

Thalles Alencar Silva

**Planejamento Cirúrgico de Estrabismo
Utilizando Regressores de Múltiplas Saídas**

São Luís - MA

2019

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Alencar Silva, Thalles.

Planejamento Cirúrgico de Estrabismo Utilizando Regressores de Múltiplas Saídas / Thalles Alencar Silva. - 2019.

41 f.

Orientador(a): João Dallyson Sousa de Almeida.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, Universidade Federal do Maranhão, São Luís - MA, 2019.

1. Estrabismo. 2. Planejamento Cirúrgico. 3. Regressão. 4. Regressão Multi-output. 5. SVR. I. Sousa de Almeida, João Dallyson. II. Título.

Thalles Alencar Silva

Planejamento Cirúrgico de Estrabismo Utilizando Regressores de Múltiplas Saídas

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. João Dallyson Sousa de Almeida

São Luís - MA

2019

Thalles Alencar Silva

Planejamento Cirúrgico de Estrabismo Utilizando Regressores de Múltiplas Saídas

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Data de aprovação: 11/01/2019



Prof. Dr. João Dallyson Sousa de
Almeida
Orientador
Universidade Federal do Maranhão



Simara Vieira da Rocha
Examinador
Universidade Federal do Maranhão



Caio Eduardo Falcão Matos
Examinador
Universidade Federal do Maranhão

São Luís - MA

2019

À minha sanidade e a todos que se importam.

Agradecimentos

Primeiramente ao professor João Dallyson, por basicamente ter me salvado – mesmo sem saber. Sinto muito pelos meus erros. Muito obrigado por não ter desistido, de verdade.

Aos meus pais, pela paciência e suporte durante todos estes anos. Sem vocês eu jamais teria chegado a lugar nenhum.

Aos meus melhores amigos, Alexandre e Gabriel. Vocês são mais importantes do que pensam. Sinto muito que eu precise de espaço com tanta frequência. E, seguindo nesta linha, à Bab por ter sido uma amiga sensacional.

Agradeço aos amigos do 2012.2 que, por mais que nossa amizade seja distante, vocês me acompanharam e me deram força desde o começo.

Àqueles que vieram e se foram. Idas e vindas contam histórias. Vocês foram parte da minha. Adeus.

Por fim à minha namorada, Hannah. Ela já passou cada uma comigo que vai entender como ainda gosta de mim... Obrigado, moça.

Também a todos os professores com quem tive contato estes anos. Vocês merecem todo o reconhecimento do mundo.

Fui intimado a agradecer à banca, então aqui vai: obrigado professor Caio e Professora Simara! Piadas à parte, vocês realmente me ajudaram a conseguir um milagre, hoje. Obrigado!

"It gets easier. Every day it gets a little easier. But you gotta do it every day – that's the hard part. But it does get easier."

(Jogging Baboon, Bojack Horseman)

Resumo

O estrabismo é uma patologia oftalmológica que afeta cerca de 4% da população e pode causar danos sensoriais irreversíveis à visão. Existem diversas técnicas aplicáveis na correção do estrabismo capazes de restabelecer o equilíbrio muscular. Entretanto, quando o tratamento médico não é suficiente, aplica-se o procedimento cirúrgico onde realiza-se o retrocesso ou ressecção dos músculos oculares debilitados. O planejamento deste procedimento é complexo e exige conhecimento científico teórico bem como a experiência por parte do médico especialista responsável. Assim, este trabalho investiga a utilização de regressores com múltiplas saídas com o objetivo de automatizar o planejamento destas cirurgias. O método proposto está organizado em quatro etapas: (1) aquisição de base dados de prontuários de pacientes já submetidos a procedimento cirúrgico; (2) preparação dos dados; (3) aplicação e otimização das técnicas MO; (4) geração dos modelos que criarão o plano cirúrgico. Dentre as técnicas aplicadas a técnica Multi-target Regressor Stacking com o SVM mostrou-se a mais consistente, apresentando média dos Erros Quadrático Médios de 0.46 milímetros e Raiz do Erro Quadrático Médio de 0.506 milímetros na indicação do plano cirúrgico de estrabismo horizontal. Assim, este trabalho apresenta avanços no contexto de planejamento cirúrgico automático.

Palavras-chaves: Estrabismo, Planejamento Cirúrgico, Regressão, Regressão Multi-output, SVR, Árvores de Regressão.

Abstract

Strabismus is an ophthalmological pathology that affects nearly 4% of the population and can cause irreversible sensorial damage to vision. There are various techniques that can be applied at strabismus correction that are capable of reestablishing the muscle balance. However, when medical treatment isn't enough, the surgical procedure is applied where retreating or resecting of the debilitated muscle is done. The planning of this procedure is complex and requires theoretical scientific knowledge as well as long time experience from the physician in charge. Thus, this work investigates the utilization of regressors with multiple outputs with the intent of automate the planning of these surgeries. The proposed method is organized in four steps: (1) acquisition of the dataset of patients who were already submitted to the procedure; (2) data pre-processing; (3) application of the MO techniques; (4) generate the models that will be creating the surgical planning. Amongst the applied techniques the Multi-target Regressor Stacking alongside SVR has shown itself as the most consistent, presenting average of the Mean Squared Error of 0.46 millimeters and Root Mean Squared Error of 0.506 millimeters on the indication of surgical planning for horizontal strabismus. As such, this work presents advance in the context of automatic surgical planning.

Keywords: Strabismus, Surgical Planning, Regression, Multi-output Regression, SVR, Regression Trees.

Lista de ilustrações

Figura 1 – Músculos oculares extrínsecos.	18
Figura 2 – Tipos de estrabismo. (a) Esotropia (ET), (b) Exotropia (XT), (c) Hipotropia (HoT) e (d) Hipertropia (HT).	19
Figura 3 – Arquitetura da criação do modelo <i>Single-target</i>	23
Figura 4 – Arquitetura da criação do modelo <i>Multi-target Regressor Stacking</i>	24
Figura 5 – Função de perda ϵ -insensível.	26
Figura 6 – Exemplo de árvores de classificação.	27
Figura 7 – Arquitetura da metodologia apresentada.	29

Lista de tabelas

Tabela 1 – Parâmetros C, γ e ϵ otimizados do método <i>Single-target</i> com SVM.	33
Tabela 2 – Parâmetros C, γ e ϵ otimizados do método <i>Multi-target Regressor Stacking</i> com SVM.	33
Tabela 3 – Parâmetros Fold e Minsplit otimizados do método <i>Single-target</i> com Árvores de Regressão.	34
Tabela 4 – Parâmetros Fold e Minsplit otimizados do método <i>Multi-target Regressor Stacking</i> com Árvores de Regressão.	34
Tabela 5 – Erro Quadrático Médio dos regressores dos métodos apresentados.	34
Tabela 6 – Raiz do Erro Quadrático Médio dos regressores dos métodos apresentados.	35
Tabela 7 – Valores comparativos dos resultados do trabalho relacionado com o modelo proposto, MTRS-SVR.	36

Lista de abreviaturas e siglas

AV	Acuidade Visual
AR	Árvores de Regressão
D	Direiro
E	Esquerdo
EqE	Equivalente Esférico
ET	Esotropia
FB	Fixação Binocular
HoT	Hipotropia
HT	Hipertropia
MT	Multi-Target
MTRS	Multi-Target Regressor Stacking
OI	Oblíquo Inferior
OS	Oblíquo Superior
RC	Recuo
RI	Reto Inferior
RL	Reto Lateral
RM	Reto Medial
RS	Regressor Stacking
RS	Ressecção
RS	Reto Superior
ST	Single Target
SVR	Support Vector Regression
XT	Exotropia

Lista de símbolos

Σ	letra grega maíuscula sigma
λ	letra grega minúscula lambda
β	letra grega minúscula beta
γ	letra grega minúscula gamma
ϵ	letra grega minúscula epsilon

Sumário

1	INTRODUÇÃO	14
1.1	Trabalhos Relacionados	14
1.2	Objetivos	15
1.2.1	Objetivos específicos	15
1.3	Organização do trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	O Olho	17
2.2	O Estrabismo	18
2.3	Planejamento Cirúrgico	19
2.4	Regressão	21
2.5	Regressão Multi-target	21
2.5.1	Métodos de Transformada de Problema	22
2.5.2	Métodos de Transformada de Algoritmo	24
2.6	Máquina de Vetores de Suporte Para Regressão	25
2.7	Árvores de Regressão	26
3	MATERIAIS E MÉTODOS	29
3.1	Base de Dados	29
3.2	Ferramentas	30
3.3	Metodologia Proposta	30
3.3.1	Pré-processamento	31
3.3.2	Treinamento dos Modelos	31
4	RESULTADOS	33
4.1	Comparação de resultados	35
5	CONCLUSÃO	37
	REFERÊNCIAS	38

1 Introdução

O estrabismo é um problema oftalmológico que afeta negativamente a qualidade de vida através de disfunção visual e aparência anormal (ARCHER et al., 2005; HATT et al., 2007), podendo ser identificado pela perda do paralelismo entre os olhos. O estrabismo afeta entre 2% e 4% da população e pode resultar em ambliopia, disfunção visual caracterizada pela falta de cooperação entre olho e cérebro que prejudica a visão, que comumente não é descoberto a tempo de se iniciar tratamento efetivo (EC, 2007).

