

Moisés Rocha dos Santos

Modelos de Regressão Aplicados à Estimação
de Aquisição de Habilidade Motora

São Luís

2018

Moisés Rocha dos Santos

Modelos de Regressão Aplicados à Estimação de Aquisição de Habilidade Motora

Monografia apresentada a Coordenação do
Curso de Engenharia da Computação da Uni-
versidade Federal do Maranhão, como requi-
sito para a obtenção do grau de Bacharel em
Engenharia da Computação.

Universidade Federal do Maranhão – UFMA
Coordenação de Engenharia da Computação

Orientador: Prof. Dr. Paulo Rogério de Almeida Ribeiro

São Luís

2018

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

Rocha dos Santos, Moisés.

Modelos de Regressão Aplicados à Estimação de Aquisição
de Habilidade Motora / Moisés Rocha dos Santos. - 2018.

35 p.

Orientador(a): Paulo Rogério de Almeida Ribeiro.

Monografia (Graduação) - Curso de Engenharia da
Computação, Universidade Federal do Maranhão, Centro
Pedagógico Paulo Freire, 2018.

1. Aquisição de Habilidade Motora. 2. Regressão. 3.
Tracing Task. I. de Almeida Ribeiro, Paulo Rogério. II.
Título.

Moisés Rocha dos Santos

Modelos de Regressão Aplicados à Estimação de Aquisição de Habilidade Motora

Monografia apresentada a Coordenação do
Curso de Engenharia da Computação da Uni-
versidade Federal do Maranhão, como requi-
sito para a obtenção do grau de Bacharel em
Engenharia da Computação.

Trabalho Aprovado. São Luís, 11 de 07 de 2018:


Prof. Dr. Paulo Rogério de Almeida
Ribeiro
Orientador


Prof. Dr. Bruno Feres de Souza
Universidade Federal do Maranhão


Prof. Dr. Luís Claudio de Oliveira
Silva
Universidade Federal do Maranhão

São Luís
2018

*Este trabalho é dedicado a minha esposa Fiama
e meus pais Ivaldo e Maria das Mercês*

AGRADECIMENTOS

Em primeiro lugar gostaria de agradecer aos meus pais, Dona Maria das Mercês e Senhor Ivaldo Santos que me fizeram sonhar o sonho deles de que a Educação é o bem mais precioso que devemos buscar em nossas vidas. Obrigado meus pais, esta paixão pelo conhecimento hoje é o que me move e me faz ampliar meus horizontes. Aos irmãos Davi, Lenivalda, Ivaldo Neto e Sandra pelo apoio direto e indireto. Amo vocês.

À minha esposa Fiana Cutrim por sempre estar do meu lado nos momentos de absurda pressão, quando ficou difícil até de respirar de tanto sufoco que passei, você estava lá para me apoiar. Obrigado amor, tenho certeza que comemoraremos muitas outras vitórias juntos.

Um agradecimento especial à Professora Ellen Caroline. Sou grato por tanta coisa a você, mestra. A principal foi por ter acreditado em mim e enxergado o Engenheiro da Computação nessa pessoa que naquele tempo nem cogitava essa opção. Deu certo, sou apaixonado pelo que faço e não me imagino em outro ramo. Sem falar da amizade e todos os conselhos acadêmicos que me deu. Obrigado, estão dando certo.

Aos orientadores que tive durante toda a graduação: Prof. Marcelo Zanetti, Profa. Márcia Molina, Prof. Alexandre César M. de Oliveira e Prof. Areolino de Almeida Neto. De todos vocês absorvi as melhores críticas, hábitos e, parafraseando Isaac Newton, "se hoje posso ver mais adiante foi porque me apoiei nos ombros de gigantes".

Ao orientador deste trabalho, Prof. Paulo Rogério de A. Ribeiro que está me guiando neste estudo desafiador na área de neuroreabilitação. Sua experiência e empenho constantes foram decisivos para a conclusão deste trabalho. Agradeço também ao Marco Curado pela ideia que serviu de base para este estudo.

Aos professores da Engenharia da Computação da UFMA, pela excelente formação pautada na auto superação. Todos os dias propondo novos desafios e fazendo com que saíamos de nossa zona de conforto. Nunca mudem, continuem criando monstros (no bom sentido).

Agradeço também à amizade dos colegas da ECP, LACMOR e INOVTEC. Em muitas situações vocês foram meu ponto de apoio. Agradeço aos amigos Mateus Barros, Camila Santos e seu marido Daniel, Chrystian, Matheus Menezes, Ítalo, Luann, Antonio Mourão, Eduardo Dorneles, Gilvan, André Baluz, Joaquim, Rodrigo Garcês, Ramon, Dayson. Aos amigos mestres Alex Newman, Marcelo Nascimento, Raphael, Thiago Lemos, Moisés Lawrence, André Felipe pela amizade e referência.

À grande primeira turma do curso de Engenharia da Computação da UFMA, da qual eu faço parte. Chegamos no final galera, tivemos momentos inesquecíveis e neste momento estamos fazendo história. Tenho orgulho de ser um de vocês.

À UFMA pelo fomento das bolsas de Monitoria, PIBIC e PIBITI que tive durante minha graduação. Essas experiências foram essenciais para a formação de um perfil de profissional com um leque de opções bem abrangente.

Em fim, a todos que cooperaram direta e indiretamente para a minha formação, como Engenheiro da Computação e cientista de dados interdisciplinar, que me tornei com todas as experiências adquiridas. Obrigado pessoal, vocês são 10.

*“Ninguém existe por um propósito.
Ninguém pertence a lugar nenhum.
Todo mundo vai morrer.”*

- Morty

RESUMO

Este estudo tem como objetivo encontrar uma correlação entre o tempo de movimento e o erro percentual com a quantidade de blocos em uma seção de aquisição de habilidade motora para "Tracing Task". A metodologia baseou-se na revisão de literatura de aquisição de habilidade motora, bem como na montagem da configuração inicial, aplicação de um experimento de "prova de conceito" e geração de duas bases de dados simuladas de 9 e 18 participantes para aplicação dos modelos de regressão. Os modelos de Regressão utilizados neste trabalho foram: Regressão baseada no KNN, Rede Neural MLP e Regressão Linear. Nos resultados do experimento piloto, percebe-se um aperfeiçoamento motor dos participantes após o treino, embora a quantidade de experimentos tenha sido pequena. Com os dados simulados a partir dos dados reais obteve-se uma correlação forte ($r^2 = 0,73$), tendo o modelo de Regressão baseada no KNN com o melhor resultado para a base de 18 participantes. Assim sendo, este trabalho mostrou a possibilidade de correlação entre o tempo de movimento e o erro percentual com a quantidade de blocos, conforme proposto inicialmente. Adicionalmente, ressalta-se que esta configuração servirá de base para um experimento futuro com mais participantes saudáveis, assim como pacientes, tendo como objetivo final a melhoria da qualidade de vida de pacientes com problemas motores.

Palavras-chave: Tracing Task. Aquisição de Habilidade Motora. Regressão.

