

Universidade Federal do Maranhão
Centro de Ciências Exatas e Tecnológicas
Graduação em Ciência da Computação

Aprendizagem de Máquina para Predição da
Quantidade de Blocos em Experimento de
Aquisição de Habilidade Motora em Tarefa de
Decalque

Eduardo Dorneles Ferreira de Souza

São Luís-MA, 2018

Eduardo Dorneles Ferreira de Souza

Aprendizagem de Máquina para Predição da
Quantidade de Blocos em Experimento de Aquisição de
Habilidade Motora em Tarefa de Decalque

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.

Universidade Federal do Maranhão – UFMA
Centro de Ciências Exatas e Tecnológicas
Bacharelado em Ciência da Computação

Orientador: Prof. Dr. Paulo Rogério de Almeida Ribeiro

São Luís-MA

2018

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

Souza, Eduardo Dorneles Ferreira de.

Aprendizagem de Máquina para Predição da Quantidade de Blocos em Experimento de Aquisição de Habilidade Motora em Tarefa de Decalque / Eduardo Dorneles Ferreira de Souza. - 2018.

36 f.

Orientador(a): Paulo Rogério de Almeida Ribeiro.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, Mini Auditório 307/308 Asa Sul - Paulo Freire, 2018.

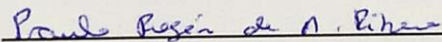
1. Aprendizagem de máquina. 2. Aprendizagem motora.
3. Tarefa de decalque. I. Ribeiro, Paulo Rogério de Almeida. II. Título.

Eduardo Dorneles Ferreira de Souza

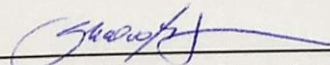
Aprendizagem de Máquina para Predição da
Quantidade de Blocos em Experimento de Aquisição de
Habilidade Motora em Tarefa de Decalque

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.

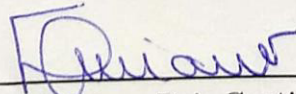
Trabalho aprovado. São Luís-MA, 10 de julho de 2018:



Prof. Dr. Paulo Rogério de Almeida
Ribeiro
Orientador
Universidade Federal do Maranhão



Prof. Dr. Geraldo Braz Junior
Universidade Federal do Maranhão



Prof. Dr. Luciano Reis Coutinho
Universidade Federal do Maranhão

São Luís-MA
2018

*À minha mãe Isabel,
por todo apoio e cuidado na minha criação.*

Agradecimentos

Em primeiro lugar agradeço Deus pela vida que tenho.

Agradeço imensamente à minha mãe Isabel por toda dedicação e esforço em minha criação e de meus irmãos além de acreditar no meu potencial. Agradeço aos meus irmãos Marcus e Rodrigo pelo convívio e momentos únicos que dividimos. Agradeço aos meus familiares por serem companheiros, oferecerem ótimos momentos de compartilhamento de experiência.

Agradeço a todos os professores da UFMA que tive o privilégio de aprender durante a graduação. Em especial ao Prof. Dr. Paulo Rogério por me orientar durante a execução deste trabalho, por compartilhar o melhor de sua experiência e por me introduzir à uma área de estudo bem interessante e cativante. Agradeço em especial também ao Prof. Dr. Alexandre por ter me acompanhado em vários momentos durante a graduação e ter sido uma referência como profissional e pessoa para mim.

De modo geral, agradeço a todos os amigos que fiz durante a minha vida: amigos de infância, de escola, faculdade e de trabalho. Nomeadamente Caetano, Lucas Mamede e Caio por lembranças eternizadas. Agradeço pelas amizades feitas durante a faculdade, por momentos de companheirismo, aprendizagem ou descontração: Lázaro, Alex, Juliano, Dayson, Danilo, Jordan, Jullyana, Matheus, Gilvan, Italo, Antonio, Luann, Raposo, Moisés, Marvin, Chrystian, Gleidson, Ada e Êmile. Agradeço aos amigos que fiz no trabalho: Victor, Joás, Francisco.

Agradeço ao estudante do curso de Engenharia da Computação da Universidade Federal do Maranhão Mateus Barros Frota por ter desenvolvido o software para realização dos experimentos utilizados neste trabalho.

Agradeço especialmente à minha namorada Fernanda pelo companheirismo, amizade e amor. Tenho forças para lidar com momentos difíceis graças ao seu apoio e crença na minha capacidade. Sou profundamente grato, não esqueça que te amo.

Agradeço à UFMA por ter fornecido toda as condições para minha formação profissional e como pessoa.

*“O silêncio eterno desses
espaços infinitos me apavora.”
(Blaise Pascal)*

Resumo

Uma parcela considerável da população mundial adquiriu algum tipo de doença neuro-motora, seja por motivos genéticos ou fatores externos. Por conta disso, a neurociência tem como um dos seus objetivos compreender como a aprendizagem motora pode ocorrer em pacientes saudáveis ou com doenças neuro-motoras. A literatura subdivide aprendizagem motora em dois tipos principais: aquisição de habilidade e reabilitação. Uma hipótese ainda não testada é a possibilidade de prever a quantidade de sessões de treinamento motor, seja para aquisição de habilidades ou reabilitação, será necessária. Nesse sentido, a aprendizagem de máquina é uma ferramenta que pode dar suporte para estimar a evolução no desempenho de pacientes. O presente trabalho utilizou uma mesa digitalizadora em conjunto com um software visando replicar o experimento de tarefa de decalque e realizar a coleta de dados de participantes: erro médio, tempo médio e bloco de treinamento. Em seguida, a partir dos dados obtidos foram aplicadas técnicas de aprendizagem de máquina como regressão linear, kNN e SVR com objetivo de prever valores de bloco. Os resultados obtidos foram satisfatórios considerando coeficiente de correlação de Pearson de 0,775 e erro médio quadrático de 0,27 em alguns experimentos, permitindo afirmar considerável correlação entre os dados preditos e os dados reais com baixo valor de erro.

Palavras-chaves: aprendizagem motora, aprendizagem de máquina, tarefa de decalque.

Abstract

A considerable portion of world population suffer from some kind of neuron motor disease caused by genetics or environmental factors. Thus, neuroscience has as one of its objectives the understanding about how motor learning may happen in healthy subjects or patients with neurological disease. Researchers categorize the motor learning in two major groups: skill learning and rehabilitation. It is worth mentioning that there is no work that predicts the amount of training sessions of a patient, which can be for skill learning and rehabilitation, might be necessary. Therefore, machine learning shows up as a nice tool to estimate the patients development. This work adopted a digital table and a software to acquire the mean error, mean time and the number of blocks during the training of a tracing task. Then, this work shows how machine learning can be used in motor learning experiments for a tracing task to predict the number of blocks that might be necessary to perform a motor skill learning . Linear regression, kNNN and SVr were used to estimate the number of blocks during a training period. The results show a 0.775 pearson correlation and a 0.27 root-mean-square error for some experiments, i.e., suggesting a correlation between the real and estimated number of blocks.

Keywords: motor learning, machine learning, regression, tracing task.