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. 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; CAMPOS, 2001; DIAZ; DIAS, 2000). Entretanto estes valores são meramente estimativas, tornando esta tarefa majoritariamente um trabalho dependente da experiência do especialista.

Por conta disso, esta é uma atividade custosa, demorada e consideravelmente subjetiva, de forma que diferentes especialistas podem fornecer planos e realizar correções distintas. No intuito de acelerar o processo, reduzir os custos e diminuir a subjetividade, a utilização de métodos automáticos para efetuar estes procedimentos é desejável.

A aplicação de abordagens automáticas podem reduzir a carga de trabalho dos oftalmologistas, além de oferecer uma segunda opinião para diagnósticos efetuados, como uma sugestão rápida e imparcial. Além disso, após validado, o método poderia vir a ser incorporado em ferramentas de treinamento de médicos residentes, visto que o aperfeiçoamento do conhecimento aplicável neste planejamento advém de anos de pesquisa e prática médica e o fornecimento de sugestões de planos aplicáveis, quando validados, viriam a agilizar o processo de formação destes novos médicos.

Assim neste trabalho será proposto a utilização de regressores *multi-output* (MO), ou seja, de múltiplas saídas, ao problema do planejamento cirúrgico da correção de Estrabismo, no intuito de aproveitar estes potenciais relacionamentos entre valores-alvo de forma a melhorar os resultados já existentes e oferecer planos cirúrgicos mais próximos de valores aplicáveis na realidade.

1.1 Trabalhos Relacionados

Trabalhos que buscam uma solução computacional ao problema apresentado são escassos, sendo a única instância encontrada o trabalho de (ALMEIDA et al., 2015) que

propõe o uso de regressores de múltiplas saídas aplicada de forma a gerar um regressor para cada valor alvo, método este que no decorrer do trabalho será apresentado como Método *Single-target*.

Esta técnica trata os valores-alvo como valores independentes e por consequência, em situações onde os valores são interdependentes entre sí, isto torna-se um empecilho aos resultados pretendidos, visto que o relacionamentos entre eles jamais é explorado.

Diversos trabalhos, entretanto, utilizam regressores de múltiplas saídas. Esta técnica tem se popularizado nos últimos anos. Um destes é (TUJA et al., 2011), que faz uso de SVR *Multi-output* para estimação de parâmetros biofísicos obtidos por sensoriamento remoto; (RUDOVIC; PAVLOVIC; PANTIC, 2012), que utiliza Regressão logística no reconhecimento de expressões faciais; (ZHEN et al., 2015) que utiliza *Random Forest* para estimar fluxo cardíaco; e (CUI et al., 2018) que fez um comparativo de diversas técnicas *multi-output* à técnicas de regressão *single-target* na tentativa de otimizar controle de orçamento direcionado à área da saúde.

1.2 Objetivos

Diante do contexto apresentado o objetivo deste trabalho consiste da pesquisa de técnicas de regressão com múltiplas saídas e desenvolver sua aplicabilidade na indicação automática um possível plano cirúrgico para correção do estrabismo em pacientes que necessitam de intervenção cirúrgica. Como suporte a esta tarefa será necessário trabalhar com diversas técnicas de aprendizado de máquina supervisionadas, visto que será necessário "aprender" planos cirúrgicos já existentes de forma a basear novas predições, além de métricas estatísticas que permitam a avaliação dos resultados obtidos.

1.2.1 Objetivos específicos

Para alcançar o objetivo geral pretendido, foram desenvolvidos os seguintes objetivos específicos:

- Buscar compreender e implementar técnicas de aprendizagem de máquina supervisionadas que viabilizem o aspecto multi-output que o problema apresenta;
- Análise da aplicabilidade dos algoritmos propostos;
- Propor uma metodologia para a geração destes modelos multi-output;
- Testar e avaliar a metodologia desenvolvida, e compará-la a trabalhos similares;
- Analisar as vantagens e limitações da metodologia proposta.

1.3 Organização do trabalho

O restante deste trabalho está disposto em mais 4 capítulos. O Capítulo 2 apresentará informações pertinentes ao desenvolvimento deste trabalho; o Capítulo 3 estará focado nos processos utilizados no desenvolvimento dos modelos de regressores.

Já os capítulos subsequentes focarão nas considerações sobre o método proposto, estando o Capítulo 4 abordando os resultados obtidos, bem como fazendo uma comparação com trabalho existente na área, enquanto que, por fim, o Capítulo 5 conclui este trabalho com observações e considerações finais, que incluem formas de possivelmente expandir o trabalho aqui apresentado.

2 Fundamentação teórica

Este capítulo foca na apresentação das idéias e conceitos utilizados no intuito de atingir os objetivos apresentados. Aqui serão abordados tópicos relacionados à anatomia ocular, o estrabismo o planejamento cirúrgico para sua correção e os métodos computacionais que serão aplicados para a geração dos modelos, como regressão (ambas com uma e com várias saídas), Máquina de Vetores de Suporte para Regressão e Árvores de Regressão.

2.1 O Olho

Os olhos são órgãos fotossensíveis complexos que atingiram alto grau de evolução, permitindo uma análise minuciosa quanto à forma dos objetos, cor e a intensidade de luz refletida. Cada olho fica dentro de uma caixa óssea protetora – a órbita – e apresenta basicamente uma câmara escura, uma camada de células receptoras sensoriais, um sistema de lentes para focalizar a imagem e um sistema de células e nervos para conduzir o estímulo ao córtex cerebral (JUNQUEIRA; CARNEIRO, 1995).

O olho é uma estrutura que fica suspensa na órbita, preso apenas pelos ligamentos cantais lateral e medial à parede da órbita, pelo nervo óptico e pelos músculos oculares extrínsecos. Isto lhe confere grande mobilidade em diversas direções e sentidos.

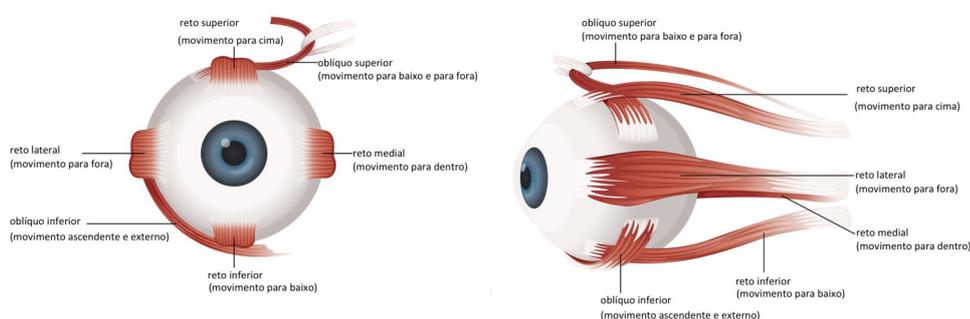
Os músculos oculares extrínsecos são responsáveis pela iniciação, coordenação e conclusão dos movimentos oculares. Em condições normais trabalham de forma coordenada, permitindo a visão binocular e a noção de profundidade (estereopsia), uma vez que o cérebro interpreta as imagens recebidas por ambos os olhos de maneira conjunta.

Existem dois conjuntos de músculos responsáveis pela movimentação dos olhos: retos e oblíquos. Os músculos retos nascem da parte posterior da órbita e dirigem-se para a anterior. São eles os retos horizontais (medial e lateral) e verticais (superior e inferior). Os oblíquos têm sua origem na porção anterior e medial da órbita (próximo ao nariz) e dirigem-se, de forma oblíqua, no sentido medial para lateral e anterior para posterior, até a metade posterior de cada globo ocular, sendo eles os oblíquos superior e inferior.

Em cada olho há um conjunto destes seis músculos, trabalhando em harmonia para promover movimentação adequada dos globos oculares. Os músculos reto medial (RM) e reto lateral (RL) movem o olho para horizontalmente, enquanto que os músculos reto inferior (RI) e reto superior (RS) movem o olho verticalmente. Os músculos oblíquos, inferior (OI) e superior (OS), por sua vez, controlam os movimentos de inclinação/torção. Quando estes músculos não funcionam em conjunto há um desalinhamento, o estrabismo.

Uma representação destes músculos pode ser observada na Figura 1.