ABSTRACT

This study aims to find a correlation between the movement time and the percentage error with the number of blocks in a motor skill acquisition section for the Tracing Task. The methodology was based on the state of art of motor skill acquisition, as well as the assembly of the initial configuration, application of a "proof of concept" experiment and generation of two simulated databases with 9 and 18 participants for application of the models of regression analysis. The Regression models used in this work were: Regression based on KNN, Neural Network MLP and Linear Regression. In the results of the pilot experiment, a motor improvement of the participants after the training was noticed, although the number of experiments was small. The regression model generated from the simulated data presented a strong correlation ($r^2 = 0.73$), which the regression based on the KNN was the best, with the base of 18 simulated participants. Thus, this work showed, as devoted to, the possibility of correlation between the movement time and the percentage error with the number of blocks. Furthermore, is worth mentioning that the setup provided on this work will be the basis for a future experiment with a much more number of healthy participants, as well as patients, once the final goal is to improve the quality of life of these patients with motor disabilities.

Keywords: Tracing Task. Motor Skill Learning. Regression.

LISTA DE ILUSTRAÇÕES

Figura 1 – Tracing Task	23
Figura 2 – Método de captura do erro na tarefa "Tracing Task"	24
Figura 3 – Aperfeiçoamento Motor	28
Figura 4 – Coeficiente de Determinação	30
Figura 5 – Raiz do Erro Médio Quadrático	30

LISTA DE TABELAS

Tabela 1 – Resultados dos Modelos de Regressão	29
--	----

LISTA DE ABREVIATURAS E SIGLAS

TDCS *Transcranial Direct Current Stimulation*

TRNS *Transcranial Random Noise Stimulation*

RMSE *Raiz do Erro Médio Quadrático*

KNN *K - Vizinhos mais Próximos*

Sumário

1	Introdução	14
1.1	Objetivos	15
1.2	Justificativa	15
1.3	Estrutura do trabalho	15
2	Revisão de Literatura	16
2.1	Aprendizado Motor e Reabilitação	16
2.2	Algoritmos de Predição	18
2.2.1	Regressão Linear	18
2.2.2	Regressão baseada nos Vizinhos mais Próximos - KNN	19
2.2.3	Perceptron com Múltiplas Camadas - MLP	20
2.3	Modelos de Predição Aplicados à Aquisição de Habilidade Motora	21
3	Metodologia	22
3.1	Participantes	22
3.2	Desenho Experimental	22
3.3	Amostras Complementares	24
3.4	Modelos de Regressão	25
3.5	Validação	26
4	Resultados e Discussão	27
4.1	Experimento Piloto	27
4.2	Análise Comparativa dos Modelos de Regressão	28
5	Considerações Finais	31
	Referências Bibliográficas	33

CAPÍTULO 1

INTRODUÇÃO

Em nossas vidas, segundo Prichard et al. (2014), muito tempo é gasto aprendendo novas habilidades motoras como caminhar, escrever, dirigir, praticar esportes, entre outras. As atividades motoras são a principal forma de interagir com o mundo que nos rodeia. Portanto a perda da capacidade de realizar algumas dessas atividades como resultado de uma doença neurológica é um dano grave ao indivíduo.

Quando uma doença neurológica causa um dano ao indivíduo, este deve adquirir uma nova habilidade motora que busque novas formas de ativar a musculatura para realizar a tarefa com o melhor desempenho possível (KITAGO; KRAKAUER, 2013). Dependendo da complexidade da tarefa, as sessões de treinamento podem se estender durante dias, meses e até anos para alcançar o desempenho desejável.

Embora a literatura sobre Aprendizado Motor seja numerosa, principalmente tratando das características Aperfeiçoamento e Consistência motora (Seção 2) ainda há uma lacuna no tocante a predição da aquisição da habilidade motora. A predição da quantidade de sessões ou blocos de treinamento motor que um indivíduo (no caso, saudável ou portador de uma doença que não afeta o aprendizado motor) levará para adquirir um determinado desempenho em uma tarefa é um exemplo de estudo a ser explorado.

Segundo Jordan e Mitchell (2015), algoritmos de predição vêm sendo aplicados com sucesso em diversas áreas como saúde, educação, economia, ciência, tecnologia e logística. Com o passar do tempo uma quantidade massiva de dados vêm sendo gerados e necessita-se de aplicações que processem e gerem informações que auxiliem na tomada de decisões. Estes algoritmos de predição também tornam possível a análise e obtenção de novos padrões e associações para problemas que outrora eram tratados apenas por pessoas especialistas em um determinado campo.

Lin et al. (2018) propôs a aplicação de algoritmos de aprendizado de máquina

para predição de atividades do cotidiano para pacientes pós Acidente Vascular Cerebral - AVC, obtendo uma correlação moderada entre as características do paciente e o Índice de Barthel. O Índice de Barthel, referenciado por Hsueh et al. (2002), reflete o nível de independência de um paciente em tarefas do cotidiano.

1.1 Objetivos

O objetivo principal deste trabalho é correlacionar o erro percentual e o tempo de movimento com a quantidade de blocos de aquisição de habilidade motora utilizando modelos de regressão, especificamente para a tarefa "Tracing Task" de Prichard et al. (2014).

Como objetivos específicos têm-se:

1. Reproduzir a metodologia da Tarefa "Tracing Task" do trabalho Prichard et al. (2014);
2. Observar as propriedades do Aprendizado Motor no Experimento Piloto aplicado;
3. Definir a base para um experimento com participantes reais a partir de dados simulados;

1.2 Justificativa

Uma vez que o ser humano depende das habilidades motoras para interagir com o mundo, pessoas acometidas de doenças neurológicas sofrem danos em determinadas habilidades motoras. Ao se submeter a um tratamento, o indivíduo tende a se desestimular com a incerteza de quanto tempo irá passar até que ele consiga recuperar a capacidade de voltar a fazer uma determinada tarefa.

Até então as pesquisas não se concentraram em tentar estimar a quantidade de seções ou blocos de treinamento que um indivíduo precisa para apresentar um determinado desempenho em uma tarefa. Os médicos até então fazem isso mediante suas experiências em casos passados. Este trabalho propõe aumentar a acurácia desta estimativa através de métodos estatísticos e de aprendizado de máquina.

1.3 Estrutura do trabalho

Este trabalho está organizado da seguinte forma: na Seção 2, descreve-se a literatura atual a respeito do tema proposto; na Seção 3, mostra-se a metodologia que será utilizada para realização dos experimentos; na Seção 4, apresentam-se alguns resultados e na Seção 5, a conclusão e trabalhos futuros propostos.

CAPÍTULO 2

REVISÃO DE LITERATURA

2.1 Aprendizado Motor e Reabilitação

Segundo Kitago e Krakauer (2013), "o sistema motor humano tem a capacidade de aprender com a prática e a experiência". Esta frase é central para introduzir o conceito de aprendizagem motora bem como o que pretende-se realizar nesta pesquisa. Como o sistema motor é capaz de aprender com a prática e a experiência com o passar do tempo, o ser humano aperfeiçoa-se na tarefa que está sendo executada.

Um aspecto que deve ser levado em consideração é que o indivíduo pode apresentar um aperfeiçoamento motor relevante após minutos de prática ou, dependendo da complexidade da tarefa, até meses.

Outra característica importante é a consistência que explica como a experiência influencia no aprendizado motor. Por essa característica, indivíduo tende a errar menos com o passar do tempo, diminuindo a variabilidade das execuções da tarefa (KITAGO; KRAKAUER, 2013).

