro médio global para todos os procedimentos.

Tabela 4. EAM e REQM (em milímetros) para o método ST.

	Rc RM		Rs RM		Rc RL		Rs RL		Média
	D	E	D	E	D	E	D	E	
EAM (mm)	0.691	0.755	0.935	0.992	0.940	1.116	0.899	0.840	0.896
REQM (mm)	1.024	1.181	1.202	1.291	1.529	1.478	1.417	1.599	1.34

Tabela 5. EAM e REQM (em milímetros) para o método MTRS.

	Rc RM		Rs RM		Rc RL		Rs RL		Média
	D	E	D	E	D	E	D	E	
EAM (mm)	0.661	0.660	0.746	0.887	0.866	0.930	0.876	0.755	0.798
REQM (mm)	1.034	1.078	1.035	1.163	1.445	1.287	1.463	1.570	1.259

Tabela 6. EAM e REQM (em milímetros) para o método RCC.

	Rc RM		Rs RM		Rc RL		Rs RL		Média
	D	E	D	E	D	E	D	E	
EAM (mm)	0.756	0.693	0.905	1.151	0.833	0.822	0.947	0.990	0.887
REQM (mm)	1.062	1.098	1.176	1.459	1.479	1.186	1.487	1.642	1.324

Estas medidas mostram erros médios, em milímetros, de cada operação sobre cada músculo de ambos olhos. Os melhores valores de ambos EAM e REQM são dados pelo método MTRS, assim como os menos satisfatórios são dados pelo método ST.

O método ST adquiriu uma performance que registrou EAM global de 0.896 mm e REQM global de 1.34 mm. Pode-se verificar que mesmo este tendo médias globais inferiores, apresenta estatísticas melhores em certas operações (i.e. RcRMD supera os valores EAM em RCC e em REQM supera ambos RC e RCC, o mesmo sendo válido para RsRLD).

Dentre os resultados apresentados pelos modelos, é possível observar que o método *Multi-Target Regressor Stacking*, com um EAM de 0.798 mm e REQM de 1.259 mm,

foi o que apresentou resultados mais satisfatórios quando comparado ao plano cirúrgico sugerido por um médico especialista.

Apesar de ter apresentado os melhores resultados globais, EAM de 0.798 mm e REQM de 1.259 mm, o método RS tem sua performance subjugada pelos métodos ST e RCC em algumas medidas (i.e. EAM de ambos RcRL do método RCC, e REQM da operação RsRLD do método ST).

Apesar do erro global está próximo de 1 mm, em alguns casos o método apresentou resultados com diferença superior a 2 mm sugerindo plano cirúrgico divergente do especialista. Tais divergências apontam a necessidade de aquisição de planos cirúrgicos realizados por vários especialistas para ampliar da base de treino.

Os erros próximos a 1 mm podem ser consideradas pequenos, uma vez que há divergências mesmo entre opiniões de profissionais quanto aos valores das correções aplicáveis nas operações. Bem como existem, também, erros humanos relacionados à precisão durante as cirurgias que podem chegar a 1.7 milímetros, de acordo com [Schutte et al. 2008].

6. Conclusão

Este trabalho apresenta a viabilidade do uso de técnicas de regressão e aprendizado de máquina no planejamento de cirurgias de correção de estrabismo, provendo estimativas baseadas em dados médicos já existentes. As contribuições deste trabalho está na utilização de modelos de múltiplas saídas que buscam aproveitar os relacionamentos entre os valores-alvo do planejamento. Estes métodos, em conjunto com as SVR, resultaram em modelos preditivos capazes de estimar valores para as operações de recuo e ressecção referentes aos músculos horizontais em ambos os olhos, formando assim um plano cirúrgico dado por oito valores-alvo.

A metodologia proposta consistiu na montagem dos planos através dos três métodos apresentados neste trabalho. Os resultados obtidos com cada método foram comparados com os planos sugeridos por um médico especialista, que também forneceu os dados utilizados no treinamento dos modelos.

Além deste método apresentamos também os métodos *Single-Target* e *Regressor Chains Corrected*, tendo o segundo obtido resultados próximos aos do MTRS. A diferença entre RCC e MTRS é inferior a 0.1 mm em ambos EAM e REQM, possivelmente devido a ordem da cadeia utilizada.

Os resultados obtidos estão próximos aos apresentados em [Almeida et al. 2015] que obtiveram EAM médio global de 0,98 mm e REQM médio global de 1,6 mm. Indicando a viabilidade da utilização de regressores com múltiplas saídas. Entretanto, para termos uma comparação mais justa necessitamos reproduzir a mesma abordagem de teste utilizada por [Almeida et al. 2015].

Por fim, propomos como futuros trabalhos a utilização de uma base de plano cirúrgico maior, dada não somente por mais instâncias como também contendo planos sugeridos por mais oftalmologistas, de forma a diversificar e dar maior confiabilidade para o método. Sugere-se também a utilização de novas cadeias no método RCC. Também sugere-se a expansão deste método para operações de estrabismo vertical.

7. Agradecimentos

Os autores agradecem à FAPEMA (Processo: UNIVERSAL-01082/16) e ao CNPq, pelo apoio financeiro.

Referências

- Almeida, J. D. S. d., 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.
- Borchani, H., Varando, G., Bielza, C., and Larrañaga, P. (2015). A survey on multi-output regression. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 5(5):216–233.
- Diaz, J. P. and Dias, C. S. (2000). *Strabismus*. Butterworth Heinemann, Woburn, Massachusetts, EUA.
- Mills, M. D., Coats, D. K., Donahue, S. P., and Wheeler, D. T. (2004). Strabismus surgery for adults: a report by the american academy of ophthalmology. *Ophthalmology*, 111(6):1255–1262.
- NOEL, L., BLOOM, J., CLARKE, W., and BAWAZEER, A. (1997). Retinal perforation in strabismus surgery. *Journal of pediatric ophthalmology and strabismus*, 34(2):115–117.
- Noorden, G. V. and Campos, E. (2001). *Binocular vision and ocular motility: theory and management of strabismus*. Mosby Inc.
- Queiroz, F. C. M. (2010). Análise de componentes principais na meta-análise para obtenção de equações de predição de valores energéticos de alimentos para aves. Master's thesis, Universidade Federal de Lavras.
- Read, J., Pfahringer, B., Holmes, G., and Frank, E. (2011). Classifier chains for multi-label classification. *Machine learning*, 85(3):333.
- Schutte, S., Polling, J. R., van der Helm, F. C. T., and Simonsz, H. J. (2008). Human error in strabismus surgery: quantification with a sensitivity analysis. *Graefe's Archive for Clinical and Experimental Ophthalmology*, 247(3):399.
- Spyromitros-Xioufis, E., Tsoumakas, G., Groves, W., and Vlahavas, I. (2012). Multi-label classification methods for multi-target regression. *arXiv preprint arXiv:1211.6581*.
- Vapnik, V. (1998). *Statistical learning theory*. 1998, volume 3. Wiley, New York.
- Vapnik, V., Golowich, S. E., Smola, A., et al. (1997). Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, pages 281–287.
- Witten, I. and Frank, E. (2005). Data mining: practical machine learning tools and techniques. *Morgan Kaufmann, San Francisco, USA*.
- Ziaei, H., Katibeh, M., Mohammadi, S., Mirzaei, M., Moein, H.-R., Kheiri, B., Taghad-dos, S., and Rajavi, Z. (2016). The impact of congenital strabismus surgery on quality of life in children. *Journal of Ophthalmic & Vision Research*, 11(2):188.