Figura 1 – Músculos oculares extrínsecos.



Fonte: (VISU, 2018)

2.2 O Estrabismo

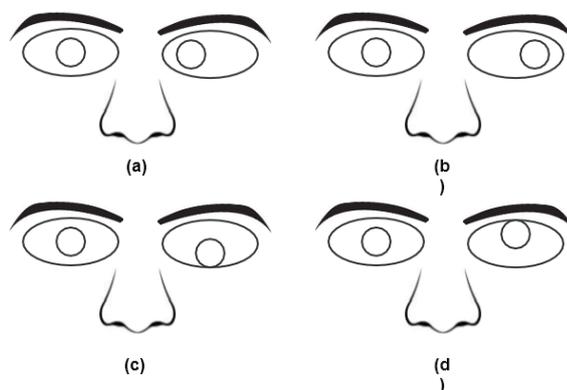
O estrabismo consiste em qualquer desvio do alinhamento binocular, ou seja, ocorre quando as fóveas¹ não estão simétricas em relação ao objeto que é focalizado pelo olhar (SPALTON; HITCHINGS; HUNTER, 2006; SHIMAUTI et al., 2012). Em outros termos, define-se o estrabismo como um distúrbio da relação posicional entre os olhos onde um dos olhos (chamado olho fixador) da pessoa portadora concentra-se em um objeto enquanto o outro volta-se em outra direção, podendo ser constante, que, como o nome indica, mantém-se a todo momento, ou intermitente, que pode, por vez, parecer normal e, em outras, anormal.

A classificação dá-se de acordo com a direção do desvio em relação ao objeto de fixação, categorizando os esodesvios (ET), quando os eixos visuais estão convergentes em relação ao objeto ou ponto de fixação; exodesvio (XT) quando divergem em relação ao objeto ou ponto de fixação; hiperdesvios quando os eixos estão desviados no sentido vertical e, se mais baixo, hipotropia (HoT); e hipertropia (HT), quando mais alto em relação ao objeto de fixação (SPALTON; HITCHINGS; HUNTER, 2006; SHIMAUTI et al., 2012). A Figura 2 apresenta estes desvios.

O estrabismo é causado pelo desequilíbrio dos músculos oculares ou desalinhamento dos olhos. Tanto em crianças como adultos isto pode dar-se por distúrbios neurológicos causados por doenças ou acidentes que alteram o funcionamento dos músculos oculares. Nas crianças pode estar presente no nascimento ou apresentar-se logo após, devido a problemas de visão não tratados no período de alta plasticidade sensorial da pessoa, que vai até os sete anos de idade (ALMEIDA et al., 2015).

¹ Região de concentração de células cónicas onde a visão é mais nítida (JUNQUEIRA; CARNEIRO, 1995).

Figura 2 – Tipos de estrabismo. **(a)** Esotropia (ET), **(b)** Exotropia (XT), **(c)** Hipotropia (HoT) e **(d)** Hipertropia (HT).



2.3 Planejamento Cirúrgico

A grande maioria dos casos de estrabismo exigem tratamento cirúrgicos afim de corrigir a ação dos músculos sobre o/os olhos. A cirurgia tem o objetivo de restabelecer a ação normal dos músculos oculares, promovendo a restauração das funções normais do olho melhorando a qualidade de vida em diversos aspectos (i.e.: restaura visão binocular, elimina a diplopia, expande o campo de visão binocular, corrige a compensação da postura da cabeça ou simplesmente melhorar a aparência cosmética do paciente).

Existem basicamente dois tipos de procedimentos cirúrgicos: cirurgias de enfraquecimento dos músculos por meio da diminuição do torque muscular, que pode se 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 (cortes) do comprimento do músculo, reposicionamento anterior da inserção e pregueamento do tendão muscular.

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. 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; CAMPOS, 2001; DIAZ; DIAS, 2000).

Estas tabelas apresentam como desvantagem o fato de fornecerem valores médios, que muitas vezes não podem ser aplicados individualmente, já sendo bem estabelecida a grande variabilidade da correção cirúrgica obtida em termos de dioptrias prismáticas por milímetro de recuo e/ou ressecção (DIAZ; DIAS, 2000).

No momento da decisão pela operação (ou não) de um certo músculo ocular, são

levados em consideração 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 ambos;
- 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):** Relevante ao se determinar em qual(is) olhos a operação deve se concentrar. Se o paciente apresentar boa visão, então a operação deve ser dividida entre ambos os olhos;
- **Exame de refração:** Este mede a adequação óptica da retina em relação ao comprimento axial do olho, fornecendo a melhor acuidade visual corrigida para cada paciente. 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. As alterações mais comuns na fundoscopia incluem retinopatia diabética, oclusões vasculares e retinopatia hipertensiva;
- Medida do desvio nas posições primária e secundária do olhar;
- Medida das versões, que 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).

Em (CURTIS; MCCLATCHEY; WHEELER, 2010) foi realizado um estudo epidemiológico da cirurgia do estrabismo na Arábia Saudita, entre os anos de 1982 e 1996,

com 4886 pacientes no hospital na cidade de Riyadh. Constataram que 96,2% dos pacientes apresentavam desvios horizontais, sendo 69,3% do tipo esotropia e 26,9% exotropia. Sendo assim, estuda-se neste trabalho o plano cirúrgico para os desvios horizontais por serem os de maior prevalência, nestes sendo necessário interferência apenas com os músculos Reto Medial (RM) e Reto Lateral (RL).

2.4 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).

Assim, considere um conjunto de dados para aprendizagem D , com N instâncias dadas na forma $D = \{(X^{(1)}, Y^{(1)}), \dots, (X^{(l)}, Y^{(l)}), \dots, (X^{(N)}, Y^{(N)})\}$ onde cada instância é caracterizada por um vetor de *inputs* $X^{(l)} = (x_1^{(l)}, \dots, x_i^{(l)}, \dots, x_p^{(l)})$ e uma variável alvo $y^{(l)}$.

$$D : \begin{bmatrix} x_1^{(1)} + \dots + x_i^{(1)} + \dots + x_p^{(1)} = y^{(1)} \\ \dots \\ x_1^{(l)} + \dots + x_i^{(l)} + \dots + x_p^{(l)} = y^{(l)} \\ \dots \\ x_1^{(N)} + \dots + x_i^{(N)} + \dots + x_p^{(N)} = y^{(N)} \end{bmatrix}$$

O objetivo da análise de regressão é obter uma função f capaz de aproximar o valor de Y a partir de um vetor de *inputs* X , equação 2.1.

$$f : \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p = y \quad (2.1)$$

onde cada β_i é uma constante numérica que multiplica o valor x_i a fim de resultar em y .

2.5 Regressão Multi-target

Por vezes, entretanto, o problema a ser resolvido possui mais de uma variável em Y , isto é mais de um valor-alvo para um dado vetor de características X . Assim define-se regressão com múltiplas saídas, também conhecida por *multi-output*, *multi-target*, *multi-variate* e *multi-response*, que busca prever simultaneamente múltiplos valores-alvo.

Considere um grupo de dados de treinamento D com N instâncias contendo um valor determinado para cada variável x_1, x_2, \dots, x_p , y_1, y_2, \dots, y_q , i.e., $D = \{(X^{(1)}, Y^{(1)}), \dots, (X^{(l)}, Y^{(l)}), \dots, (X^{(N)}, Y^{(N)})\}$. Cada instância é caracterizada por um vetor de *inputs* com p variáveis descritivas, ou preditivas, $X^{(l)} = (x_1^{(l)}, \dots, x_i^{(l)}, \dots, x_p^{(l)})$ e um vetor de saída

com q variáveis-alvo $Y^{(l)} = (y_1^{(l)}, \dots, y_j^{(l)}, \dots, y_q^{(l)})$, com $i \in \{1, \dots, p\}$, $j \in \{1, \dots, q\}$, e $l \in \{1, \dots, N\}$ (BORCHANI et al., 2015)

$$D : \begin{bmatrix} x_1^{(1)} + \dots + x_i^{(1)} + \dots + x_p^{(1)} = (y_1^{(1)}, \dots, y_j^{(1)}, \dots, y_q^{(1)}) \\ \dots \\ x_1^{(l)} + \dots + x_i^{(l)} + \dots + x_p^{(l)} = (y_1^{(l)}, \dots, y_j^{(l)}, \dots, y_q^{(l)}) \\ \dots \\ x_1^{(N)} + \dots + x_i^{(N)} + \dots + x_p^{(N)} = (y_1^{(N)}, \dots, y_j^{(N)}, \dots, y_q^{(N)}) \end{bmatrix}$$

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 q valores-alvo (BORCHANI et al., 2015), Equação 2.2:

$$h : \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_i + \dots + \beta_p x_p = (y_1, y_2, \dots, y_j, \dots, y_q) \quad (2.2)$$

onde cada β_i é uma constante numérica que multiplica o valor x_i a fim de resultar em y_j .