Lista de ilustrações

- Figura 1 – Ilustração do processo de aprendizagem a partir de um conjunto de pontos de dados. Os pontos em azul representam os pontos de dados de entrada. A curva em laranja representa a função polinomial ajustada a partir dos pontos de dados. Os novos pontos de dados a serem avaliados serão preditos a partir da curva dessa função 7
- Figura 2 – Apresentação de um exemplo de *trial* realizado por um participante para a palavra “vai”. Em (A) é apresentada a palavra modelo em cor preta, enquanto que na cor vermelha está representada o decalque do participante durante o *trial*. Em (B) é apresentada a imagem da palavra modelo após aplicação do filtro gaussiano de kernel 50x50 e desvio padrão 12. Em (C) é apresentada a imagem resultante após aplicação do filtro gaussiano na imagem de decalque do participante. 12
- Figura 3 – Comparativo entre experimentos do algoritmo kNN com VCCOU variando o parâmetro k correspondente à quantidade de vizinhos utilizados para cálculo do valor a ser predito. O eixo x apresenta os valores de k , enquanto o eixo y apresenta os valores do Coeficiente de Correlação em cada um dos experimentos. A linha vermelha representa a utilização da distância Manhattan e a linha azul representa o uso da distância euclidiana. 18
- Figura 4 – Comparativo entre experimentos mais relevantes selecionados em relação à Raiz do Erro Quadrático Relativo, as abordagens com melhores resultados apresentados não diferiram muito. 20

Lista de tabelas

- Tabela 1 – Informações sobre os atributos presentes na base de dados. Enfatiza-se que o atributo bloco possui somente três valores: 1,2 e 3. 13
- Tabela 2 – Configurações de todos os experimentos realizados utilizando kNN. Na primeira coluna da tabela estão presentes os rótulos de cada uma das configurações dos experimentos. A segunda coluna, de cabeçalho “Parâmetro K”, apresenta os valores utilizados no parâmetro k do algoritmo kNN. A coluna “Tipo da Distância” apresenta qual modo de cálculo de distância foi utilizado: Euclidiana ou Manhattan. Por fim, a coluna “Número de Folds” apresenta a quantidade de repetições utilizada durante a técnica de Validação Cruzada, o caso de 180 repetições trata-se dos casos de validação cruzada com omissão de um. 16
- Tabela 3 – Configurações de todos os experimentos realizados com SVR. A primeira coluna da tabela apresenta o rótulo de cada uma das configurações dos experimentos. A coluna de cabeçalho “Kernel” apresenta as funções Kernel utilizadas nos experimentos. A coluna “Parâmetro γ ” apresenta os valores utilizados no parâmetro γ do kernel RBF. As últimas duas colunas apresentam os valores utilizados nos parâmetros ω e σ do Kernel PUK. Em todos os experimentos de SVR o parâmetro C foi mantido com valor 1 e VCCOU foi utilizada. 17
- Tabela 4 – Resultados obtidos dos experimentos com Regressão Linear, kNN e SVR. No cabeçalho da tabela da esquerda para a direita estão representados o Coeficiente de Correlação de Pearson, o Erro Médio Absoluto, o Erro Quadrático Médio, a Raiz do Erro Quadrático Médio, o Erro Absoluto Relativo, a Raiz do Erro Quadrático Relativo e o número de folds utilizado no experimento. Linhas em negrito apresentam experimentos com resultados satisfatórios, buscou-se evidenciar configurações e técnicas diferentes, não necessariamente as que obtiveram melhores valores de CCP ou de erro 19

Lista de abreviaturas e siglas

kNN	k-Vizinhos Mais Próximos (<i>k-nearest neighbours</i>)
SVR	Regressão por Vetores de Suporte (Support Vectors Regression)
RBF	Função de Base Radial (radial-basis function)
PUK	VII Kernel Universal de Pearson
CSV	Valores separados por vírgulas (comma separated values)
VCCOU	Validação Cruzada com Omissão de Um
EMA	Erro médio absoluto
EQM	Erro quadrático médio
REQM	Raiz do Erro Quadrático Médio
EAR	Erro absoluto relativo
REQR	Raiz do Erro Quadrático Relativo
CCP	Coefficiente de Correlação de Pearson

Sumário

1	INTRODUÇÃO	1
2	REFERENCIAL TEÓRICO	3
2.1	Aprendizagem Motora	3
2.1.1	Componentes de Aprendizagem Motora	3
2.1.2	Processos de Aprendizagem Motora	4
2.2	Tipos de Aprendizagem Motora	5
2.2.1	Aquisição de Habilidade Motora	5
2.3	Aprendizagem de Máquina	6
2.3.1	Regressão Linear	7
2.3.2	Regressão de k-vizinhos mais próximos	8
2.3.3	Regressão por Vetores de Suporte	9
3	METODOLOGIA	11
3.1	Tarefa de decalque com mão não-dominante	11
3.1.1	Coleta de dados	13
3.2	Aplicação das Técnicas de Aprendizagem de Máquina	14
4	RESULTADOS	18
5	CONCLUSÃO	21
	REFERÊNCIAS	22

1 Introdução

Pessoas com algum tipo de deficiência motora representam uma quantidade considerável da população brasileira. De acordo com o Censo de 2010 (SDH/PR, 2012) 7% da população brasileira possui algum tipo de deficiência motora variando entre lesões traumáticas como derrame ou paralisia cerebral e doenças congênitas. Esses tipos de traumas deixam sequelas e tornam a vida dos pacientes mais complicadas. Tendo em vista esse cenário, estudos de neurociência com ênfase em aprendizagem motora para aquisição e reabilitação de habilidades mostram-se necessários com o objetivo de apresentar soluções aos pacientes que sofrem de tais sequelas, por exemplo em Prichard, Weiller, Fritsch e Reis (2014).

Aspectos de como a aprendizagem motora pode ocorrer são constantemente estudados, por exemplo em (WOLPERT, 2011) realiza-se uma revisão dos trabalhos publicados até então, elencando os principais componentes para a aprendizagem motora: extração de informação, classes de controle, estratégias e decisões. Além dos componentes, são apresentados processos de aprendizagem motora: aprendizagem baseada em erro, aprendizagem por reforço e aprendizagem dependente de uso.

Durante sessões de reabilitação motora, a experiência médica é a informação predominante a respeito do tempo necessário para melhorias no desempenho motor do paciente. A ausência de maiores detalhes e informações podem, por vezes, desmotivar o paciente e criar falsas expectativas em relação à sua evolução durante as sessões. Portanto, a utilização de ferramentas computacionais para enfatizar a opinião médica mostra-se interessante. Além da experiência médica, dados históricos de sessões de reabilitação de outros pacientes podem ser utilizados para inferência, dessa forma, técnicas de regressão de aprendizagem de máquina são bem convenientes, pois a partir de conjuntos de dados de entrada é possível realizar predição de novos valores, conseqüentemente estimar a evolução do paciente.

No âmbito da psiquiatria, Galatzer-Levy, Ruggles e Chen (2018) apresentam como diversas abordagens da aprendizagem de máquina podem ser relevantes para o estudo de pacientes que sofrem de estresse mental e podem desenvolver doenças mentais. Enquanto que no âmbito da neurociência, especificamente de aprendizagem motora, a literatura carece de trabalhos envolvendo a aplicação da aprendizagem de máquina. Assim sendo, o presente trabalho tem como objetivo apresentar uma metodologia para prever alterações no desempenho motor online de participantes em experimentos de tarefa de decalque (detalhada na seção 3.1) utilizando técnicas de aprendizagem de máquina. Como objetivos específicos o trabalho propõe a criação de uma base de dados adquirida durante os

experimentos para estudos posteriores e validação da metodologia proposta.

A estrutura do trabalho segue em: Referencial Teórico no capítulo 2, Metodologia no capítulo 3, Resultados no capítulo 4, por fim Conclusão no capítulo 5.