Outro aspecto importante da aprendizagem motora é o estado inicial em que se encontra o sistema motor do indivíduo. Este estado inicial influencia no resultado final após uma sessão de treinamento, ou seja, o mesmo protocolo de treinamento pode levar a resultados diferentes dependendo do estado inicial do indivíduo (SHMUELOF; KRAKAUER, 2014).

Ainda segundo Kitago e Krakauer (2013) a aprendizagem motora divide-se em duas áreas: adaptação motora e aquisição de habilidade. Por adaptação entende-se que esta está relacionada à capacidade do sistema motor responder para alterar as condições ambientais para recuperar o nível de desempenho nas novas configurações do ambiente, ou seja, adaptar-se às novidades impostas por algum novo obstáculo.

Entende-se por aquisição de habilidade motora, baseado em Hallett e Grafman (1997), em contraste com a adaptação, esta envolve adquirir novos padrões de ativação muscular e adquirir um melhor desempenho pela redução dos erros sem a redução da velocidade de execução do movimento. Outra peculiaridade da aquisição em relação à adaptação é que, enquanto a adaptação ocorre durante apenas uma seção, a aquisição de habilidade motora requer um estendido período de prática, podendo durar vários dias, meses ou até anos dependendo da complexidade da tarefa (KITAGO; KRAKAUER, 2013). O ganho de desempenho pode ser aferido durante as seções (efeitos *online*) e entre as seções (efeitos *offline*) (KARNI et al., 1998).

Segundo Korman et al. (2003), quanto maior o número de repetições de uma tarefa, melhor o desempenho nesta, ou seja, a prática é o método mais efetivo de obtenção de *performance*. Outros fatores no planejamento da prática podem também contribuir para uma melhor retenção da habilidade motora.

Krakauer (2006) diz que reabilitação motora é um processo para reaprender a mover-se para realizar uma tarefa com sucesso. Ainda nesse trabalho, o autor cita diversas abordagens de reabilitação motora para recuperar aptidão em diversas tarefas como: reabilitação baseada em realidade virtual; terapia com interação robótica; terapia de movimento induzido por restrições; treinamento de capacidade de braço para pacientes com hemiparesia leve.

Em Reis et al. (2009), investigou-se o efeito da estimulação não invasiva do cérebro via Transcranial Direct Current Stimulation - tDCS (em tradução livre: Estimulação Transcraniana por Corrente Direta) na consolidação do aprendizado motor. Nesse trabalho, foi analisada a tarefa "*Pinch Task*", com a execução de cinco seções ou dias de treinamento, cada seção possuía nove blocos, cada bloco possuía 10 "*trials*" ou treinos. Como resultados principais obteve-se a função "*Speed-Accuracy Tradeoff*" para esta tarefa e encontrou-se a evidência que a aplicação da estimulação tDCS contribui apenas para os efeitos *offline* mas não para os efeitos *online* ou retenção a longo prazo.

A função "*Speed-Accuracy Tradeoff*" trata da velocidade do movimento. Quando se aumenta a velocidade do movimento, perde-se acurácia, ou seja, aumenta-se o erro. Então a acurácia por si só não é uma boa medida de desempenho, segundo Kitago e Krakauer (2013).

Prichard et al. (2014) mostrou os efeitos de diferentes protocolos de estimulação não invasiva no cérebro, tDCS e Transcranial Random Noise Stimulation - tRNS (cuja tradução livre é Estimulação Transcraniana por Ruído Aleatório), nos subcomponentes de aprendizagem de habilidade motora. A tarefa utilizada no trabalho é a "*Tracing Task*". Foram executadas três seções diárias, cada seção possui 12 blocos, cada bloco possui 15 "*trials*". Como resultados principais, obteve-se que os efeitos do tDCS e tRNS são diferentes. Enquanto os efeitos do tDCS contribuíram mais para os efeitos imediatos, os efeitos tRNS

são mais graduais e puderam ser observados em efeitos *offline*. É importante frisar que esse trabalho também fornece uma metodologia para a captura do erro percentual da tarefa "Tracing Task".

2.2 Algoritmos de Predição

2.2.1 Regressão Linear

A regressão linear consiste em uma relação estatística que envolve duas variáveis: dependente ou de resposta (y) e independente ou preditora (x). Um modelo de regressão linear considera que o valor da variável de resposta pode ser estimado por uma combinação linear das variáveis preditoras. Um modelo de regressão linear com uma variável preditora pode ser descrito pela Equação 2.1. (SILVA; PERES; BOSCAROLI, 2017)

$$y = a + bx \quad (2.1)$$

Na Equação 2.1, a e b são os coeficientes de regressão e especificam onde a reta intercepta o eixo y e a inclinação. Os coeficientes de regressão podem ser estimados usando o método dos mínimos quadrados que é apresentado no Algoritmo 1.

Algoritmo 1: Algoritmo da Regressão Linear adaptado de (SILVA; PERES; BOSCAROLI, 2017)

Dados: X_{tr} : um conjunto de treinamento com exemplos rotulados

Resultado: a, b

- 1 Calcular a média das variáveis x e y ;
- 2 Inicializar somadores com 0;
- 3 **para** $i \leftarrow 1$ a X_{tr} **faça**
- 4 $soma_1 = soma_1 + (x_i - \mu_x)(y_i - \mu_y)$
- 5 $soma_2 = soma_2 + (x_i - \mu_x)^2$
- 6 **fim**
- 7 $b = soma_1 / soma_2$
- 8 $a = \mu_y - b\mu_x$

Montgomery, Peck e Vining (2015) mostra uma aplicação da Regressão Linear: dada a necessidade de um modelo empírico que relacione a viscosidade de um polímero com a temperatura e a taxa de adição de um catalisador. O modelo de regressão que descreve essa relação é dado pela Equação 2.2.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon \quad (2.2)$$

A variável y representa a viscosidade, x_1 é a temperatura e x_2 é a taxa de adição do catalisador. Este é um modelo de regressão linear múltipla com 2 variáveis independentes. O

termo linear é usado porque a Equação 2.2 é uma função linear de parâmetros desconhecidos β_0 , β_1 e β_2 . O modelo descreve um plano no espaço bidimensional x_1, x_2 . O parâmetro β_0 define a intersecção do plano.

Generalizando, a variável de resposta y relacionadas a k variáveis preditoras. O modelo da Equação 2.3 é chamado modelo de regressão linear múltipla com k variáveis preditoras. Os parâmetros β_j , $j = 1, 2, \dots, k$, são chamados de coeficientes de regressão. Este modelo descreve um hiperplano em um espaço k -dimensional de variáveis preditoras $\{x_j\}$. O parâmetro β_j representa a mudança esperada na resposta y por unidade mudadas em x_j .

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (2.3)$$

2.2.2 Regressão baseada nos Vizinhos mais Próximos - KNN

Segundo Altman (1992), a regressão KNN (do Inglês, *K-Nearest Neighbors-based regression*) utiliza uma média do valor dos k vizinhos mais próximos para estimar o valor atual, em que k é uma constante inteira positiva.

A regressão KNN, segundo Norvig e Russell (2014), introduz uma melhora na tarefa de regressão ao considerar os k vizinhos mais próximos ao invés de apenas dois exemplos para esquerda e para a direita de um ponto. Quanto maior o valor de k mais suave é a aproximação, porém a função resultante tende a apresentar algumas descontinuidades. O Algoritmo 2 representa a regressão KNN de forma intuitiva.