Ou seja, a partir dessa base de treinamento D obtém-se uma função h capaz de correlacionar os dados de entrada X em um conjunto de saídas Y , função esta que futuramente será utilizada para prever simultaneamente os valores-alvo (y_1, \dots, y_q) referentes a um novo conjunto (x_1, \dots, x_p) de *inputs*.

Métodos de Transformada de Algoritmos e de Transformada de Problemas são os dois grupos nos quais podem ser divididos os algoritmos de regressão *multi-output*. Como os nomes sugerem, o primeiro grupo de algoritmos busca uma nova forma de aproximar-se do problema enquanto que o segundo busca adaptar os algoritmos conhecidos de forma a obter os vários outputs simultaneamente, ambas abordagens a serem explanadas a seguir.

2.5.1 Métodos de Transformada de Problema

Este grupo de soluções baseia-se na ideia de transformar o problema de múltiplas saídas, isto é com q variáveis alvo, em múltiplos (q) 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.

Por se trabalhar o problema em mãos, quaisquer regressores simples (de única variável alvo) podem ser aplicados nestes métodos – sendo vetado o uso de quaisquer outras abordagens *multi-output*, como discutido em (SPYROMITROS-XIOUFIS et al., 2012). O maior problema destes métodos é que o relacionamento entre os valores-alvo são ignorados, e estes são estimados independentemente o que pode afetar o desempenho médio dos regressores (BORCHANI et al., 2015).

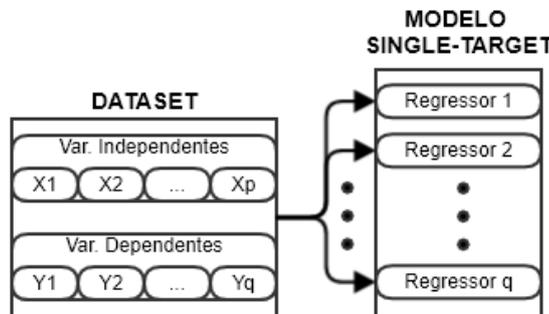
O primeiro, e mais simples, destes métodos é o método **Single-target** (ST). Sua abordagem é definida pela geração de q modelos de regressores com única saída – uma para cada valor-alvo – a partir de uma versão levemente alterada da base de treinamento D .

Cada função h_j é dada pelo treinamento de um regressor a partir da base modificada $D_j = \{(X^1, Y_j^1), \dots, (x^N, Y_j^N)\}$, $j \in \{1, \dots, q\}$, e cada um destes resulta em um único valor y_j (SPYROMITROS-XIOUFIS et al., 2012; BORCHANI et al., 2015), equação 2.3.

$$\begin{aligned}
 h_1 : \quad & \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_i + \dots + \beta_p x_p = y_1 \\
 & \dots \\
 h_j : \quad & \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_i + \dots + \beta_p x_p = y_j \\
 & \dots \\
 h_q : \quad & \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_i + \dots + \beta_p x_p = y_q \\
 & Y = (y_1, \dots, y_j, \dots, y_q)
 \end{aligned} \tag{2.3}$$

onde cada β_i é uma constante numérica que multiplica o valor x_i a fim de resultar em y_j . Na Figura 3 é possível observar como este método funciona:

Figura 3 – Arquitetura da criação do modelo *Single-target*.



Em (GODBOLE; SARAWAGI, 2004) é descrita a abordagem de generalização empilhada (*stacked generalization*) como método aplicável no contexto de problemas de classificação com múltiplas variáveis-alvo (*multi-label classification*).

Esta funciona com a expansão do espaço de entrada original de cada elemento de treinamento com q variáveis binárias adicionais, correspondendo às predições de d classificadores, um para cada saída, para aquele exemplo. Este conjunto de treinamento é alimentado à uma segunda camada de classificadores binários que produzirá as decisões finais (SPYROMITROS-XIOUFIS et al., 2012).

A partir deste conceito surge a abordagem **Multi-Target Regressor Stacking** (MTRS), um processo em duas etapas definido por (SPYROMITROS-XIOUFIS et al.,

2012) dado pela geração de modelos ST a partir do conjunto de dados inicial acrescidos das predições do próprio modelo ST.

Assim, 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, q novos metamodelos serão gerados para que se obtenha os valores finais $Y = (y_1, \dots, y_j, \dots, y_q)$.

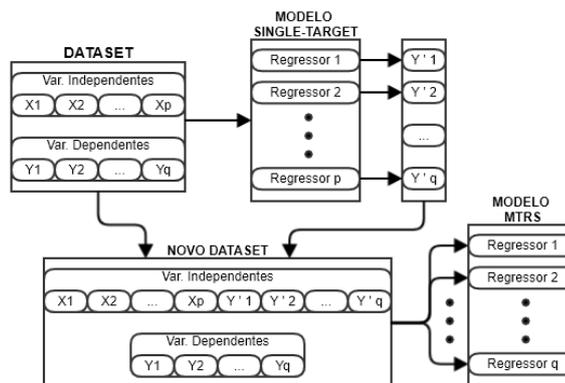
Cada um destes metamodelos gerados nesta segunda etapa do MTRS é treinado sobre um conjunto de características transformado dado por $D_j = \{(X^{(1)}, Y_j^{(1)}), \dots, (X^{(N)}, Y_j^{(N)})\}$ onde $X^{(l)} = \{(x_1^{(l)}, \dots, x_p^{(l)}, y_1^{(l)}, \dots, y_q^{(l)})\}$, ou seja com X composto dos valores anteriores acrescidos das predições adquiridas a partir dos primeiros modelos aplicados sobre a base inicial D .

Assim, os regressores h do modelo MTRS são dados na equação 2.4:

$$\begin{aligned}
 h_1 : \quad & \beta_1 x_1 + \dots + \beta_i x_i + \dots + \beta_p x_p + \beta_{p+1} y'_1 + \dots + \beta_{p+j} y'_j + \dots + \beta_{p+q} y'_q = y_1 \\
 & \dots \\
 h_j : \quad & \beta_1 x_1 + \dots + \beta_i x_i + \dots + \beta_p x_p + \beta_{p+1} y'_1 + \dots + \beta_{p+j} y'_j + \dots + \beta_{p+q} y'_q = y_j \\
 & \dots \\
 h_q : \quad & \beta_1 x_1 + \dots + \beta_i x_i + \dots + \beta_p x_p + \beta_{p+1} y'_1 + \dots + \beta_{p+j} y'_j + \dots + \beta_{p+q} y'_q = y_q \\
 & Y = (y_1, \dots, y_j, \dots, y_q)
 \end{aligned} \tag{2.4}$$

onde cada β_i é uma constante numérica que multiplica o valor x_i a fim de resultar em y_j . Na Figura 3 é possível observar como este método funciona:

Figura 4 – Arquitetura da criação do modelo *Multi-target Regressor Stacking*.



2.5.2 Métodos de Transformada de Algoritmo

Estes métodos são capazes de prever todas as variáveis-alvo a partir de um único modelo. Isto é, é gerado apenas um modelo (função) h capaz de gerar os q valores-alvo em

Y a partir dos dados em X . Estes algoritmos são mais complexos, uma vez que calculam simultaneamente todos os valores, levando em consideração, também, os relacionamentos entre eles.

Isto proporciona vantagens sobre os modelos anteriores, como a simplicidade na interpretação de um único modelo *multi-target* que diversos modelos *single-target* além de garantir a exploração do relacionamento entre as variáveis-alvo.

Esta função h é a própria função dada na equação 2.2, já com todos os valores alvos sendo emitidos simultaneamente por uma única função com q valores distintos contidos no vetor de *outputs*.

2.6 Máquina de Vetores de Suporte Para Regressão

Máquina de Vetores de Suporte (SVMs, do inglês *Support Vector Machine*) 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.

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 (SMOLA; SCHÖLKOPF, 2004) ampliou o método de forma que este viesse a resolver, também, problemas de regressão. Desta forma, existem duas categorias principais de SVM: Classificação por Vetores de Suporte (SVC, do inglês *Support Vector Classification*) e Regressão por Vetores de Suporte (SVR, do inglês *Support Vector Regression*) (BASAK; PAL; PATRANABIS, 2007).