2 Referencial Teórico

2.1 Aprendizagem Motora

2.1.1 Componentes de Aprendizagem Motora

A aprendizagem motora é compreendida basicamente por três componentes (WOLPERT, 2011): “extração de informação”, “decisões e estratégias” e “classes de controle”. Tais componentes definem como a aprendizagem pode ocorrer. A extração de informação diz respeito às capacidades que o sistema motor tem de influenciar órgãos sensoriais como evidenciou Sailer, Flanagan e Johansson (2005). Em estágios iniciais da aprendizagem motora em tarefa visual-motora, os órgãos sensoriais (olhos) concentram a sua atenção na origem do movimento, enquanto que em indivíduos mais experientes os órgãos sensoriais concentram-se no objetivo da tarefa, não mais na origem do movimento. Portanto, concluiu-se que diferentes informações são obtidas em estágios diferentes da aprendizagem. Além disso, outro aspecto relevante para extração de informação está relacionada em como o cérebro filtra informações. Durante a execução de tarefas motoras, indivíduos só conseguiram perceber mudanças, no instante da ocorrência, quando relacionadas à tarefa em execução (TRIESCH, 2003). Percebe-se a necessidade de extrair informação ou processá-la somente quando ela é relevante para executar ações de interesse.

Qualquer tarefa motora exige tomadas de decisão a partir da informação extraída e estratégias são elaboradas para que determinadas tarefas sejam concluídas com êxito ao se considerar como ou quando um movimento deve ser executado (WOLPERT, 2011). Em experimentos de tomada de decisão uma variável de decisão foi utilizada para representar: o acúmulo de experiência, uma evidência e um valor em quantidade a ser interpretado pela regra de decisão para enfim gerar uma escolha por parte do participante (GOLD; SHADLEN, 2007). Um tomador de decisões está interessado em obter respostas positivas enquanto evita resultados negativos. Pode-se entender respostas positivas como simples acertos durante a tomada de decisão enquanto que resultados negativos são erros, desperdício de tempo ou desperdício de esforço.

As classes de controle estão relacionadas às formas de se otimizar o desempenho motor, são subdivididas em: controle preditivo, controle reativo e controle biomecânico. Controle preditivo está associado ao atraso de respostas sensoriais-motoras. Tal atraso ocorre por conta do trajeto que a informação precisa passar no sistema nervoso até a ativação muscular para execução da tarefa de forma hábil. A predição é sustentada por correlações ou experiências anteriores, um exemplo é a aplicação de força necessária para carregar um determinado objeto: o indivíduo analisa o tamanho do objeto, o material de

sua composição para então prever a força necessária e realizar a tarefa com destreza. O controle reativo está relacionado a atualização de comandos motores durante o curso de execução após percepções sensoriais. Continuando na linha de raciocínio do exemplo do levantamento de um objeto, poderia ocorrer de o indivíduo perceber, ao iniciar a execução da tarefa, que o objeto é mais pesado do que o previsto ou que a superfície é menos aderente, etc. Diante disso o controle reativo tomará ações corretivas para executar a tarefa além de acrescentar mais informações sobre o objeto, para possíveis situações futuras.

Por fim, o controle biomecânico está relacionado a movimentos dos membros que possuem fator de peso muito grande no desenvolvimento motor. Todas as três classes são adaptáveis e contribuem para aprendizagem motora. Dependendo da tarefa sendo executada é possível que alguma das classes contribua de forma mais significativa, porém ainda assim todas podem ser utilizadas em conjunto.

2.1.2 Processos de Aprendizagem Motora

Os processos de aprendizagem motora permitem verificar como a aprendizagem é adquirida nos neurônios ao enfatizar as informações utilizadas para a aprendizagem sem depender essencialmente da modalidade sensorial (visual, cinestésica, tátil, etc), apesar destas possuírem papel importante.

No processo de aprendizagem baseada em erro o sistema sensório-motor é capaz de perceber se a resposta aos movimentos executados foram de acordo com as respostas desejadas, o interessante é que os erros de predição sensorial permitem demonstrar possíveis causas para a falha ter ocorrido, não somente o resultado da falha para atingir se o objetivo (WOLPERT, 2011). Para reduzir erros, o sistema nervoso realiza estimativas similares a um vetor gradiente do erro em que cada uma das componentes corresponde a um dos fatores relevantes para o comando motor. Como exemplo, suponha que após um indivíduo lançar um dardo ele percebeu sua falha, pois o dardo não se localizava na posição do objetivo, para diminuir o erro proveniente da execução da tarefa o indivíduo deverá ajustar fatores como: posição das mãos durante o lançamento, posição dos braços, maneira de lançamento, etc (componentes do vetor gradiente). A aprendizagem baseada em erro, portanto, utiliza o sinal direcional do erro para estimar ajustes nos comandos motores. O conceito de adaptação motora está intimamente relacionado ao processo de aprendizagem baseada em erros em que a melhoria do desempenho motor ocorre de forma gradual em condições adversas (KRAKAUER; MAZZONI, 2011). De acordo com Krakauer (2009), adaptação motora pode ser entendida como uma nova relação entre movimentos bem desenvolvidos e um novo objetivo espacial. Em outras palavras, é a utilização de habilidades motoras já aperfeiçoadas em novas situações impostas pelo ambiente sem que tenha ocorrido um treinamento no ambiente alterado. Está fora do escopo deste trabalho aprofundamentos sobre adaptação motora.

Outro processo de aprendizagem motora relevante é a aprendizagem por reforço, que diferentemente da aprendizagem baseada em erro, não há um vetor gradiente de erros, os valores de respostas são considerados simplesmente como positivos ou negativos para cada uma das ações tomadas, sem qualquer informação do direcionamento de como os comandos motores devem ser alterados para um desempenho superior. Uma vantagem constatada da aprendizagem por reforço sobre a aprendizagem baseada em erro é a sua maior contribuição para consolidação da aquisição de habilidades a partir dos sinais de recompensa (ABE, 2011). Apesar disso, infelizmente os mecanismos da aprendizagem por reforço ainda não são bem compreendidos e ainda há necessidade de um maior entendimento do que pode ser considerado uma recompensa para o sistema motor (WOLPERT, 2011).

Aprendizagem dependente do uso refere-se à capacidade de se aprender a partir da pura repetição de movimentos mesmo se nenhuma informação de resposta estiver disponível.

2.2 Tipos de Aprendizagem Motora

Diversos trabalhos publicados também subdividem a aprendizagem motora em tipos: adaptação de habilidade motora e aquisição de habilidade motora (SHMUELOF, 2012) (KRAKAUER; MAZZONI, 2011). Para melhor entendimento é importante conceituar a diferença entre aprendizagem motora online e offline: aprendizagem motora online ocorre dentro de uma mesma sessão de treinamento ou experimento, enquanto a aprendizagem motora offline ocorre entre sessões de treinamento (PRICHARD, 2014), geralmente associada à aprendizagem de longo prazo (ABE, 2011).

2.2.1 Aquisição de Habilidade Motora

Diferentemente da adaptação motora, a aquisição de habilidade motora envolve aquisição de novos padrões de ativação muscular para alcançar novos níveis de desempenho enquanto se reduz erros sem redução na velocidade do movimento da tarefa executada (AGOSTINO, 1996) (SHMUELOF, 2012). A repetição é um fator muito importante para a efetivação da aquisição de habilidade motora, principalmente ao se considerar aprendizagem motora entre blocos de treinamento.

A metodologia proposta por Prichard, Weiller, Fritsch e Reis (2014) utiliza um conjunto de ferramentas (mesa digitalizadora, softwares gráficos e o software matlab) para realizar experimentos de tarefa de decalque com mão não-dominante para simular aquisição de habilidade motora. Então são obtidos dados do aperfeiçoamento do desempenho dos participante a partir de operações de processamento de imagem entre a imagem modelo e a imagem de decalque (a seção 3.1 detalha esses procedimentos).