Algoritmo 2: Algoritmo da Regressão KNN adaptado de (NORVIG; RUSSELL, 2014)

Dados: X_{tr} : um conjunto de treinamento com exemplos rotulados

Resultado: Função de Estimção

```

1 para  $i \leftarrow 1$  a  $X_{tr}$  faça
2   | Calcular a distancia de  $i$  para todos os exemplos de treinamento;
3   | Selecionar os  $k$  exemplos mais próximos de  $i$ ;
4   | Retornar como estimativa o rótulo médio:
5   |  $f(x) = \frac{1}{k} \sum_{i=1}^k y_i$ 
6 fim
```

Esta técnica consiste basicamente em calcular a distância entre todos os pontos e depois tirar a média dos k pontos mais próximos para obter o valor estimado, conforme apresentado no Algoritmo 2. Nas Equações 2.4 e 2.5, referenciadas por Gonzalez e Woods (2010), pode-se ver diferentes cálculos de distância, a saber, Euclidiana e Manhattan (ou City Block), respectivamente.

$$d_{euclidiana} = \sqrt{\sum_{i=1}^n (x_{2i} - x_{1i})^2} \quad (2.4)$$

$$d_{manhattan} = \sum_{i=1}^n |x_{2i} - x_{1i}| \quad (2.5)$$

2.2.3 Perceptron com Múltiplas Camadas - MLP

As Redes Neurais Artificiais são algoritmos que foram inspirados no sistema nervoso humano, mais especificamente na comunicação e geração do conhecimento a nível dos neurônios (HAYKIN, 2004). Existem várias abordagens e um dos modelos mais populares na literatura é o Perceptron de Múltiplas Camadas.

Existem vários algoritmos utilizados para fazer o treinamento destas redes, dentre eles um dos mais populares é o *Backpropagation*. Outra característica das redes neurais é que estas possuem partículas elementares chamadas neurônios e conjuntos de neurônios chamados de camadas. O Algoritmo 3 mostra a implementação de uma rede neural MLP.

Algoritmo 3: Algoritmo da Rede Neural Artificial MLP com algoritmo de treinamento Backpropagation adaptado de (MARSLAND, 2015)

Dados: X_{tr} : um conjunto de treinamento com exemplos rotulados
Resultado: Função de Estimação

```

1 início
2   Inicialização: Iniciam-se os pesos com valores aleatórios pequenos;
3   para  $i \leftarrow 1$  a  $X_{tr}$  faça
4     Calcular a ativação de cada neurônio  $j$  na camada escondida:
5      $h_{\zeta} = \sum_{i=0}^L x_i v_{i\zeta}$ 
6      $a(\zeta) = g(h_{\zeta}) = \frac{1}{1+exp(-h_{\zeta})}$ 
7     Calcular entrada da camada de saída:
8      $h_{\kappa} = \sum_j a_j w_{j\kappa}$ 
9      $y(\kappa) = g(h_{\kappa}) = \frac{1}{1+exp(-h_{\kappa})}$ 
10    Calcular o erro da saída:
11     $\delta_o(\kappa) = (y_{\kappa} - t_{\kappa}) y_{\kappa} (1 - y_{\kappa})$ 
12    Calcular o erro da camada escondida:
13     $\delta_{\zeta} = a_{\zeta} (1 - a_{\zeta}) \sum_{k=1}^N w_{\zeta} \delta_o(k)$ 
14    Atualizar os pesos da camada de saída:
15     $w_{\zeta\kappa} = w_{\zeta\kappa} - \eta \delta_o(\kappa) a_{\zeta}^{escondida}$ 
16    Atualizar os pesos da camada escondida:
17     $v_l = v_l - \eta \delta_h(\kappa) x_l$ 
18 fim
19 fim
```

Outro parâmetro variável relacionado à redes neurais são as funções de ativação, geralmente presentes nas camadas escondidas e de saída. Exemplos de funções: sigmoide

(Equação 2.6), tangente hiperbólica (Equação 2.7) e linear. A referencia da notação matemática das funções de ativação é (MARS LAND, 2015).

$$g_1(x) = \frac{1}{1 + \exp(-x)} \quad (2.6)$$

$$g_2(x) = \tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (2.7)$$

2.3 Modelos de Predição Aplicados à Aquisição de Habilidade Motora

Atualmente, estudos de diversas áreas como ciência, tecnologia, comércio tem gerado uma quantidade massiva de dados. A análise destes dados tem sido mais complexa e com custo computacional mais árduo (JORDAN; MITCHELL, 2015).

Há uma grande diversidade de técnicas de reabilitação motora clássicas e recém descobertas, porém em todas estas o período de prática é determinado de forma não arbitrária, ou seja, o paciente realiza o treinamento motor sem uma projeção com uma boa aproximação de quando alcançará um determinado limiar de aptidão na tarefa.

Lin et al. (2018) fez a predição de atividades do cotidiano de pacientes iniciando a reabilitação pós Acidente Vascular Cerebral – AVC. Utilizando uma base de dados de um hospital em Taiwan entre 2014 e 2016, eles buscaram prever o índice Barthel utilizando algoritmos de aprendizado de máquina. O índice Barthel é um índice de atividades do dia a dia que um paciente consegue fazer, ou seja, seu nível de independência em tarefas cotidianas (HSUEH et al., 2002). Lin et al. (2018) conseguiu uma boa predição com os algoritmos Máquina com Suporte Vetorial - SVM e Regressão Linear, com erro absoluto médio aceitável e próximo para os dois algoritmos. O Coeficiente de Determinação apresentou uma correlação moderada ($r^2 = 0.57$) para os dois algoritmos.

No trabalho Hahne et al. (2014), os autores utilizaram técnicas de regressão linear e não linear para o controle mioelétrico independente, simultâneo e proporcional de próteses com 2 graus de liberdade. As próteses são geralmente aplicadas em pacientes com membros amputados, então estes tem que adquirir com o tempo a habilidade motora de controlá-las. Foram usadas as técnicas: Regressão Linear - LR, Perceptrons de Múltiplas Camadas - MLP, Regressão Kernel Ridge - KRR e Mistura de Especialistas Lineares - ME (técnica inspirada na regressão linear). A originalidade do trabalho deve-se à, segundo o conhecimento dos autores, a KRR e ME não terem sido utilizados em trabalhos anteriores para a mesma tarefa. Como resultado foi mostrado que ME é promissor para o controle de próteses com 2 graus de liberdade devido o bom ajuste aos comandos e custo computacional baixo, que requer menor complexidade de hardware.

CAPÍTULO 3

METODOLOGIA

3.1 Participantes

Os participantes deste experimento serão estudantes, docentes e técnicos da Universidade Federal do Maranhão. Inicialmente um grupo de 3 pessoas saudáveis, ou seja, pessoas sem restrição motora irá ser voluntário no experimento. Todos os participantes devem fornecer autorização por escrito, a fim de que seus dados possam ser usados em uma publicação enquanto que ao mesmo tempo este trabalho manterá a confidencialidade dos participantes.

Serão aplicado aos participantes o questionário "*Edinburgh Handedness Inventory*" (ESPÍRITO-SANTO et al., 2017). Este questionário é usado para saber a mão com a qual o indivíduo realiza a maioria das atividades. Serão considerados neste estudo os participantes que utilizam frequentemente apenas a mão direita.