O algoritmo de SVR é uma adaptação da SVC aplicando uma função de perda, o que permite o seu uso para regressão. Esta função de perda pode ser Quadrática, Laplaciana, Huber, ϵ -insensível e ϵ -quadrática, com as três primeiras não produzindo vetores dispersos o que fez com que (VAPNIK et al., 1997) viesse a propor 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 na equação 2.5:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (2.5)$$

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

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

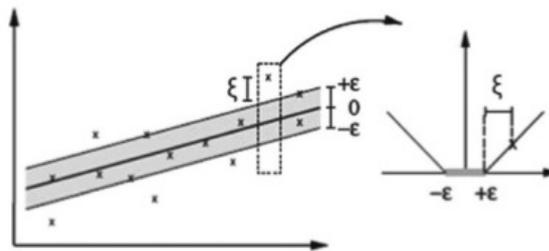
e

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

A Figura 5 representa a equação 2.6. Nesta, os pontos que não pertencem à região sombreada contribuem para o valor da função de custo.

$$\begin{aligned} |\xi|_\epsilon &= 0, & \text{se } |\xi| \leq \epsilon \\ |\xi|_\epsilon &= |\xi| - \epsilon, & \text{caso contrário} \end{aligned} \tag{2.6}$$

Figura 5 – Função de perda ϵ -insensível.



FONTE: (SMOLA; SCHÖLKOPF, 2004)

2.7 Árvores de Regressão

Árvores de Classificação e Regressão (CART, do inglês *Classification and Regression Trees*), também conhecidas como Árvores de Particionamento Recursivo (*Recursive Partitioning Trees*, introduzidas por (LEO et al., 1984), são modelos de regressão não paramétricos que funcionam a partir da construção de árvores binárias que se utilizam de características e limiares capazes de proporcionar a maior redução de impureza a cada nó gerado.

Considere um grupo de dados de treinamento D com N instâncias, da forma $D = \{(X^{(1)}, Y^{(1)}), \dots, (X^{(l)}, Y^{(l)}), \dots, (X^{(N)}, Y^{(N)})\}$ onde $X^{(l)} = (x_1^{(l)}, \dots, x_i^{(l)}, \dots, x_p^{(l)})$ é um vetor de *inputs* com p variáveis descritivas uma variável alvo $y^{(l)}$. O objetivo do modelo CART consiste em encontrar um modelo capaz de prever os valores de Y dado um novo conjunto de valores X .

Árvores de classificação são construídas a partir de uma regra de divisão – responsável pela realização da divisão da amostra em partes menores, de forma que a cada vez que o conjunto for dividido este o será feito entre duas partes com máximo de homogeneidade.

Homogeneidade máxima é definida pela "função de impureza" $i(t)$. Como a impureza do nó pai é constante, é constante para todos as possíveis divisões, a homogeneidade máxima dos nós filhos a direita e à esquerda serão equivalentes à maximização da mudança de impureza da função $\delta i(t)$:

$$\delta i(t) = i(t_p) - E[i(t_c)]$$

onde t_c são os nós filhos (direita e esquerda) do pai (t_p). Assumindo P_l, P_r como as probabilidades da esquerda e direita, respectivamente, temos:

$$\delta i(t) = i(t_p) - P_l i(t_l) - P_r i(t_r)$$

Assim, a cada nó o algoritmo de CART resolve o problema de maximização dado por:

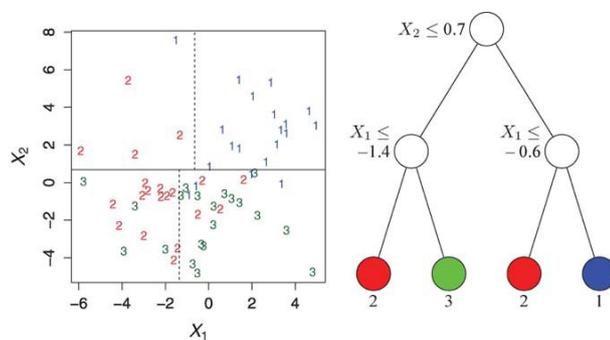
$$\underset{x_j \leq x_j^R, j=1, \dots, M}{\arg \max} [i(t_p) - P_l i(t_l) - P_r i(t_r)] \tag{2.7}$$

A equação 2.7 implica que o algoritmo irá buscar entre todos os possíveis valores e possíveis variáveis da matriz X pelo melhor ponto de divisão $x_j < x_j^R$ que irá maximizar a mudança de impureza $\delta i(t)$.

As funções de impureza, $i(t)$, mais comumente usadas são a *Gini Splitting Rule*, onde o foco é o isolamento da maior classe o que a permite melhor funcionamento com bases de dados ruidosas, e a *Twoing Splitting Rule*, que diferente da primeira vai buscar por duas classes que juntas abrangem mais de 50% dos dados. Em (TIMOFEEV, 2004) este método é discutido em mais detalhes.

Na Figura 6 pode-se observar um exemplo deste particionamento onde três classes y são representadas por dois grupos de variáveis X . O painel à esquerda mostra os valores no espaço e à direita temos a árvore de classificação.

Figura 6 – Exemplo de árvores de classificação.



FONTE: (LOH, 2011)

Já as árvores de regressão, devido aos valores y se tratarem de valores reais e não de classes, as regras de divisão *Gini* e *Twoing* (e demais não citadas anteriormente) não se aplicam.

A divisão nas árvores de regressão são dadas de acordo com o Algoritmo de Minimização dos Resíduos Quadráticos o que implica que a soma das variâncias esperada para dois nós resultantes deve ser minimizada.

$$\arg \min_{x_j \leq x_j^R, j=1, \dots, M} [P_l \text{Var}(Y_l) + P_r \text{Var}(Y_r)] \quad (2.8)$$

onde $\text{Var}(Y_l), \text{Var}(Y_r)$ correspondem aos vetores-resposta para os nós filhos esquerdo e direito, respectivamente; $x_j \leq x_j^R, j=1, \dots, M$ refere-se ao critério de subdivisão que satisfaz a condição apresentada na equação 2.8.

Algoritmo de Minimização dos Resíduos Quadráticos funciona de maneira irêntica à *Gini Splitting Rule*. A função de impureza *Gini* é facilmente traduzida para notação de variância. Se designarmos aos objetos da classe k o valor 1, e 0 aos demais, então a amostra de variância destes valores seriam igual a $p(k|t)[1 - p(k|t)]$. Resumindo por número de classes K , temos a seguinte função de impureza $i(t)$:

$$i(t) = 1 - \sum_{k=1}^K p^2(k|t)$$

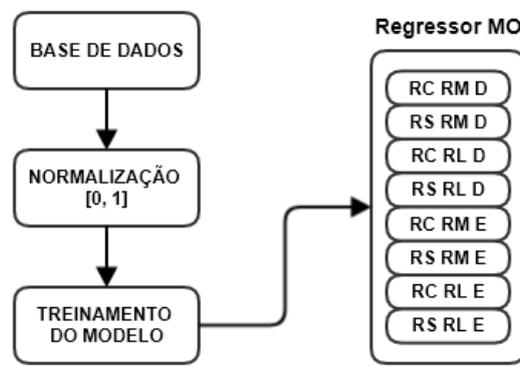
As árvores de regressão se comportam de maneira bastante similar às árvores de classificação, como demonstrado na Figura 6 com a diferença de que, dada a natureza dos valores-alvo, as árvores tendem a ser mais extensas pois cada valor alvo pode vir a ser apresentado em seu próprio nó-folha.

Por fim, ao se estender o modelo CART de forma que este dê suporte aos problemas *multi-output* a função de impureza de um nó deve ser redefinida como a soma dos erros dentre todos os valores-alvo $y_j \in Y$ (DE'ATH, 2002).

3 Materiais e Métodos

Neste capítulo, é apresentada a sequência de etapas adotada para o treinamento e validação dos modelos de regressão escolhidos. A Figura 7 demonstra as etapas adotadas na criação dos modelos de regressores MO aplicados, que se divide em 4: aquisição da base de dados, pré-processamento dos dados (normalização), aplicação e otimização das técnicas MO e criação dos modelos.

Figura 7 – Arquitetura da metodologia apresentada.



Neste capítulo é apresentada, primeiramente, a base planos cirúrgicos de operações já previamente realizadas. Em seguida, fala-se sobre as ferramentas utilizadas para o desenvolvimento da metodologia proposta. Logo após, cada etapa que constitui o método proposto é detalhada.

3.1 Base de Dados

A base de dados utilizada neste trabalho é proveniente do trabalho de (ALMEIDA et al., 2015). Em seu trabalho é relatado que estes dados foram obtidos por meio de estudo retrospectivo realizado em colaboração com uma clínica médica especializada em oftomologia (em São Luís, Maranhão) através da análise de prontuários de pacientes examinados por um médico oftamologista especialista em estrabismo.

A base é constituída de dados de 114 pacientes, com 31 valores por instância sendo 23 referentes às características (X) e os 8 valores restantes os valores-alvo (Y) que definem o plano cirúrgico. As características consistem das medidas de desvio, dada em dioptrias prismáticas, nas posições primárias e secundárias, o tipo de desvio, o olho fixador, equivalentes esféricos, versões dos músculos oculares de ambos os olhos e os resultados do exame de fundoscopia, enquanto que os valores-alvo condizem com a correção, em milímetros, a ser efetuada nos músculos oculares.