2.3 Aprendizagem de Máquina

Em todo tipo de aprendizagem termos como “memória”, “adaptação” e “generalização” são recorrentes. No caso da aprendizagem de máquina não é muito diferente, seu maior objetivo é permitir que computadores sejam capazes de modificar ou adaptar suas ações (MARSLAND, 2015). A literatura estabelece que a aprendizagem de máquina é dividida em três tipos (RUSSELL; NORVIG, 2013): aprendizagem por reforço, aprendizagem de máquina não-supervisionada, aprendizagem de máquina supervisionada. Em outras referências da literatura a aprendizagem evolutiva (ou computação evolutiva) também é considerada uma vertente da aprendizagem de máquina

De forma semelhante à aprendizagem por reforço abordada na seção 2.1.2, na aprendizagem de máquina ela se baseia em uma medida de utilidade em que um tomador de decisões (geralmente um programa de computador denominado de agente nesse contexto) recebe recompensas ou punições (respostas positivas ou negativas) dependendo dos resultados de suas ações.

A aprendizagem não-supervisionada, também denominada comumente de agrupamento ou clusterização, utiliza um conjunto de dados de entrada com o objetivo de encontrar similaridades entre eles, para então, categorizá-los ou agrupá-los.

Por fim, a aprendizagem de máquina supervisionada que será abordada de forma mais enfática por ser objeto de parte da metodologia deste trabalho. Tais técnicas utilizam pares de entrada e saída a fim de aprender uma função que consiga mapear o conjunto de entrada para um conjunto de saída (RUSSELL; NORVIG, 2013). Por isso, são referidas como técnicas de aprendizagem a partir de exemplos e seu principal objetivo é pautado na capacidade de generalização nos mapeamentos de entrada e saída.

Formalizando, dado um conjunto de treinamento de n pares de exemplos de entrada e saída

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) \quad (2.1)$$

onde cada y_j foi gerado por uma função desconhecida $y = f(x)$, deve-se descobrir uma função h que se aproxime da função verdadeira f .

Aprendizagem supervisionada é uma busca através do espaço de hipóteses possíveis por aquela que terá um bom desempenho, mesmo em novos exemplos além do conjunto de treinamento (RUSSELL; NORVIG, 2013). A aprendizagem supervisionada ainda é subdividida em classificação (para os casos em que os valores de saída pertencem a um conjunto discreto) e regressão (para os casos em que os valores de saída pertencem a um conjunto contínuo). Tendo em vista a proposta desse trabalho, regressão será o foco, afinal pretende-se prever a pontuação (conjunto infinito) que os participantes obterão após treinos consecutivos.

Para maior entendimento considere a Figura 1. Nela há uma função $f(x)$ de uma variável. O eixo x representa os dados de entrada conhecidos, enquanto $f(x)$ representa o eixo dos dados de saída para cada um dos valores de x conhecidos, na figura, os pontos destacados em azul representam os pontos de dados conhecidos. É válido enfatizar que a função f é desconhecida em sua totalidade, portanto, objetiva-se descobrir uma função h aproximada de f a partir dos exemplares conhecidos. A curva destacada em laranja representa uma das possíveis funções do espaço de hipóteses que podem ser aprendidas a partir do conjunto de entrada, a função h .




Figura 1 – Ilustração do processo de aprendizagem a partir de um conjunto de pontos de dados. Os pontos em azul representam os pontos de dados de entrada. A curva em laranja representa a função polinomial ajustada a partir dos pontos de dados. Os novos pontos de dados a serem avaliados serão preditos a partir da curva dessa função

As técnicas de aprendizagem de máquina supervisionada abordadas nesse trabalho serão detalhadas nas subseções seguintes. Para melhor entendimento, em alguns casos será apresentado inicialmente a técnica apropriada para classificação e em seguida a adaptação da técnica para regressão.

2.3.1 Regressão Linear

Funções lineares univariadas com entrada x e saída y têm a forma: $y = w_1x + w_0$ em que w_0 e w_1 são coeficientes a serem aprendidos e são denominados de pesos.

$$h_w(x) = w_1x + w_0 \quad (2.2)$$

Tendo um conjunto de dados dispostos em um plano cartesiano, busca-se o melhor ajuste que alinhe os dados, para isso é necessário cacular os valores de w_0 e w_1 considerando a função de perda quadrática de Gauss [$L_2(y, \hat{y}) = (y - \hat{y})^2$] (\hat{y} representa o valor predito enquanto que y representa o valor real:

$$w_0 = \frac{\sum y_j - w_1 \sum x_j}{N} \quad (2.3)$$

$$w_1 = \frac{N(\sum x_j y_j) - (\sum x_j)(\sum y_j)}{N(\sum x_j^2) - (\sum x_j)^2}; \quad (2.4)$$

Para os casos em que diversos atributos são considerados a regressão linear é denominada regressão linear multivariada, sendo a sua equação representada por:

$$h_{sw}(\mathbf{x}_j) = w_0 + \sum_i w_i x_{j,i} \quad (2.5)$$

Deve-se minimizar o erro quadrático, portanto busca-se o melhor vetor de pesos w^* :

$$w^* = \underset{\mathbf{w}}{\operatorname{argmin}} \sum_j L_2(y_j, \mathbf{w} \cdot \mathbf{x}_j) \quad (2.6)$$

2.3.2 Regressão de k-vizinhos mais próximos

O algoritmo de k-vizinhos mais próximos, abreviado kNN (do inglês *k-nearest neighbours*), é originalmente uma técnica de aprendizagem de máquina utilizada para classificação, porém nesse trabalho a sua versão para regressão é utilizada.

O kNN realiza classificação de novos indivíduos baseado em votação dos k elementos mais próximos do novo indivíduo a ser classificado, cada elemento da base inserido entre os k elementos contribui para a contagem da classificação. Por fim, a classe com maior contagem define a classe do indivíduo testado. O valor de k é definido pelo experimentador e geralmente utiliza-se um valor ímpar para evitar empates (em casos de duas classes). O funcionamento desta técnica é simples, dispensando a necessidade da etapa de treinamento, o cálculo da distância entre o indivíduo a ser classificado e os elementos existentes na base de dados é suficiente (RUSSELL; NORVIG, 2013):

$$L^p(x_j, x_q) = \left(\sum_i |x_{j,i} - x_{q,i}|^p \right)^{\frac{1}{p}} \quad (2.7)$$

O valor de p define o tipo da distância a ser utilizada durante a execução do algoritmo, por exemplo: para $p = 1$, obtém-se a distância Manhattan entre os elementos, e para $p = 2$ obtém-se a distância euclidiana (RUSSELL; NORVIG, 2013) entre os elementos.

No kNN para regressão, por não se tratar de classificação, ao invés de utilizar o critério de votação entre os vizinhos mais próximos, o valor a ser predito é calculado a partir da média dos k-vizinhos mais próximos (MARSLAND, 2015).

2.3.3 Regressão por Vetores de Suporte

A regressão por vetores de suporte (*support vector regression*, SVR) é uma técnica com finalidade de regressão baseada no algoritmo de classificação da máquina de vetores de suporte (CORTES; VAPNIK, 1995). Enquanto o SVM tem objetivo de traçar um plano (ou hiperplano, dependendo da quantidade de dimensões do problema) que melhor separa os elementos de cada classe maximizando a distância entre os elementos e esse plano, o SVR tem como objetivo traçar um hiperplano que melhor se ajusta aos dados à medida que tenta minimizar o erro de uma função de custo. Após reformulações consecutivas, e transformações (ÜSTÜN, 2006):

$$\frac{1}{2}||w||^2 + C \sum_{i=1}^n L_{\epsilon}(h(x_i), y_i) \quad (2.8)$$

com

$$L_{\epsilon}(f(x_i), y_i) = \begin{cases} 0 & \text{se } |y_i - f(x_i)| \leq \epsilon \\ |y_i - f(x_i)| - \epsilon & \text{caso contrário} \end{cases} \quad (2.9)$$

Em que $L_{\epsilon}(f(x_i), y_i)$ é a função de perda, C é a constante de regularização que determina a complexidade do modelo $h(x)$ e a quantidade até a qual desvios maiores que ϵ são toleradas (ÜSTÜN, 2006).