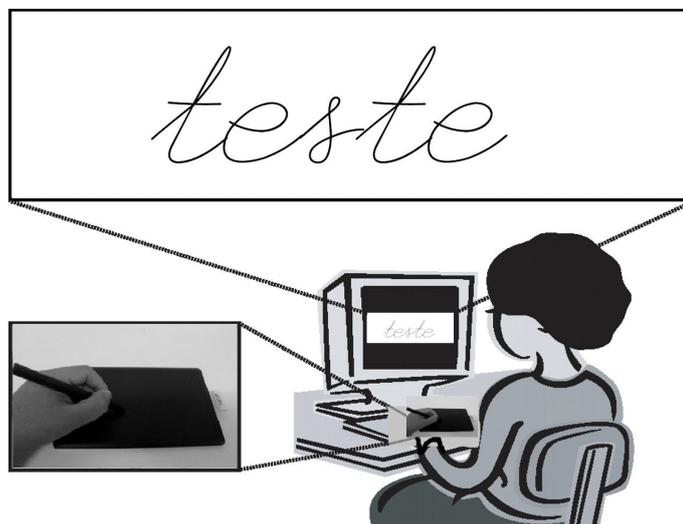
Para a seleção dos participantes, também será realizado um histórico neurológico, onde perguntou-se para os candidatos a participantes do experimento se este tem ou já teve epilepsia, depressão, acidente vascular cerebral ou mesmo acidente em que a cabeça tenha sido atingida a ponto de precisar intervenção cirúrgica, consumo de entorpecentes, frequência de consumo de bebida alcoólica, ou mesmo qualquer sintoma neurológico que poderia ocasionar uma alteração de sua performance motora. Os candidatos que apresentarem algum destes citados anteriormente serão excluídos deste estudo.

3.2 Desenho Experimental

Foi criado um software - por outro aluno do projeto - para a tarefa de traçado com o *Framework* "Pygame" (SHINNERS, 2011) da linguagem de programação Python (ROSSUM, 1995) com base no experimento proposto por Prichard et al. (2014). Aos

participantes é requerido que tracem uma série de palavras com o auxílio de uma mesa digitalizadora Wacom com a sua mão esquerda. A tarefa a ser utilizada para o treinamento motor neste trabalho é a "Tracing Task", que pode ser melhor ilustrada na Figura 1.

Figura 1: Tracing Task



Para controlar um cursor na tela o participante movimenta a caneta sob a mesa digitalizadora. O participante tenta reproduzir com a caneta na mesa digitalizadora a palavra disposta na tela. O erro percentual é usado para determinar uma medida de habilidade.

Fonte: Baseado em Reis et al. (2009).

As palavras utilizadas serão escolhidas de uma base de dados gratuita (Invoke IT Limited ¹). São as palavras mais comuns de 5 letras do idioma Português do Brasil. As palavras foram escritas com uma fonte cursiva gratuita (League Script ²).

A métrica extraída da tarefa de traçado é o erro percentual da diferença entre a imagem de fundo e a imagem traçada pelo participante. Ambas imagens passaram por um processo de borragem para que os participantes que não acertarem perfeitamente a forma do desenho não sejam prejudicados. O processo de borragem consiste em realizar a convolução da imagem com um *kernel* Gaussiano de tamanho 50×50 pixels. A Figura 2 ilustra o processamento feito nas imagens.

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 do projeto (CARVALHO, 2018).

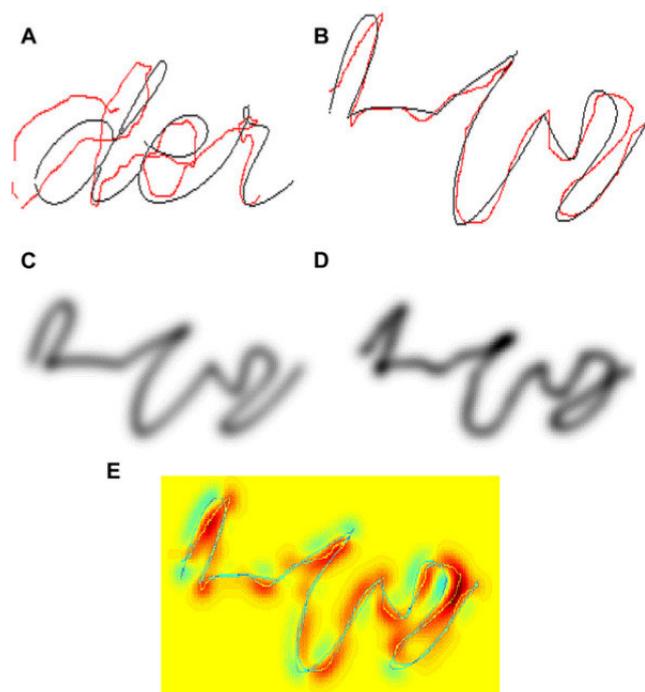
Cada participante fará uma seção. A seção consiste em 3 blocos cada um com 10 "trials". Os participantes serão submetidos aos mesmos exemplos de "trials".

Após a aquisição dos dados, estes foram formatados em Valor Separados por Vírgulas - CSV (do inglês, "Comma Separated Value") para que possam ser feitos o

¹ <http://invokeit.wordpress.com/frequency-word-lists/>

² www.theleagueofmoveabletype.com

Figura 2: Método de captura do erro na tarefa "Tracing Task"



A e B são exemplos de "trials". Podem ser utilizadas como "trials" tanto palavras como em A quanto aproximações de palavras como em B. Em C temos a figura B borrada conforme o método descrito anteriormente. Em D temos o traçado que foi feito sob a figura B borrado. Em E temos uma imagem da subtração pixel a pixel da imagem C da D. Se o traçado for feito na região amarela ou não for feito nenhum traçado o erro é máximo. Se o traçado for feito tanto na região azul quanto na região vermelha será considerado acerto e não haverá acréscimo no erro percentual.

Fonte: Prichard et al. (2014).

processamento e a análise. O formato CSV foi escolhido pela simplicidade e por ser largamente utilizado em análises estatísticas.

3.3 Amostras Complementares

Amostras complementares foram criadas a partir das obtidas pelo experimento a fim de utilizar satisfatoriamente os modelos de regressão. Essas amostras foram referentes ao desempenho médio dos três blocos, para as duas medidas de desempenho: tempo e erro percentual.

A partir do dado real, soma-se a este um ruído gaussiano com média zero e desvio padrão 0.01 (valor definido com base na magnitude dos dados). Foram gerados 18 participantes com base nos três participantes reais para os três blocos, a saber, seis participantes com base em cada participante real.

3.4 Modelos de Regressão

Todos os métodos de predição utilizados são provenientes do Software "Weka", referenciado por Frank, Hall e Witten (2016). O "Weka" é uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados, neste pode-se realizar pré-processamento, classificação, regressão, agrupamento, regras de associação e visualização.