Todas as indicações cirúrgicas nesta base foram realizadas pelo mesmo médico especialista e, visto como a metodologia proposta é voltada apenas para o planejamento cirúrgico de desvios horizontais, foram extraídas dos prontuários apenas informações referentes a este problema (conforme Seção 2.3).

3.2 Ferramentas

A linguagem de programação utilizada no desenvolvimento deste trabalho foi R (versão 3.5.1). Foram utilizadas as bibliotecas `e1071` (MEYER et al., 2018), versão 1.7-0, e `rpart` (THERNEAU; ATKINSON, 2018), versão 4.1-13. Estas bibliotecas utilizadas foram responsáveis pelo treinamento dos modelos de regressão utilizados, a primeira sendo responsável pelas SVM enquanto que a segunda pelas Árvores de Regressão.

Além destas, as bibliotecas `Parallel` (CORPORATION; WESTON, 2018), versão 1.0.14, e `foreach` (Microsoft; WESTON, 2017), versão 1.4.4, foram responsáveis pelo treinamento utilizando computação paralela; `hydroGOF` (Mauricio Zambrano-Bigiarini, 2017), versão 0.3-10, foi utilizada na avaliação dos modelos; e, por fim, a biblioteca `caret` (WING et al., 2018), versão 6.0-81, foi utilizada para avaliação bem como manipulação dos dados da base.

O computador onde o método proposto foi implementado e testado possui a seguinte configuração: processador Intel Core i7-3610QM, com oito núcleos; 8GB de memória RAM; sistema operacional Windows 10 de 64 *bits*.

3.3 Metodologia Proposta

Ao se realizar o treinamento dos modelos utilizados no plano cirúrgico o objetivo é gerar um regressor capaz de apontar um valor de recuo (RC) e de ressecção (RS) a cada um dos dois músculos responsáveis pelo desvio horizontal, reto medial (RM) e reto lateral (RL), em ambos os olhos, direito (D) e esquerdo (E). Assim, os *outputs* são oito valores referentes ao:

- recuo 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 do olho esquerdo (RCRME);
- ressecção do músculo reto medial do olho esquerdo (RSRME);

- recuo do músculo reto lateral do olho esquerdo (RCRLE);
- ressecção do músculo reto lateral do olho esquerdo (RSRLE).

O treinamento destes modelos é dado em duas etapas: preparação dos dados e treinamento dos modelos. A Imagem 7 mostra os passos apresentados nesta metodologia, ao passo que as seções 3.3.1 e 3.3.2 estas etapas serão discutidas com maior propriedade, enquanto que em 4 será discutido os resultados obtidos.

3.3.1 Pré-processamento

De maneira bastante direta, a etapa de pré-processamento consiste da seleção das características, já previamente estabelecidas cabendo aqui apenas o isolamento destas de forma a utilizá-las em nosso treinamento, e normalização dos dados.

A normalização foi realizada pela fórmula 3.1

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

de forma que os valores x_i de X fossem delimitados no intervalo $0 \leq x_i \leq 1$.

3.3.2 Treinamento dos Modelos

A segunda etapa, por sua vez, trata-se do treinamento dos modelos, que engloba otimização de parâmetros e subsequente avaliação interna destes para que fosse possível encontrar os parâmetros ótimos para cada método. Neste sentido foi aplicada a validação cruzada k -fold¹ para que se pudesse realizar a otimização dos parâmetros, através de busca em grid², de cada um dos regressores.

Quando lidamos com modelos de múltiplas saídas (i.e. árvores de regressão *multi-target*) a Imagem 7 é capaz de representar de maneira direta a criação deste modelo. Entretanto a etapa de treinamento dos modelos nos métodos ST e MTRS, por se tratarem de métodos de transformada de problema, é consideravelmente mais convoluta e varia entre cada método, como visto em 2.5.1.

Na Figura 3 vimos a arquitetura do modelo ST, um dos modelos de transformada de problema apresentado na seção 2.5.1, e este pode ser descrito pela criação de um modelo para cada valor-alvo. No caso deste trabalho, geramos 8 modelos que, quando aplicados sequencialmente sobre um conjunto de dados X irá proporcionar um plano.

¹ A Validação Cruzada k -fold consiste da divisão do conjunto de treinamento D em k subconjuntos onde $k - 1$ destes são utilizados no treinamento do classificador/regressor e o subconjunto restante é utilizado para teste do modelo gerado.

² Método por força bruta, onde é gerada uma tabela que contém combinações de valores de parâmetros que são testados um a um.

Na Figura 4 vimos os passos realizados no treinamento dos regressores no método MTRS. Neste nos aproveitamos dos modelos do método ST, ao qual alimentamos a base de dados inicial de forma a obter um conjunto de predições que será utilizado junto às características X como um novo conjunto de dados de entrada para geração dos novos modelos, criados de forma similar ao ST.

Como estes problemas consistem meramente de manipulação de dados, quaisquer regressores podem ser utilizados. Aqui foram utilizados o SVR (seção 2.6) e as Árvores de Regressão (seção 2.7), e aplicada validação cruzada na obtenção dos parâmetros ótimos de cada um destes regressores.

Durante o treinamento foram otimizados os parâmetros ϵ , C e γ das SVM, sob a função de *kernel* RBF, dada por $k(x, y) = e^{\gamma\|x-y\|^2}$. As árvores de regressão não dependem de constantes otimizáveis, mas internamente esta realiza uma validação cruzada ao buscar otimizar a heterogeneidade dos nós, assim testamos diferentes valores de k nessa validação cruzada interna.

Com isto, um total de 4 métodos diferentes são comparados neste trabalho, sendo eles: ST com SVR (ST-SVR) e com Árvores de Regressão (ST-AR), MTRS com SVR (MTRS-SVR) e com Árvores de Regressão (MTRS-AR). Todos estes métodos são validados e otimizados por meio de validação cruzada $k - fold$, onde $k = 10$.

4 Resultados

Neste capítulo serão discutidas as métricas de avaliação do método proposto bem como os resultados obtidos a partir deste. Também será feita uma comparação com os resultados obtidos por (ALMEIDA et al., 2015), tendo sido feita a implementação de sua metodologia.

Para obtermos os resultados ótimos de cada regressor foi efetuada a validação cruzada e a busca de parâmetros por busca em grid, assim os parâmetros ótimos encontrados em cada um dos algoritmos podem ser visto nas Tabelas 1, 2, 3 e 4.

Devido ao fato de estes métodos serem de transformada de problema, o que temos é um regressor para cada valor-alvo o que se reflete nos conjuntos de parâmetros, sendo um conjunto destinado a cada regressor dentro do método.

Nas Tabelas 1 e 2 vemos os parâmetros C , γ e ϵ utilizado nas SVM, a primeira referente ao método ST e a segunda referente ao método MTRS.

Tabela 1 – Parâmetros C , γ e ϵ otimizados do método *Single-target* com SVM.

	RCRM		RSRM		RCRL		RSRL	
	D	E	D	E	D	E	D	E
C	2^8	2^5	2^{10}	2^8	2^3	2^7	2^5	2^6
γ	2^{-7}	2^{-6}	2^{-9}	2^{-8}	2^{-4}	2^{-7}	2^{-4}	2^{-5}
ϵ	0.05	0.05	0.25	0.2	0	0.3	0.1	0.3

Tabela 2 – Parâmetros C , γ e ϵ otimizados do método *Multi-target Regressor Stacking* com SVM.

	RCRM		RSRM		RCRL		RSRL	
	D	E	D	E	D	E	D	E
C	2^{15}	2^{12}	2^7	2^{12}	2^{13}	2^{14}	2^{12}	2^{15}
γ	2^{-15}	2^{-15}	2^{-12}	2^{-13}	2^{-15}	2^{-15}	2^{-15}	2^{14}
ϵ	0.05	0.05	0.1	0.1	0	0.2	0.1	0.3

Os valores "Fold" e "Minsplit", nas árvores de regressão, estão fortemente correlacionados, de forma que o primeiro expressa quantas subdivisões haverá na validação cruzada interna e quantos valores (no mínimo) haverá por grupo. Assim, os valores ótimos encontrados são os apresentados nas Tabelas 3 e 4.

Quanto as medidas de avaliação dos resultados obtidos com a aplicação da metodologia sobre a base de dados apresentada, foram utilizados o Erro Quadrático Médio (EQM) e a Raiz do Erro Quadrático Médio (REQM). O primeiro, dado pela Equação 4.1, remete à média absoluta da distância entre os valores previstos e os valores

Tabela 3 – Parâmetros Fold e Minsplit otimizados do método *Single-target* com Árvores de Regressão.