Após a inserção de variáveis de folga ξ , ξ_i^* a equação 2.8 é transformada em um problema primal, para que seja aplicada regressão:

$$\text{minimizar } \frac{1}{2}||w||^2 + C \sum_{i=1}^n \xi_i, \xi_i^* \quad (2.10)$$

$$\text{sujeito à } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \epsilon + \xi_i^* \\ \epsilon, \xi_i, \xi_i^* \geq 0 \end{cases} \quad (2.11)$$

A partir da equação 2.10 e suas restrições 2.11 é possível adicionar os multiplicadores de Lagrange e reformular a equação para:

$$h(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (\phi(x_i) \phi(x) + b) \quad (2.12)$$

O produto interno $\langle \phi(x_i)\phi(x) \rangle$ representa a transformação de um espaço de entrada para outro espaço de características e é comumente denominada de função kernel $K(x_i, x)$. Finalmente a equação que constrói o modelo do SVR é:

$$h(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (K(x_i, x) + b) \quad (2.13)$$

Como citado brevemente, a função kernel permite a transformação de um espaço de dados em outro para finalidades de melhor ajuste do plano em relação aos dados. A possibilidade de aplicar um kernel que melhor se ajuste a um determinado problema torna o SVR bastante versátil. A seguir são apresentadas as duas funções kernel utilizadas nesse trabalho, a Função Kernel de Base Radial (*radial basis function*, RBF):

$$K(x, y) = e^{-\gamma(x-y)^2} \quad (2.14)$$

Sendo $\gamma = \frac{1}{2\sigma^2}$ e σ a variância.

A outra função kernel utilizada é o VII kernel universal de Pearson (ÜSTÜN, 2006):

$$K(x, y) = \frac{1}{[1 + (\frac{2\sqrt{\|x-y\|\sqrt{2^{\frac{1}{\omega}}-1}}}{\sigma})^2]^\omega} \quad (2.15)$$

3 Metodologia

O presente capítulo demonstra a metodologia empregada para predição do erro e da quantidade de blocos necessários para aquisição de habilidade motora na tarefa de decalque.

A metodologia do presente trabalho é dividida em: coleta de dados em experimentos com tarefa de decalque, análise dos dados, aplicação de técnicas de regressão para predição de erros entre blocos de sessões de aprendizagem.

3.1 Tarefa de decalque com mão não-dominante

O trabalho de Prichard, Weiller, Fritsch e Reis (2014) apresentou uma metodologia para medir a contribuição de estímulos elétricos no cérebro de participantes para a execução de tarefas de decalque com a mão não-dominante. Está fora do escopo deste trabalho a utilização de estímulos elétricos nos participantes. A tarefa de decalque com mão não-dominante consiste de um participante sobrescrever uma palavra utilizando sua mão não-dominante (os participantes dos experimentos eram todos destros de acordo com o questionário Edinburgh Handedness Inventory (OLDFIELD, 1971) para simular uma situação de aquisição de habilidade motora.

Para realização do experimento, o participante deve sobrescrever (decalcar) cada uma das palavras modelo que aparece na tela do computador utilizando uma mesa digitalizadora de forma semelhante à escrita convencional, utilizando um software desenvolvido por outro membro do projeto (CARVALHO, 2018), que permitiu a aquisição das imagens. A mesa digitalizadora utilizada foi a One by Wacom CTL471L de dimensão 21cm x 14,6cm e largura, área ativa de 15,2cm x 9,5cm e 1024 níveis de pressão.

Um experimento completo com cada participante foi realizado em um dia (sessão) e consistia de 3 blocos, em que cada bloco é composto de dez *trials* (termo utilizado para cada porção mínima de um bloco de experimento, ou seja, o decalque de uma palavra modelo). O conjunto de palavras selecionadas para os *trials* foi retirado da base de dados InvokeIT (2018), ela contém o conjunto de palavras mais utilizadas de 3 a 5 letras do português brasileiro.

Durante cada *trial*, o software utilizado para os experimentos imprime na tela uma das palavras modelo da base em fonte cursiva *League Script* (FEIGE, 2018). O participante deve realizar a tarefa de decalque de cada palavra dentro do tempo apresentado pelo software. O tempo definido para cada letra foi de dez segundos, a partir da estimativa de uma função de *tradeoff* (compensação) em que a execução de uma tarefa

para ser considerada hábil possui uma relação de balanceamento entre precisão e tempo (KRAKAUER, 2013) . Em um experimento piloto, dez segundos por letra se mostrou um tempo razoável para a execução do *trial*.

Para cálculo de desempenho do participante, em cada um dos *trials* foi utilizado o percentual de erro a partir da aplicação de operações de processamento de imagem: inicialmente uma imagem é gerada para a palavra modelo e para o decalque feito pelo participante (Figura 2 A); em seguida, é aplicado um filtro gaussiano (borrão) com dimensão de kernel 50x50 e desvio padrão 12, sobre cada uma das imagens geradas (Figuras 2 B e C) para que se obtenha uma margem de erro; por fim, é feita a diferença entre as imagens da palavra modelo com filtro aplicado e a imagem do decalque com filtro aplicado (subtração entre 2 B e C), portanto um decalque perfeito retornará uma subtração de imagens com todos valores de pixel iguais a 0. Para transformação em valor percentual um valor de limiar foi calculado a partir da razão entre a soma dos valores de pixel da imagem resultante da diferença e a sua dimensão.




Figura 2 – Apresentação de um exemplo de *trial* realizado por um participante para a palavra “vai”. Em (A) é apresentada a palavra modelo em cor preta, enquanto que na cor vermelha está representada o decalque do participante durante o *trial*. Em (B) é apresentada a imagem da palavra modelo após aplicação do filtro gaussiano de kernel 50x50 e desvio padrão 12. Em (C) é apresentada a imagem resultante após aplicação do filtro gaussiano na imagem de decalque do participante.

Por fim, o valor da soma da diferença entre as imagens é dividido pelo limiar e subtraído por 1, tal valor representa o erro percentual. Ressalta-se que essa aquisição das imagens, filtragem e função de erro não fazem parte do objetivo deste trabalho, sendo que esses métodos estão implementados no software previamente desenvolvido pelo outro aluno.

3.1.1 Coleta de dados

Por conta de limitações em relação ao tempo e disponibilidade de possíveis voluntários a participantes o experimento foi realizado somente com 3 participantes. Cada participante executou 3 blocos, cada bloco contendo 10 trials. Portanto, cada participante deu origem a 30 instâncias de dados. Cada instância é composta por dados de cada *trial*, seguem os atributos por instância: a palavra, o erro percentual, o tempo (em segundos), e o número do bloco. Enfatiza-se que tais dados são fornecidos pelo software utilizado durante os experimentos.

Para analisar a melhoria de desempenho online (entre os blocos do experimento) dos participantes, foi necessário adaptar o conjunto de dados fornecido pelo software para um novo formato contendo os seguintes atributos: erro médio do participante em determinado bloco, tempo médio utilizado no bloco e o número do bloco.