Os parâmetros utilizados para os algoritmos foram:

- Regressão Linear:
 - Variáveis Preditoras: Erro Percentual Médio e Tempo Médio;
 - Variável de Resposta: Bloco;
 - Parâmetros Weka: `weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4;`

- Regressão baseada no KNN:
 - Variáveis Preditoras: Erro Percentual Médio e Tempo Médio;
 - Variável de Resposta: Bloco;
 - Quantidade de Vizinhos: 1;
 - Distância: Manhattan;
 - Parâmetros Weka: `weka.classifiers.lazy.IBk -K 1 -W 0 -A "weka.core.neighboursearch.LinearNNSearch -A "weka.core.ManhattanDistance -R first-last;`

- Rede Neural Artificial MLP:
 - Variáveis Preditoras: Erro Percentual Médio e Tempo Médio;
 - Variável de Resposta: Bloco;
 - Função de Ativação: Sigmoide;
 - Camada escondida: 2 neurônios;
 - Épocas: 1000000
 - Constante de Aprendizagem: 0.05;
 - Parâmetros Weka: `weka.classifiers.functions.MultilayerPerceptron -L 0.05 -M 0.01 -N 1000000 -V 0 -S 0 -E 20 -H t;`

3.5 Validação

Para avaliação do desempenho da predição foi aplicada a validação cruzada "k-fold" com 5 folds. Isso foi feito para manter o conjunto de treinamento e teste o mais balanceados possível, conforme é feito em Hahne et al. (2014) e Lemm et al. (2011).

A validação "k-fold", segundo Norvig e Russell (2014), pode ser usada para obter uma estimativa precisa do desempenho de uma técnica. A ideal central é a de um mesmo exemplo servir tanto para treinamento quanto para teste. A base de dados é dividida em k-conjuntos de igual tamanho. Realizam-se k rodadas de treinamento em que $\frac{1}{k}$ dos dados servem para teste e os demais para treinamento. A estimativa final é a média do valor obtido nas k rodadas. Segundo Norvig e Russell (2014), valores populares de k são 5 e 10, suficientes para apresentar uma estimativa estatisticamente provável que seja precisa.

O desempenho é avaliado a partir do conjunto de teste. A métrica utilizada para avaliar o desempenho é o valor do Coeficiente de Determinação dado pela Equação 3.1.

$$r^2 = 1 - \frac{\sum_d Var(y^d - \hat{y}^d)}{\sum_d Var(y^d)} \quad (3.1)$$

Na Equação 3.1, y representa a quantidade de blocos, d representa os participantes, y^d é o conjunto das quantidades de blocos medidas no experimento. \hat{y}^d é o conjunto das quantidades de blocos estimadas pelos modelos utilizados. O numerador consiste no erro quadrático médio da predição normalizado pelo denominador que é a variância do conjunto das quantidades de blocos medidas no experimento. O valor máximo do Coeficiente de Determinação é 1 e significa que a estimação foi perfeita.

Outra métrica utilizada foi a Raiz do Erro Médio Quadrático denotada pela Equação 3.2. O RMSE representa o desvio médio da predição em relação à quantidade de blocos real.

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (y^d - \hat{y}^d)^2}{n}} \quad (3.2)$$

CAPÍTULO 4

RESULTADOS E DISCUSSÃO

4.1 Experimento Piloto

Um experimento de "Prova de Conceito" foi realizado com 3 participantes com o objetivo de extrair um tempo médio por letra para um futuro experimento de forma que as "*trials*" fiquem difíceis porém factíveis conforme Prichard et al. (2014). Outro objetivo deste experimento é observar a característica do aperfeiçoamento motor na tarefa "Tracing Task" realizada.

O experimento teve a seguinte configuração: 1 seção; a seção teve 3 blocos; cada bloco continha 10 "*trials*" de palavras com 5 letras. O tempo será capturado após a conclusão de cada "*trial*". Foi capturado também o erro percentual conforme foi descrito na Seção 3.

O cálculo do tempo médio por letra com base no experimento é descrito pela Equação 4.1. Neste trabalho considerou-se o tempo médio por letra como a média do tempo por letra do bloco de todas as "*trials*" realizadas.

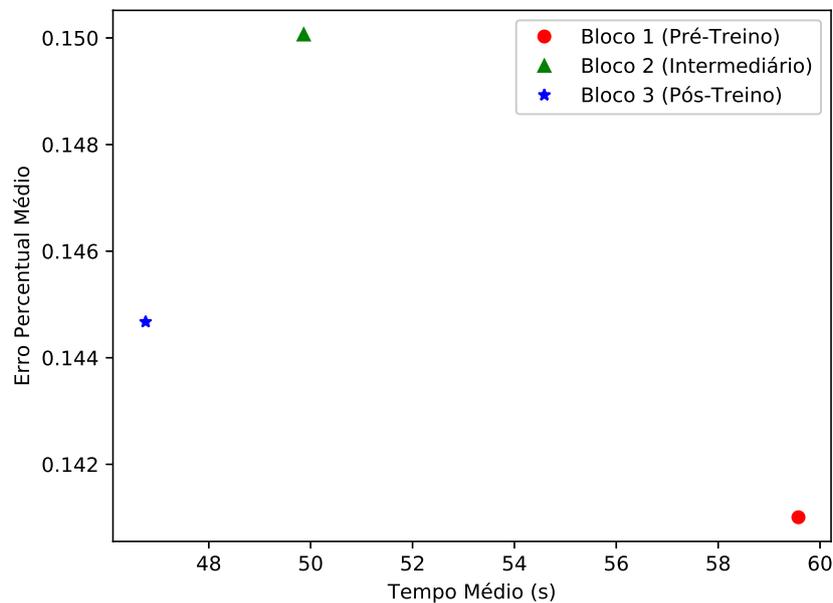
$$t_{letra} = \frac{\sum_{i=1}^{num_{trials}} t_{palavra}(i)}{tam_{palavra} * num_{trials}} \quad (4.1)$$

Na Equação 4.1, t_{letra} corresponde ao tempo por letra a ser utilizado no experimento final. Para calcular este tempo foram utilizados número de "*trials*" (num_{trials}), o tempo por palavra ($t_{palavra}$) e o tamanho da palavra ($tam_{palavra}$) medido em quantidade de letras. O tempo médio obtido através deste experimento foi de 10.41 segundos, então, através do arredondamento, será utilizado o tempo igual a 10 segundos por letra no experimento final.

A característica do aperfeiçoamento motor pode ser observada na Figura 3.

Segundo Kitago e Krakauer (2013) e Reis et al. (2009), o aprendizado motor ocorre quando há um equilíbrio entre velocidade e acurácia na execução de um movimento ou

Figura 3: Aperfeiçoamento Motor



O ponto vermelho representa o desempenho médio dos participantes no Bloco 1 (Pré-Treino). O triângulo verde representa o desempenho médio dos participantes no Bloco 2 (Intermediário). A estrela azul representa o desempenho médio dos participantes no Bloco 3 (Pós-Treino). O desempenho médio é uma função do tempo médio de movimento (abscissa) e o erro percentual médio por bloco (ordenadas).

Fonte: Próprio autor.

tarefa. O aperfeiçoamento motor é uma característica do aprendizado motor cuja ocorrência pode ser percebida quando tem-se uma diminuição do tempo e do erro de execução de uma tarefa depois de um período de prática.

Na Figura 3, pode-se perceber que há um aperfeiçoamento motor comparando o Pré-Treino com o Pós-Treino. No Pré-Treino, os participantes tiveram em média um erro percentual pequeno porém o tempo médio de execução foi grande em relação aos demais blocos. No Intermediário os participantes diminuíram o tempo médio porém aumentaram o erro percentual médio. No Pós-Treino é possível observar um balanceamento entre tempo e erro percentual médio de execução da tarefa.