	RCRM		RSRM		RCRL		RSRL	
	D	E	D	E	D	E	D	E
Fold	5	5	10	10	5	10	10	10
Minsplit	15	5	10	5	5	5	5	5

Tabela 4 – Parâmetros Fold e Minsplit otimizados do método *Multi-target Regressor Stacking* com Árvores de Regressão.

	RCRM		RSRM		RCRL		RSRL	
	D	E	D	E	D	E	D	E
Fold	5	10	10	10	10	10	10	5
Minsplit	10	10	5	15	5	10	15	10

reais. Já o segundo representa o desvio médio padrão do todo a partir da amostra utilizada, e é dado pela equação 4.2.

$$MSE = \frac{1}{n} \sum_{i=1}^n |p_i - a_i|^2 \quad (4.1) \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - a_i)^2} \quad (4.2)$$

Em ambas as equações n é o número de amostras levadas em consideração na avaliação (como o método foi validação cruzada com $k = 10$ isto corresponde a 10% da base); p_i é a predição feita pelo regressor para a i -ésima amostra e a_i é o valor observado da amostra (aquele estabelecido pelo médico especialista).

Assim, quanto menor os valores de erro, mais eficiente é o método e, visto que o erro dado é em milímetros, é bastante importante manter estes o mais próximo de 0 o possível. As Tabelas 5 e 6 apontam, respectivamente, o EQM e REQM médio obtidos a partir da aplicação do melhor conjunto de parâmetros sobre seus respectivos métodos, como descrito anteriormente.

Tabela 5 – Erro Quadrático Médio dos regressores dos métodos apresentados.

		RCRM		RSRM		RCRL		RSRL		Média
		D	E	D	E	D	E	D	E	
ST	SVR	1.59	1.607	2.636	2.53	2.562	2.544	2.318	2.354	2.268
	AR	0.772	0.648	0.991	0.292	0.362	0.699	1.904	2.151	0.977
MTRS	SVR	0.149	0.049	1.103	0.567	0.473	1.128	0.044	0.163	0.46
	AR	0.715	0.494	1.025	0.329	0.567	0.354	2.025	1.606	0.89

Ao se observar o desempenho dos métodos ST e MTRS individualmente é notável, logo em um primeiro momento, que o segundo obteve desempenho superior, com a média de ambos EQM abaixo dos 0.9 milímetros em ambas instâncias enquanto que no método ST o melhor desempenho, obtido utilizando as AR, foi de 0.977 milímetros.

Assim, o método MTRS mostra-se superior e pode-se apontar destaque para este

Tabela 6 – Raiz do Erro Quadrático Médio dos regressores dos métodos apresentados.

		RCRM		RSRM		RCRL		RSRL		Média
		D	E	D	E	D	E	D	E	
ST	SVR	1.156	1.199	1.520	1.515	1.489	1.516	1.488	1.460	1.418
	AR	0.777	0.714	0.773	0.433	0.505	0.67	1.272	1.175	0.79
MTRS	SVR	0.247	0.207	0.928	0.697	0.393	0.965	0.208	0.401	0.506
	AR	0.718	0.63	0.721	0.435	0.573	0.456	1.183	1.06	0.722

método aplicado com o uso das SVM que obteve MSE médio de 0.46 e REQM médio de 0.506, os menores dentre os quatro métodos avaliados.

O método que mais se aproximou foi o MTRS-AR, que mesmo sendo o mais próximo ainda apresenta diferença de 0.43 e 0.216 no EQM e REQM, respectivamente. Entretanto, alguns dos outputs tiveram comportamento semelhantes, como RSRM – tanto D quanto E – e RCRLE, onde este método obteve erros médios até menores.

Entretanto estes casos, onde a maior diferença é de 0.774 milímetros, não é capaz de justificar o método como mais eficiente quando, em contra partida, este apresenta erros de até 1.981 a mais que o MTRS-SVR. Assim, o método MTRS fazendo uso das SVM é o melhor método, dentre os explorados, para o planejamento cirúrgico.

Vale ressaltar que tais valores refletem na precisão dos métodos como um todo. Desta forma enquanto os erros, de forma geral, são em torno de 1 milímetro, podem haver em casos específicos, por paciente e/ou operação indicada, erros mais amplos que poderiam vir a ocasionar prejuízos à saúde.

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).

4.1 Comparação de resultados

Nesta seção os resultados obtidos durante os testes do método proposto são comparados com o trabalho de (ALMEIDA et al., 2015) (ao qual, de agora em diante, nos referiremos como método *D*), o único trabalho encontrado que aborda o mesmo problema. Da mesma forma, iremos nos referir ao método proposto, dado pela combinação do modelo MTRS com o algoritmo de SVR (MTRS-SVR) como método *T*.

Na Tabela 7, são expostos os erros EQM e REQM comparando os métodos aplicados em seu trabalho com o método de melhor desempenho desenvolvido neste.

Estes valores são dados pelo treinamento da base de forma que 88 instâncias são

Tabela 7 – Valores comparativos dos resultados do trabalho relacionado com o modelo proposto, MTRS-SVR.

		RCRM		RSRM		RCRL		RSRL		Média
		D	E	D	E	D	E	D	E	
EQM	<i>D</i>	0.510	0.480	1.220	1.210	1.130	1.140	1.040	1.100	0.979
	<i>T</i>	0.298	0.099	1.182	0.889	0.946	1.134	0.087	0.327	0.620
REQM	<i>D</i>	0.800	0.880	2.020	1.580	1.850	2.00	1.760	1.940	1.604
	<i>T</i>	0.495	0.414	0.994	1.138	0.786	1.482	0.416	0.801	0.816

usadas para treino e 26 para teste, de maneira direta. Em seu trabalho ([ALMEIDA et al., 2015](#)) usou da técnica ST, gerando um regressor para cada valor alvo.

De maneira similar aos resultados obtidos anteriormente, quando foi feita a validação cruzada de forma a obter as médias dos resultados, a diferença entre o método ST, aplicada inconscientemente no método D, e MTRS são de vários milímetros, com o segundo método apresentado MSE médio $\approx 37\%$ e RMSE $\approx 50\%$ menores que o primeiro.

Ainda assim, em certas operações (e.g.: RSRMD, RSRME e RCRLE) os erros apresentados ainda são bastante preocupantes. Mesmo quando levamos em conta o fator humano, que pode levar a operações consideravelmente diferentes do plano a ocorrerem, podem ter resultados bastante negativos.

5 Conclusão

Este trabalho apresentou um estudo acerca de regressores de múltiplas saídas bem como a viabilidade do uso destas técnicas no planejamento de cirurgias de correção de estrabismo a partir do aprendizado de dados de planos cirúrgicos já existentes, definidos por um médico especialista.

Trabalhos anteriores com intuito similares não exploraram o uso de regressores com múltiplos valores-alvo. Assim, a contribuição deste trabalho para o âmbito da discussão da geração automática de planos cirúrgicos convém da utilização destas técnicas capazes de explorar o relacionamento entre os valores-alvo pretendidos no plano e, assim, melhorar os resultados aproximando-os mais da realidade.

Um total de quatro métodos foram explorados neste trabalho, obtidos pela aplicação dos modelos ST e MTRS juntamente de dois regressores de única saída (SVR e Árvores de Regressão). Quanto aos resultados obtidos, estes focam de maneira primária na redução do MSE, permitindo uma aproximação dos valores sugeridos no plano do especialista.

Dentre os métodos experimentados aquele que obteve melhor desempenho foi o método MTRS em conjunto do regressor SVR visto que este, apesar de não apresentar os menores desvios em todas os oito valores-alvo, foi o que se manteve mais consistente com o plano cirúrgico estabelecido pelo médico, apresentando o melhor resultado médio.

A partir da análise dos resultados obtidos pode-se concluir que o uso de técnicas de regressão com múltiplas saídas no contexto apresentado é uma pesquisa que pode ainda trazer bons frutos. Sua aplicabilidade em um ambiente real é uma possibilidade mas ainda exige diversos testes antes de atingirem este ponto, visto que erros que ultrapassam 1 milímetro são bastante significativos no escopo deste trabalho. Ainda assim, tendo em vista a melhora em relação a outros trabalhos, sabe-se que a abordagem *multi-output* vale a pena ser aprofundada.

Em trabalhos futuros é proposto, inicialmente, a redução do espaço de características, visto que 23 ainda é um conjunto muito grande. Uma revisão do método proposto pela medicina pode vir a beneficiar o desempenho do método computacional, ou mesmo uma análise fria com métodos computacionais, como mapas de calor.

A utilização de bases de dados mais diversificada, tanto em volume (dado que esta continha apenas 114 casos) como sugestões de outros oftalmologistas para o mesmo problema – o que permitiria maior flexibilidade dos regressores. Também é sugerido a aplicação de mais métodos *multi-output*, visto que ainda existem muitos não explorados neste trabalho, como LS-SVR, MOSVR, *Random Forest*.