Conseqüentemente, o conjunto de dados a ser estudado foi reduzido para 9 instâncias. Como resultado dessa limitação na quantidade de dados a serem analisados, percebeu-se a necessidade de gerar dados para tornar o estudo mais consistente. A partir dessas instâncias foram gerados novos dados pseudo-aleatórios a partir da aplicação de ruído com média zero e desvio padrão 0,01 aos atributos de erro médio e tempo médio (em segundos). Para cada instância de desempenho médio foram gerados 19 novas instâncias totalizando 180 instâncias (9 instâncias obtidas a partir dos dados de experimentos dos participantes e mais 171 geradas).

Tabela 1 – Informações sobre os atributos presentes na base de dados. Enfatiza-se que o atributo bloco possui somente três valores: 1,2 e 3.

Atributo	Mínimo	Máximo	Média	Desvio Padrão
erro	0,103	0,182	0,142	0,014
tempo	27,144	63,381	52,068	11,41
bloco	1	3	2	0,819

A nova base de dados foi posteriormente adaptada a um layout tabular e convertida em arquivo no formato CSV (*comma-separated-values*, valores separados por vírgulas) a fim de se aplicar técnicas de aprendizagem de máquinas nessa nova base de dados.

3.2 Aplicação das Técnicas de Aprendizagem de Máquina

Esta seção apresenta como as técnicas de aprendizagem de máquina introduzidas na seção 2.3 (Aprendizagem de Máquina) serão utilizadas sobre o conjunto de dados apresentado na seção anterior. Objetiva-se estimar o valor do bloco que o participante deve estar inserido a partir dos valores de atributo erro médio e tempo médio. Para realização de treino e teste se utilizou da técnica de validação cruzada com omissão de um (VCCOU, *leave-one-out cross validation*), uma vez que a base de dados é composta de uma quantidade pequena de instâncias (Marsland (2015) recomenda utilização de validação cruzada para bases de dados pequenas).

O primeiro experimento de aprendizagem de máquina foi aplicação do algoritmo de regressão linear. Em seguida, a técnica aplicada foi o kNN para regressão em diversas configurações, para consultar maiores detalhes das configurações utilizadas é necessário consultar a Tabela 2. Os experimentos com kNN foram conduzidos iniciando com valor de k igual a 3, método de busca linear variando entre distância euclidiana e distância manhattan, em seguida acrescentando o valor do parâmetro k em 2 até se constatar estabilidade ou decaimento nos resultados.

A última técnica utilizada foi Regressão por Vetores de Suporte, os experimentos foram conduzidos com validação cruzada com omissão de um variando as funções kernel entre RBF e PUK. Para maiores detalhes quanto a configuração dos experimentos consultar a Tabela 3

Para a avaliação dos resultados dos experimentos com os algoritmos de aprendizagem de máquina as métricas utilizadas foram o Coeficiente de Correlação de Pearson (CCP , Equação 3.1), o Erro Médio Absoluto (EMA , Equação 3.2), o Erro Quadrático Médio (EQM , Equação 3.3), a Raiz do Erro Quadrático Médio ($REQM$, Equação 3.4), Erro Absoluto Relativo (EAR , Equação 3.5) e Raiz do Erro Quadrático Relativo ($REQR$, Equação 3.6). O CCP representa o grau de associação entre variáveis, variando entre -1 e 1, quanto mais próximo de 1 maior é a correlação entre o valor predito (\hat{y}) e o valor esperado (y). As métricas citadas (com exceção do CCP) permitem avaliar o acúmulo de erro das predições, portanto o valor ótimo para cada uma delas é zero e não há limite superior. As métricas de erro com raiz quadrada em sua equação (Equações 3.4 3.6) tendem a intensificar o erro quando ocorrem predições com valores muito discrepantes de seus valores reais.

$$CCP_{\hat{y},y} = \frac{cov(\hat{y}, y)}{\sqrt{var(\hat{y})var(y)}} \quad (3.1)$$

$$EMA = \frac{\sum_{i=1}^n |\hat{y}_i - y_i|}{n} \quad (3.2)$$

$$EQM = \sum_i \frac{(y_i - \hat{y}_i)^2}{n} \quad (3.3)$$

$$REQM = \sqrt{\sum_i \frac{(y_i - \hat{y}_i)^2}{n}} \quad (3.4)$$

$$EAR = \frac{\sum_{i=1}^n |\hat{y}_i - y_i|}{\sum_{i=1}^n |\hat{y}_i - \bar{y}_i|} \quad (3.5)$$

$$REQR = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)}} \quad (3.6)$$

Tabela 2 – Configurações de todos os experimentos realizados utilizando kNN. Na primeira coluna da tabela estão presentes os rótulos de cada uma das configurações dos experimentos. A segunda coluna, de cabeçalho “Parâmetro K”, apresenta os valores utilizados no parâmetro k do algoritmo kNN. A coluna “Tipo da Distância” apresenta qual modo de cálculo de distância foi utilizado: Euclidiana ou Manhattan. Por fim, a coluna “Número de Folds” apresenta a quantidade de repetições utilizada durante a técnica de Validação Cruzada, o caso de 180 repetições trata-se dos casos de validação cruzada com omissão de um.

Experimento	Parâmetro K	Tipo da distância	Número de Folds
k3Euc5F	3	Euclidiana	5
k3Euc10F	3	Euclidiana	10
k3EucVCCOU	3	Euclidiana	180
k5Euc5F	5	Euclidiana	5
k5Euc10F	5	Euclidiana	10
k5EucVCCOU	5	Euclidiana	180
k7Euc5F	7	Euclidiana	5
k7Euc10F	7	Euclidiana	10
k7EucVCCOU	7	Euclidiana	180
k9Euc5F	9	Euclidiana	5
k9Euc10F	9	Euclidiana	10
k9EucVCCOU	9	Euclidiana	180
k11Euc5F	11	Euclidiana	5
k11Euc10F	11	Euclidiana	10
k11EucVCCOU	11	Euclidiana	180
k13EucVCCOU	13	Euclidiana	180
k3Man5F	3	Manhattan	5
k3Man10F	3	Manhattan	10
k3ManVCCOU	3	Manhattan	180
k5Man5F	5	Manhattan	5
k5Man10F	5	Manhattan	10
k5EucVCCOU	5	Manhattan	180
k7Man5F	7	Manhattan	5
k7Man10F	7	Manhattan	10
k7ManVCCOU	7	Manhattan	180
k9Man5F	9	Manhattan	5
k9Man10F	9	Manhattan	10
k9ManVCCOU	9	Manhattan	180
k11Man5F	11	Manhattan	5
k11Man10F	11	Manhattan	10
k11ManVCCOU	11	Manhattan	180

Tabela 3 – Configurações de todos os experimentos realizados com SVR. A primeira coluna da tabela apresenta o rótulo de cada uma das configurações dos experimentos. A coluna de cabeçalho “Kernel” apresenta as funções Kernel utilizadas nos experimentos. A coluna “Parâmetro γ ” apresenta os valores utilizados no parâmetro γ do kernel RBF. As últimas duas colunas apresentam os valores utilizados nos parâmetros ω e σ do Kernel PUK. Em todos os experimentos de SVR o parâmetro C foi mantido com valor 1 e VCCOU foi utilizada.

Experimento	Kernel	Parâmetro γ	Parâmetro ω	Parâmetro σ
SvrRbfG.01	RBF	0,01	—	—
SvrRbfG1	RBF	1	—	—
SvrRbfG30	RBF	30	—	—
SvrPukO1S1	PUK	—	1	1
SvrPukO1S.5	PUK	—	1	0,5
SvrPukO1S.1	PUK	—	1	0,1
SvrPukO2S.1	PUK	—	2	0,1
SvrPukO4S.1	PUK	—	4	0,1
SvrPukO8S.1	PUK	—	8	0,1
SvrPukO9S.1	PUK	—	9	0,1

4 Resultados

Este capítulo apresenta os resultados obtidos após aplicação das técnicas de aprendizagem de máquina com as configurações apresentadas na seção 3.2 Aplicação das Técnicas de Aprendizagem de Máquina.