Por estes aspectos pode-se deduzir qualitativamente que houve um aperfeiçoamento motor entre o Bloco 1 e Bloco 3, corroborando com a literatura a respeito do tema. Para uma conclusão quantitativa, será necessário mais participantes e um treinamento mais prolongado, porém os resultados foram importantes a título de prova de conceito.

4.2 Análise Comparativa dos Modelos de Regressão

Com as amostras complementares, foram criadas 2 bases de dados com 9 e 18 participantes, respectivamente. Cada modelo de regressão foi testado para ambas as bases,

Experimento	Fatores		Variáveis de Resposta	
	Algoritmo(A)	Participantes(B)	r^2 (Y)	RMSE(Y)
1	Regressão Linear	9	0,1707	0,8170
2	Regressão Linear	18	0,4352	0,7353
3	MLP	9	0,2134	1,0209
4	MLP	18	0,5457	0,7335
5	KNN	9	0,2942	0,8114
6	KNN	18	0,7300	0,6086

Tabela 1: Resultados dos Modelos de Regressão

sendo apresentados na Tabela 1 o resultado médio da validação cruzada k-fold com 5 folds para as 2 métricas de avaliação: Coeficiente de Determinação (r^2) e RMSE.

Pode-se perceber ao analisar a Tabela 1 que o Algoritmo de Regressão baseado no KNN obteve melhor performance tanto no tocante do Coeficiente de Determinação quanto no RMSE. O Coeficiente de Correlação igual a 0,73 é considerado como uma Correlação Forte, segundo os indicadores de Mukaka (2012). Este mostra-se satisfatório visto que em Lin et al. (2018) obteve-se correlação moderada para um problema semelhante.

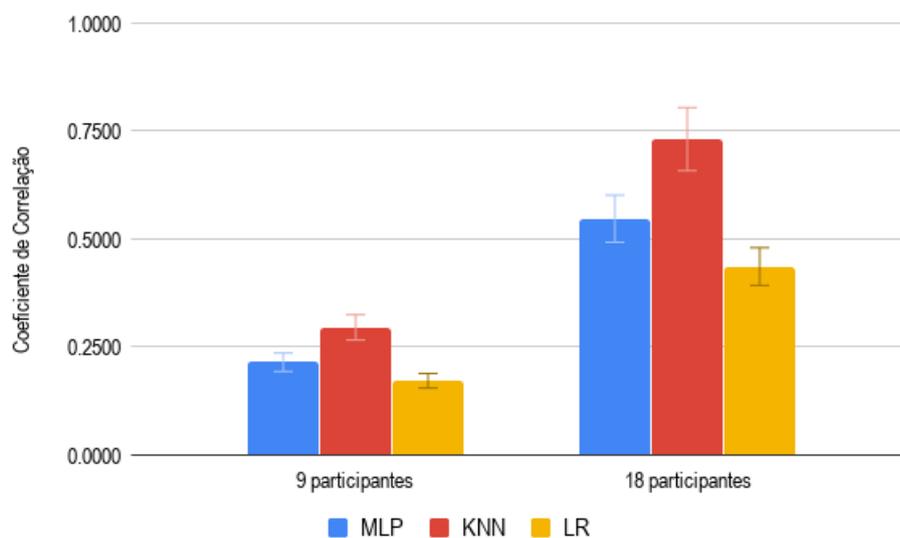
Os melhores resultados ocorreram nas bases com 18 participantes, evidenciando assim a carência de dados para uma boa predição. Com 18 participantes obteve-se um coeficiente de correlação forte, assim estima-se que seja um limiar de base para um futuro experimento com dados em que todos os participantes serão reais.

Nas Figura 4 e 5 observa-se gráficos de barras do Coeficiente de Determinação e do RMSE, respectivamente, para as três técnicas e para as bases de 9 e 18 participantes. As barras azuis representam o coeficiente de correlação da Rede Neural Artificial MLP. As barras vermelhas representam o coeficiente de correlação da Regressão baseada no KNN. As barras amarelas representam o coeficiente de determinação da Regressão Linear. As barras de erro representam 10% do valor do Coeficiente de Correlação e do RMSE para fins de comparação, respectivamente.

Pode-se perceber na Figura 4 que para a Rede Neural MLP é um pouco melhor que a Regressão Linear, sendo os dois superados pelo KNN tanto para a base de 9 participantes quanto para a de 18 participantes. Para a base de 9 participantes, todos os coeficientes de determinação foram abaixo de 0,30, o que indica correlação insignificante segundo Mukaka (2012). Para a base de 18 participantes, a Regressão Linear apresentou correlação baixa, a Rede Neural MLP correlação moderada e a Regressão baseada no KNN apresentou correlação forte.

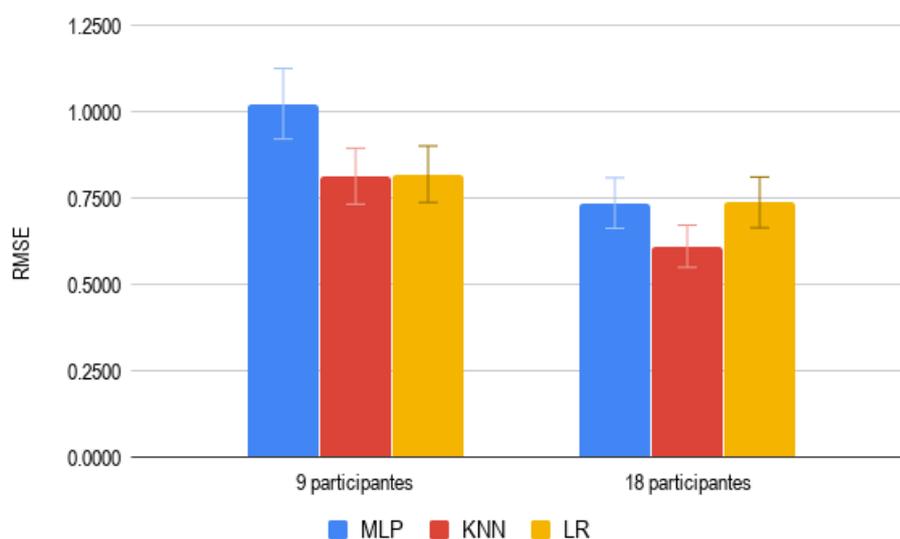
Na Figura 5 observa-se que não há diferença entre o RMSE da Regressão baseada no KNN e da Regressão Linear para a base de 9 participantes, enquanto que o RMSE da Rede Neural MLP é maior que estes para a mesma base. Para a base de 18 participantes a

Figura 4: Coeficiente de Determinação



Fonte: Próprio autor

Figura 5: Raiz do Erro Médio Quadrático



Fonte: Próprio autor

Regressão baseada no KNN apresenta RMSE menor que as demais, que não apresentam diferença entre si. É possível notar também que o RMSE da base de 18 participantes é menor que a de 9 participantes.

CAPÍTULO 5

CONSIDERAÇÕES FINAIS

O objetivo principal deste trabalho foi encontrar uma correlação entre o tempo de movimento e o erro percentual com a quantidade de blocos em uma seção de aquisição de habilidade motora, no caso específico da tarefa "Tracing Task" de Prichard et al. (2014).

Durante esta pesquisa foi elaborado um experimento junto ao grupo de pesquisa com a finalidade de encontrar características do aprendizado motor em pessoas saudáveis. Para isto foi feito o experimento da tarefa "Tracing Task" e conseguiu-se observar mesmo com poucas amostras a característica do Aperfeiçoamento Motor.