Referências

- ALMEIDA, J. D. S. de; SILVA, A. C.; TEIXEIRA, J. A. M.; PAIVA, A. C.; GATTASS, M. Surgical planning for horizontal strabismus using support vector regression. *Computers in biology and medicine*, Elsevier, v. 63, p. 178–186, 2015. Citado 6 vezes nas páginas 14, 18, 29, 33, 35 e 36.
- ARCHER, S. M.; MUSCH, D. C.; WREN, P. A.; GUIRE, K. E.; MONTE, M. A. D. Social and emotional impact of strabismus surgery on quality of life in children. *Journal of American Association for Pediatric Ophthalmology and Strabismus*, Elsevier, v. 9, n. 2, p. 148–151, 2005. Citado na página 14.
- BASAK, D.; PAL, S.; PATRANABIS, D. C. Support vector regression. *Neural Information Processing-Letters and Reviews*, Citeseer, v. 11, n. 10, p. 203–224, 2007. Citado na página 25.
- BORCHANI, H.; VARANDO, G.; BIELZA, C.; LARRAÑAGA, P. A survey on multi-output regression. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 5, n. 5, p. 216–233, 2015. Citado 2 vezes nas páginas 22 e 23.
- CORPORATION, M.; WESTON, S. *doParallel: Foreach Parallel Adaptor for the 'parallel' Package*. [S.l.], 2018. R package version 1.0.14. Disponível em: <<https://CRAN.R-project.org/package=doParallel>>. Citado na página 30.
- CUI, L.; XIE, X.; SHEN, Z. M.; LU, R.; WANG, H. Prediction of the healthcare resource utilization using multi-output regression models. *IISE Transactions on Healthcare Systems Engineering*, Taylor & Francis, n. just-accepted, p. 1–25, 2018. Citado na página 15.
- CURTIS, T. H.; MCCLATCHEY, M.; WHEELER, D. T. Epidemiology of surgical strabismus in saudi arabia. *Ophthalmic epidemiology*, Taylor & Francis, v. 17, n. 5, p. 307–314, 2010. Citado na página 20.
- DE'ATH, G. Multivariate regression trees: a new technique for modeling species–environment relationships. *Ecology*, Wiley Online Library, v. 83, n. 4, p. 1105–1117, 2002. Citado na página 28.
- DIAZ, J. P.; DIAS, C. S. *Strabismus*. [S.l.]: Butterworth Heinemann, Woburn, Massachusetts, EUA, 2000. Citado 2 vezes nas páginas 14 e 19.
- EC, E. Genetic basis of congenital strabismus. *Archives of Ophthalmology*, v. 125, n. 2, p. 189–195, 2007. Disponível em: <[+http://dx.doi.org/10.1001/archophth.125.2.189](http://dx.doi.org/10.1001/archophth.125.2.189)>. Citado na página 14.
- GODBOLE, S.; SARAWAGI, S. Discriminative methods for multi-labeled classification. In: SPRINGER. *Pacific-Asia conference on knowledge discovery and data mining*. [S.l.], 2004. p. 22–30. Citado na página 23.
- HATT, S. R.; LESKE, D. A.; KIRGIS, P. A.; BRADLEY, E. A.; HOLMES, J. M. The effects of strabismus on quality of life in adults. *American journal of ophthalmology*, Elsevier, v. 144, n. 5, p. 643–647, 2007. Citado na página 14.

JUNQUEIRA, L.; CARNEIRO, J. *Histologia Básica. 8a Edição*. [S.l.]: Editora Guanabara Koogan, 1995. Citado 2 vezes nas páginas 17 e 18.

LEO, B.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. Classification and regression trees. *Wadsworth International Group*, 1984. Citado na página 26.

LOH, W.-Y. Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 1, n. 1, p. 14–23, 2011. Citado na página 27.

Mauricio Zambrano-Bigiarini. *hydroGOF: Goodness-of-fit functions for comparison of simulated and observed hydrological time series*. [S.l.], 2017. R package version 0.3-10. Disponível em: <<http://hzambran.github.io/hydroGOF/>>. Citado na página 30.

MEYER, D.; DIMITRIADOU, E.; HORNIK, K.; WEINGESSEL, A.; LEISCH, F. *e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien*. [S.l.], 2018. R package version 1.7-0. Disponível em: <<https://CRAN.R-project.org/package=e1071>>. Citado na página 30.

Microsoft; WESTON, S. *foreach: Provides Foreach Looping Construct for R*. [S.l.], 2017. R package version 1.4.4. Disponível em: <<https://CRAN.R-project.org/package=foreach>>. Citado na página 30.

NOORDEN, G. V.; CAMPOS, E. *Binocular vision and ocular motility: theory and management of strabismus*. [S.l.]: Mosby Inc, 2001. Citado 2 vezes nas páginas 14 e 19.

QUEIROZ, F. C. M. *Análise de componentes principais na meta-análise para obtenção de equações de predição de valores energéticos de alimentos para aves*. Dissertação (Mestrado) — Universidade Federal de Lavras, 2010. Citado na página 21.

RUDOVIC, O.; PAVLOVIC, V.; PANTIC, M. Multi-output laplacian dynamic ordinal regression for facial expression recognition and intensity estimation. In: *IEEE. 2012 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.], 2012. p. 2634–2641. Citado na página 15.

SCHUTTE, S.; POLLING, J. R.; HELM, F. C. T. van der; SIMONSZ, H. J. Human error in strabismus surgery: quantification with a sensitivity analysis. *Graefe's Archive for Clinical and Experimental Ophthalmology*, v. 247, n. 3, p. 399, 2008. ISSN 1435-702X. Disponível em: <<http://dx.doi.org/10.1007/s00417-008-0961-x>>. Citado na página 35.

SHIMAUTI, A. T.; PESCI, L. d. T.; SOUSA, R. L. F. d.; PADOVANI, C. R.; SCHELLINI, S. A. Estrabismo: detecção em uma amostra populacional e fatores demográficos associados. *Arquivos Brasileiros de Oftalmologia*, Conselho Brasileiro de Oftalmologia, p. 92–96, 2012. Citado na página 18.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. *Statistics and computing*, Springer, v. 14, n. 3, p. 199–222, 2004. Citado 2 vezes nas páginas 25 e 26.

SPALTON, D. J.; HITCHINGS, R. A.; HUNTER, P. A. Atlas de oftalmologia clínica. In: *Elsevier*. Rio de Janeiro, RJ: [s.n.], 2006. v. 3, p. 603–35. Citado na página 18.

SPYROMITROS-XIOUFIS, E.; TSOUMAKAS, G.; GROVES, W.; VLAHAVAS, I. Multi-label classification methods for multi-target regression. *arXiv preprint arXiv:1211.6581*, 2012. Citado 3 vezes nas páginas 22, 23 e 24.

- THERNEAU, T.; ATKINSON, B. *rpart: Recursive Partitioning and Regression Trees*. [S.l.], 2018. R package version 4.1-13. Disponível em: <<https://CRAN.R-project.org/package=rpart>>. Citado na página 30.
- TIMOFEEV, R. Classification and regression trees (cart) theory and applications. *Humboldt University, Berlin*, 2004. Citado na página 27.
- TUIA, D.; VERRELST, J.; ALONSO, L.; PÉREZ-CRUZ, F.; CAMPS-VALLS, G. Multioutput support vector regression for remote sensing biophysical parameter estimation. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 8, n. 4, p. 804–808, 2011. Citado na página 15.
- VAPNIK, V.; GOLOWICH, S. E.; SMOLA, A. et al. Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, Morgan Kaufmann Publishers, p. 281–287, 1997. Citado na página 25.
- VISU, T. P. *Olho e visão*. 2018. <<https://www.provisu.ch/pt/assuntos/olho-e-visao.html>>. (Accessed on 01/11/2019). Citado na página 18.
- WING, M. K. C. from J.; WESTON, S.; WILLIAMS, A.; KEEFER, C.; ENGELHARDT, A.; COOPER, T.; MAYER, Z.; KENKEL, B.; TEAM the R. C.; BENESTY, M.; LESCARBEAU, R.; ZIEM, A.; SCRUCICA, L.; TANG, Y.; CANDAN, C.; HUNT., T. *caret: Classification and Regression Training*. [S.l.], 2018. R package version 6.0-81. Disponível em: <<https://CRAN.R-project.org/package=caret>>. Citado na página 30.
- ZHEN, X.; ISLAM, A.; BHADURI, M.; CHAN, I.; LI, S. Direct and simultaneous four-chamber volume estimation by multi-output regression. In: SPRINGER. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. [S.l.], 2015. p. 669–676. Citado na página 15.