O kNN obteve bons resultados, tanto para configurações utilizando a distância euclidiana quanto para a distância Manhattan. A Figura 3 evidencia a diferença de resultados em relação ao coeficiente de correlação nas duas abordagens. A distância Manhattan obteve melhor resultado em todos os experimentos.

A Tabela 4 detalha os resultados dos experimentos de todas as abordagens utilizadas. Ao se avaliar as métricas em conjunto é evidente perceber que os experimentos com regressão linear não obtiveram resultados satisfatórios, provavelmente por conta da natureza dos dados. O atributo “bloco” a ser predito é distribuído entre os valores 1, 2 e 3, enquanto que o “erro” se distribui por todo o eixo. A regressão linear teve sua limitação pelo fato de os pontos de dados serem extremamente dispersos impossibilitando o traçar de uma reta que se ajuste de maneira ideal sobre os dados. O SVR com kernel RBF não apresentou resultados satisfatórios, para suprir essa falha seria necessário alterar valores de γ que poderiam resultar em overfit. Tendo em vista o potencial do kernel PUK com pequenos ajustes nos parâmetros os experimentos com RBF foram descontinuados.




Figura 3 – Comparativo entre experimentos do algoritmo kNN com VCCOU variando o parâmetro k correspondente à quantidade de vizinhos utilizados para cálculo do valor a ser predito. O eixo x apresenta os valores de k , enquanto o eixo y apresenta os valores do Coeficiente de Correlação em cada um dos experimentos. A linha vermelha representa a utilização da distância Manhattan e a linha azul representa o uso da distância euclidiana.

Os valores da Raiz do Erro Quadrático Relativo entre esses experimentos foram

Tabela 4 – Resultados obtidos dos experimentos com Regressão Linear, kNN e SVR. No cabeçalho da tabela da esquerda para a direita estão representados o Coeficiente de Correlação de Pearson, o Erro Médio Absoluto, o Erro Quadrático Médio, a Raiz do Erro Quadrático Médio, o Erro Absoluto Relativo, a Raiz do Erro Quadrático Relativo e o número de folds utilizado no experimento. Linhas em negrito apresentam experimentos com resultados satisfatórios, buscou-se evidenciar configurações e técnicas diferentes, não necessariamente as que obtiveram melhores valores de CCP ou de erro

Experimento	CCP	EMA	EQM	REQM	EAR	REQR	Folds
RegLin	0,3953	0,6362	0,56505289	0,7517	94,89%	91,55%	180
k3Euc5F	0,6842	0,3519	0,37896336	0,6156	75,03%	51,87%	5
k3Euc10F	0,7008	0,3426	0,363609	0,6156	73,43%	50,71%	10
k3EucVCCOU	0,7017	0,3426	0,35988001	0,5999	51,10%	73,06%	180
k5EucVCCOU	0,7049	0,3722	0,346921	0,589	55,52%	71,73%	180
k7EucVCCOU	0,7241	0,3683	0,32058244	0,5662	54,93%	68,97%	180
k9EucVCCOU	0,7202	0,3889	0,32433025	0,5695	58,01%	69,36%	180
k11EucVCCOU	0,6728	0,4616	0,37393225	0,6115	68,05%	74,52%	180
k11Euc5F	0,7452	0,402	0,30536676	0,5526	67,34%	59,27%	5
k11Euc10F	0,7619	0,3773	0,28558336	0,5526	65,07%	55,84%	10
k13EucVCCOU	0,6709	0,4902	0,380689	0,617	72,26%	75,19%	180
k3Man5F	0,7271	0,3241	0,32901696	0,5736	69,91%	47,78%	5
k3Man10F	0,7631	0,3074	0,28761769	0,5736	65,31%	45,50%	10
k3ManVCCOU	0,7635	0,3019	0,28579716	0,5346	45,03%	65,11%	180
k5ManVCCOU	0,7556	0,32	0,29333056	0,5416	47,73%	65,96%	180
k7ManVCCOU	0,766	0,3341	0,27762361	0,5269	49,84%	64,18%	180
k9Man5F	0,7715	0,3654	0,27657081	0,5259	64,09%	53,87%	5
k9Man10F	0,7614	0,3611	0,28483569	0,5259	64,99%	53,45%	10
k9ManVCCOU	0,7628	0,3506	0,28047616	0,5296	52,30%	64,51%	180
k11Man5F	0,6728	0,4616	0,37393225	0,6115	74,52%	68,05%	5
k11Man10F	0,6871	0,4419	0,35940025	0,6115	73,01%	65,41%	10
k11ManVCCOU	0,7734	0,3611	0,27217089	0,5217	53,87%	63,55%	180
k13ManVCCOU	0,7452	0,4274	0,31382404	0,5602	63,00%	68,28%	180
SvrRbfG.01	0,436	0,6541	0,602176	0,776	97,57%	94,51%	180
SvrRbfG1	0,5133	0,5513	0,52983841	0,7279	82,24%	88,65%	180
SvrRbfG30	0,7264	0,356	0,32558436	0,5706	53,10%	69,50%	180
SvrPukO1S1	0,583	0,4542	0,44515584	0,6672	67,74%	81,26%	180
SvrPukO1S.5	0,7153	0,3716	0,33466225	0,5785	55,43%	70,46%	180
SvrPukO1S.1	0,7699	0,2815	0,28536964	0,5342	42,00%	65,06%	180
SvrPukO2S.1	0,7734	0,2761	0,28164249	0,5307	41,19%	64,64%	180
SvrPukO4S.1	0,7747	0,2745	0,27994681	0,5291	40,95%	64,45%	180
SvrPukO8S.1	0,775	0,2741	0,27962944	0,5288	40,88%	64,40%	180
SvrPukO9S.1	0,775	0,2743	0,27952369	0,5287	40,91	64,393	180

bem próximos - conforme ilustrado na Figura 4 - permitindo constatar que os resultados convergiram para essas configurações.

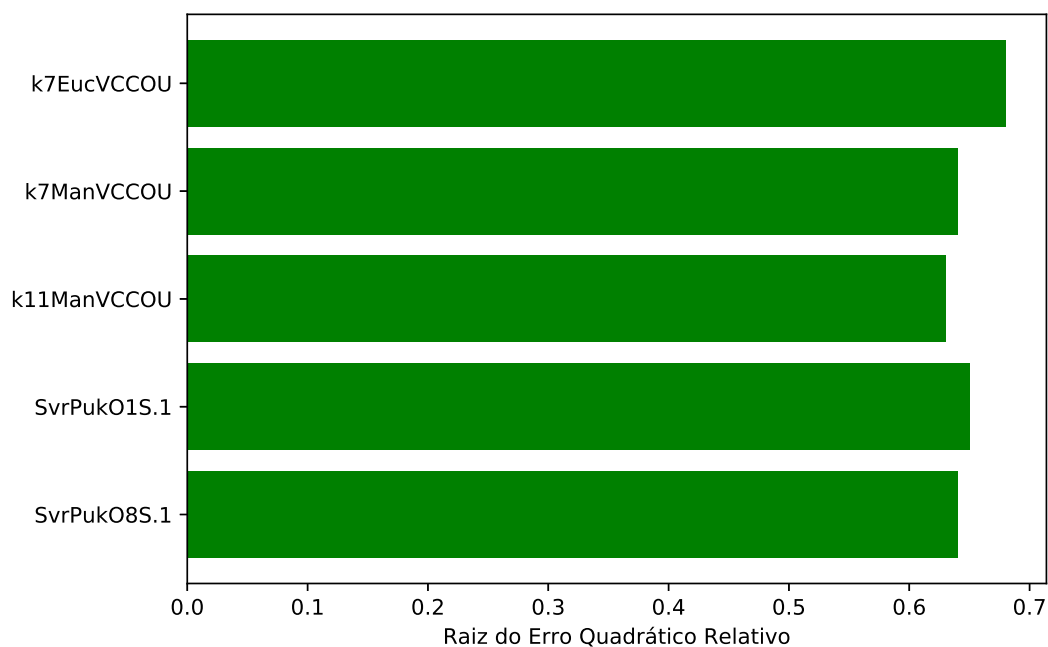


Figura 4 – Comparativo entre experimentos mais relevantes selecionados em relação à Raiz do Erro Quadrático Relativo, as abordagens com melhores resultados apresentados não diferiram muito.