A partir da geração de novas amostras através da adição de ruídos gaussianos com média zero e desvio padrão fixo foram concebidas 2 bases de dados, com 9 e 18 participantes. Através desses dados simulados foi possível aplicar técnicas de regressão visando correlacionar o tempo de movimento e o erro percentual com a quantidade de blocos. Com o modelo de Regressão baseada no KNN conseguiu-se um coeficiente de determinação igual 0,73, que indica correlação forte segundo Mukaka (2012). Este resultado é coerente com o presente na literatura atual, no trabalho Lin et al. (2018), em que tem-se uma aplicação semelhante.

O modelo mais eficiente para o problema deste trabalho foi a Regressão baseada no KNN, seguida pela Rede Neural MLP e por último a Regressão Linear. Futuramente outras técnicas podem ser testadas como Regressão com Suporte Vetorial - SVR, Regressão Kernel Ridge - KRR e Métodos Especialistas - ME, referenciados na literatura.

Como trabalhos futuros pretende-se fazer o experimento, outrora simulado com 18 participantes, com 20 participantes reais e saudáveis. Pretende-se testar mais técnicas e compará-las ao desempenho da Regressão baseada no KNN. Ao confirmar a correlação para pessoas saudáveis o conceito poderá ser estendida a pacientes de doenças neurológicas que sofreram dano motor, porém não perderam a capacidade de aprendizagem motora.

Um exemplo presente em Kitago e Krakauer (2013) é a hemiparesia leve. Esta técnica também pode vir a ser utilizada para a predição de progresso da coordenação motora fina para fins pedagógicos.

REFERÊNCIAS BIBLIOGRÁFICAS

ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, Taylor & Francis, v. 46, n. 3, p. 175–185, 1992. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/00031305.1992.10475879>>. Nenhuma citação no texto.

CARVALHO, M. B. F. de. *Plataforma de Avaliação do Aprendizado de Habilidade Motora Automatizada*. 2018. Nenhuma citação no texto.

ESPÍRITO-SANTO, H.; PIRES, C. F.; GARCIA, I. Q.; DANIEL, F.; SILVA, A. G. d.; FAZIO, R. L. Preliminary validation of the portuguese edinburgh handedness inventory in an adult sample. *Applied Neuropsychology: Adult*, Taylor & Francis, v. 24, n. 3, p. 275–287, 2017. Nenhuma citação no texto.

FRANK, E.; HALL, M.; WITTEN, I. The weka workbench. *Data mining: Practical machine learning tools and techniques*, Morgan Kaufmann MA, US, v. 4, 2016. Nenhuma citação no texto.

GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. 3. ed. [S.l.]: Pearson Education, 2010. Nenhuma citação no texto.

HAHNE, J. M.; BIESSMANN, F.; JIANG, N.; REHBAUM, H.; FARINA, D.; MEINECKE, F.; MÜLLER, K.-R.; PARRA, L. Linear and nonlinear regression techniques for simultaneous and proportional myoelectric control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 22, n. 2, p. 269–279, 2014. Nenhuma citação no texto.

HALLETT, M.; GRAFMAN, J. Executive function and motor skill learning. *International review of neurobiology*, Elsevier, v. 41, p. 297–323, 1997. Nenhuma citação no texto.

HAYKIN, S. *Neural networks: A comprehensive foundation*. v. 2, n. 2004, p. 41, 2004. Nenhuma citação no texto.

HSUEH, P.; LIN, J.-H.; JENG, J.-S.; HSIEH, C.-L. Comparison of the psychometric characteristics of the functional independence measure, 5 item barthel index, and 10 item barthel index in patients with stroke. *Journal of Neurology, Neurosurgery & Psychiatry*, BMJ Publishing Group Ltd, v. 73, n. 2, p. 188–190, 2002. Nenhuma citação no texto.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. *Science*, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015. Nenhuma citação no texto.

KARNI, A.; MEYER, G.; REY-HIPOLITO, C.; JEZZARD, P.; ADAMS, M. M.; TURNER, R.; UNGERLEIDER, L. G. The acquisition of skilled motor performance: fast and slow experience-driven changes in primary motor cortex. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 95, n. 3, p. 861–868, 1998. Nenhuma citação no texto.

KITAGO, T.; KRAKAUER, J. W. Motor learning principles for neurorehabilitation. *Handb Clin Neurol*, v. 110, p. 93–103, 2013. Nenhuma citação no texto.

KORMAN, M.; RAZ, N.; FLASH, T.; KARNI, A. Multiple shifts in the representation of a motor sequence during the acquisition of skilled performance. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 100, n. 21, p. 12492–12497, 2003. Nenhuma citação no texto.

KRAKAUER, J. W. Motor learning: its relevance to stroke recovery and neurorehabilitation. *Current Opinion in Neurology*, Lippincott Williams and Wilkins, v. 19, 02 2006. Nenhuma citação no texto.

LEMM, S.; BLANKERTZ, B.; DICKHAUS, T.; MÜLLER, K.-R. Introduction to machine learning for brain imaging. *Neuroimage*, Elsevier, v. 56, n. 2, p. 387–399, 2011. Nenhuma citação no texto.

LIN, W.-Y.; CHEN, C.-H.; TSENG, Y.-J.; TSAI, Y.-T.; CHANG, C.-Y.; WANG, H.-Y.; CHEN, C.-K. Predicting post-stroke activities of daily living through a machine learning-based approach on initiating rehabilitation. *International Journal of Medical Informatics*, Elsevier, 2018. Nenhuma citação no texto.

MARSLAND, S. *Machine learning: an algorithmic perspective*. [S.l.]: CRC press, 2015. Nenhuma citação no texto.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. *Introduction to linear regression analysis*. [S.l.]: John Wiley & Sons, 2015. Nenhuma citação no texto.

MUKAKA, M. M. A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, Medical Association of Malawi, v. 24, n. 3, p. 69–71, 2012. Nenhuma citação no texto.

NORVIG, P.; RUSSELL, S. *Inteligência Artificial*. 3. ed. [S.l.]: Elsevier Brasil, 2014. Nenhuma citação no texto.

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. Nenhuma citação no texto.

REIS, J.; SCHAMBRA, H. M.; COHEN, L. G.; BUCH, E. R.; FRITSCH, B.; ZARAHN, E.; CELNIK, P. A.; KRAKAUER, J. W. Noninvasive cortical stimulation enhances motor skill acquisition over multiple days through an effect on consolidation. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 106, n. 5, p. 1590–1595, 2009. Nenhuma citação no texto.

ROSSUM, G. *Python Reference Manual*. Amsterdam, The Netherlands, The Netherlands, 1995. Nenhuma citação no texto.

SHINNERS, P. *PyGame*. 2011. <http://pygame.org/>. Nenhuma citação no texto.

SHMUELOF, L.; KRAKAUER, J. W. Recent insights into perceptual and motor skill learning. *Frontiers in human neuroscience*, Frontiers Media SA, v. 8, 2014. Nenhuma citação no texto.

SILVA, L. A. da; PERES, S. M.; BOSCARIOLI, C. *Introdução à mineração de dados: com aplicações em R*. [S.l.]: Elsevier Brasil, 2017. Nenhuma citação no texto.