5 Conclusão

Este trabalho apresentou a aplicação de técnicas de aprendizagem de máquina em dados coletados a partir de experimentos de tarefa de decalque com mão não-dominante. O objetivo da utilização de regressão de aprendizagem de máquina foi estimar em qual bloco de treinamento o participante melhor se ajustava como forma de afirmar a sua melhoria na aquisição de habilidade motora.

Durante os experimentos com técnicas de aprendizagem de máquina, determinadas configurações dos algoritmos kNN e SVR reproduziram resultados interessantes, enfatizando principalmente o algoritmo SVR com kernel PUK e kNN com distância Manhattan. De maneira geral, os resultados obtidos sustentam a continuidade na linha de estudo do trabalho, apesar de algumas limitações quanto à base de dados utilizada durante o estudo como quantidade de instâncias e quantidade pequena de atributos. Portanto como melhorias para trabalhos futuros:

- a Deve-se realizar novos experimentos para coleta de dados;
- b Adicionar novos atributos à base para que haja maior possibilidade de correlação entre os dados e que permita novos estudos de mineração de dados, como por exemplo seleção de atributos mais relevantes, detecção de anomalia, etc;
- c Realizar coletas de dados com pacientes que possuam doenças neuro-motoras;
- d Aplicação de novas técnicas de regressão na base utilizada neste trabalho e nas novas a serem contruídas.

Tendo em vista diversas pesquisas em aprendizagem motora e o vasto conhecimento descoberto, a linha de estudo deste trabalho é promissora por trazer um teor de inovação por mesclar uma abordagem de inclusão de aprendizagem de máquina para apoiar a opinião médica, portanto, esse trabalho apresenta sua relevância social e científica.

Referências

- ABE, M.; SCHAMBRA, H.; WASSERMANN, E. M.; LUCKENBAUGH, D.; SCHWEIGHOFER, N.; COHEN, L. G. Reward improves long-term retention of a motor memory through induction of offline memory gains. *Current Biology*, Elsevier, v. 21, n. 7, p. 557–562, 2011. Citado na página 5.
- AGOSTINO, R.; SANES, J. N.; HALLETT, M. Motor skill learning in parkinson’s disease. *Journal of the neurological sciences*, Elsevier, v. 139, n. 2, p. 218–226, 1996. Citado na página 5.
- CARVALHO, M. B. F. de. *Plataforma de Avaliação Automatizada do Aprendizado de Habilidade Motora*. 44 f. Monografia — Bacharelado em Engenharia da Computação, Universidade Federal do Maranhão, São Luís, 2018. Citado na página 11.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado na página 9.
- FEIGE, H. *League Script Font*. 2018. Site de compartilhamento de fontes. Disponível em: <<https://www.theleagueofmoveabletype.com/league-script>>. Acesso em: 1 jul. 2018. Citado na página 11.
- GALATZER-LEVY, I. R.; RUGGLES, K. V.; CHEN, Z. Data science in the research domain criteria era: Relevance of machine learning to the study of stress pathology, recovery, and resilience. *Chronic Stress*, SAGE Publications Sage CA: Los Angeles, CA, v. 2, p. 2470547017747553, 2018. Citado na página 1.
- GOLD, J. I.; SHADLEN, M. N. The neural basis of decision making. *Annual review of neuroscience*, v. 30, 2007. Citado na página 3.
- INVOKEIT. *Frequency Words List*. 2018. Blog da Invoke IT Limited. Disponível em: <<https://invokeit.wordpress.com/about/>>. Acesso em: 16 abr. 2018. Citado na página 11.
- KRAKAUER, J. W. Motor learning and consolidation: the case of visuomotor rotation. In: *Progress in motor control*. [S.l.]: Springer, 2009. p. 405–421. Citado na página 4.
- KRAKAUER, J. W.; MAZZONI, P. Human sensorimotor learning: adaptation, skill, and beyond. *Current opinion in neurobiology*, Elsevier, v. 21, n. 4, p. 636–644, 2011. Citado 2 vezes nas páginas 4 e 5.
- KRAKAUER, T. K. J. W. Motor learning principles for neurorehabilitation. 2013. Citado na página 12.
- MARSLAND, S. *Machine learning: an algorithmic perspective*. [S.l.]: CRC press, 2015. Citado 3 vezes nas páginas 6, 9 e 14.
- OLDFIELD, R. C. The assessment and analysis of handedness: the edinburgh inventory. *Neuropsychologia*, Elsevier, v. 9, n. 1, p. 97–113, 1971. Citado na página 11.

PRICHARD, G.; WEILLER, C.; FRITSCH, B.; REIS, J. Effects of different electrical brain stimulation protocols on subcomponents of motor skill learning. *Brain stimulation*, Elsevier, v. 7, n. 4, p. 532–540, 2014. Citado 3 vezes nas páginas 1, 5 e 11.

RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. [S.l.]: Malaysia; Pearson Education Limited,, 2013. Citado 2 vezes nas páginas 6 e 8.

SAILER, U.; FLANAGAN, J. R.; JOHANSSON, R. S. Eye–hand coordination during learning of a novel visuomotor task. *Journal of Neuroscience*, Soc Neuroscience, v. 25, n. 39, p. 8833–8842, 2005. Citado na página 3.

SDH/PR. *Cartilha do Censo 2010 Pessoas com Deficiência*. 2012. SECRETARIA DE DIREITOS HUMANOS DA PRESIDÊNCIA DA REPÚBLICA. Disponível em: <<http://www.pessoacomdeficiencia.gov.br/app/sites/default/files/publicacoes/cartilha-censo-2010-pessoas-com-deficiencia-reduzido.pdf>>. Citado na página 1.

SHMUELOF, L.; KRAKAUER, J. W.; MAZZONI, P. How is a motor skill learned? change and invariance at the levels of task success and trajectory control. *Journal of neurophysiology*, American Physiological Society Bethesda, MD, v. 108, n. 2, p. 578–594, 2012. Citado na página 5.

TRIESCH, J.; BALLARD, D. H.; HAYHOE, M. M.; SULLIVAN, B. T. What you see is what you need. *Journal of vision*, The Association for Research in Vision and Ophthalmology, v. 3, n. 1, p. 9–9, 2003. Citado na página 3.

ÜSTÜN, B.; MELSEN, W. J.; BUYDENS, L. M. Facilitating the application of support vector regression by using a universal pearson vii function based kernel. *Chemometrics and Intelligent Laboratory Systems*, Elsevier, v. 81, n. 1, p. 29–40, 2006. Citado 2 vezes nas páginas 9 e 10.

WOLPERT, D. M.; DIEDRICHSEN, J.; FLANAGAN, J. R. Principles of sensorimotor learning. *Nature Reviews Neuroscience*, Nature Publishing Group, v. 12, n. 12, p. 739, 2011. Citado 4 vezes nas páginas 1, 3, 4 e 5.