

Evaluating User Gestures in Rehabilitation from Electromyographic Signals

T. V. V. Batista, R. M. Moraes, L. S. Machado and A. M. G. Valença

Abstract— One of the strategies being used over the last years to increase the user commitment and motivation on rehabilitation systems is the use of virtual reality (VR) environments. In addition to contributing to motivation, these systems can simulate real life activities and provide means to measure and evaluate user performance. The use of natural interaction devices originally conceived to the game market allowed the development of low-cost and minimally invasive systems. With the advent of interaction devices based on electromyography, the electromyographic signals of the user can also be used on the natural interaction process. This work has the goal of verifying if, by using an evaluation model, is possible to evaluate user performance in real time through gesture recognition by means of an electromyography device attached to a rehabilitation system.

Keywords— Natural Interaction, Rehabilitation, Neural Networks, Electromyography, Fuzzy Logic.

I. INTRODUÇÃO

ACIDENTE Vascular Cerebral (AVC) é um problema de saúde de ocorrência mundial. Em 2014, 6.7 milhões mortes por AVC foram relatadas no mundo inteiro [1]. O AVC é causado pela interrupção do suprimento de oxigênio para o cérebro, normalmente resultante do rompimento de uma artéria ou entupimento da mesma por coágulos, resultando em danos ao tecido cerebral. Embora não seja uma doença necessariamente fatal, o AVC causa graves sequelas ao paciente e é uma das patologias que mais incapacitam para a realização de atividades cotidianas.

Os membros superiores são umas das principais estruturas atingidas após o AVC [2], afetando diretamente a qualidade de vida do paciente. Particularmente, destacam-se as restrições geradas aos movimentos das mãos, que comprometem a execução de tarefas comuns do dia-a-dia, como segurar um talher ou levantar uma xícara. De forma geral, várias sessões de fisioterapia são necessárias para recuperar os movimentos dos membros atingidos, requerendo do paciente a execução de séries de movimentos repetitivos. Devido a esta característica do tratamento, manter o interesse do paciente é uma tarefa difícil, o que pode levar à interrupção do tratamento ou a ausências nas sessões de fisioterapia, tornando o tratamento ineficiente e causando frustração ao paciente [3].

Nos últimos anos, uma das estratégias que vem sendo

utilizadas para aumentar o grau de comprometimento e motivação dos usuários é a criação de ambientes baseados em realidade virtual (RV). Além de proporcionarem a motivação, estes sistemas simulam atividades da vida real e proveem meios de medir e avaliar automaticamente a performance do paciente [4].

No entanto, para serem capazes de fornecer uma avaliação automática da performance do usuário, o sistema precisa incorporar dispositivos de rastreamento de movimento, como rastreadores magnéticos, óticos ou exoesqueletos [5]. Tais equipamentos normalmente requerem que o usuário vista sensores ou roupas especiais, inserindo aspectos relacionados ao conforto, à higiene e à segurança do usuário, que podem comprometer a experiência do usuário e onerar os custos do sistema.

Com a introdução de dispositivos comerciais de interação natural no mercado, foi possível o desenvolvimento de sistemas de reabilitação com baixo custo e pouco invasivos. O Kinect, por exemplo, que foi desenvolvido inicialmente para ser um periférico para o console de jogos XBox, foi utilizado para rastreamento de expressões e reconhecimento de gestos em diferentes aplicações de saúde [6].

Dispositivos baseados em eletromiografia de superfície (sEMG) são uma alternativa aos dispositivos comumente utilizados em ambientes de reabilitação de mãos, como as luvas de dados e os baseados em sensores óticos, por fornecerem uma maneira não invasiva, barata e segura para detecção de movimentos através da interpretação dos sinais elétricos que são gerados pelos músculos humanos.

Um dos dispositivos de sEMG recém-desenvolvidos é o Myo, um dispositivo de captura de sinais eletromiográficos de relativo baixo custo (em torno de 150 dólares) que permite a captura de sinais elétricos musculares e uma posterior interpretação destes dados em um gesto. Da mesma forma que o Kinect, este dispositivo não foi desenvolvido especificamente para ser usado em aplicações de reabilitação e fornece um conjunto limitado de gestos reconhecidos de forma automática, o que dificulta seu uso em aplicações desta natureza. O Myo, no entanto, possui uma biblioteca de programação que fornece os dados eletromiográficos originais capturados pelos sensores.

O objetivo deste trabalho é verificar se, através da utilização de um modelo de avaliação, é possível a incorporação de dispositivos de eletromiografia de baixo custo a sistemas de reabilitação a fim de fornecer feedback imediato ao usuário. Deseja-se verificar, principalmente, se os dados fornecidos pelo dispositivo utilizado neste trabalho podem ser interpretados por um modelo de avaliação de forma adequada, além de aspectos relacionados à calibração e à utilização do dispositivo. Pretende-se, desta forma, verificar a possibilidade

T. V. V. Batista, Universidade Federal da Paraíba, João Pessoa, PB, Brasil, thiagovvb@gmail.com

R. M. Moraes, Universidade Federal da Paraíba, João Pessoa, PB, Brasil, ronei@de.ufpb.br

L. S. Machado, Universidade Federal da Paraíba, João Pessoa, PB, Brasil, liliane@di.ufpb.br

A. M. G. Valença, Universidade Federal da Paraíba, João Pessoa, PB, Brasil, anamvalenca@gmail.com

de desenvolvimento futuro de um sistema de reabilitação para mãos em pacientes que sofreram AVC ou outras doenças que causam problemas motores.

II. INTERAÇÃO NATURAL E DETECÇÃO DE MOVIMENTO

A interação natural pode ser definida como uma forma mais natural de interação que, diferentemente daquela realizada por meio mouse e teclado, permite a comunicação do usuário com o sistema computacional através de gestos, expressões e movimentos [7]. A interação natural permite a abertura de um canal de comunicação direto entre o usuário e o mundo digital.

Uma das áreas mais importantes no que concerne a interação natural é a captura de movimento (MoCap), que consiste em rastrear os movimentos do usuário através de dispositivos de rastreamento. Em ambientes para reabilitação, é importante o monitoramento e a avaliação dos movimentos sendo realizados pelo usuário, portanto a captura de movimento se torna parte integrante destes sistemas [8].

Zhou [8] classificou as técnicas de captura de movimento em três categorias principais, como ilustrado na Fig. 1.




Figura 1. Classificação dos tipos de captura de movimento. Adaptado de Zhou [8].

O rastreamento assistido por robô é feito utilizando estruturas que são "vestidas" pelo usuário, similares a um exoesqueleto. A utilização deste sistema em aplicações de reabilitação provê tratamento repetitivo, específico e interativo. Com dispositivos robóticos, pacientes tem um maior ganho com tratamento de reabilitação, pois é mais fácil controlar e monitorar o progresso do paciente [9]. No entanto, estes sistemas são caros e difíceis de serem construídos, além de serem pouco adaptáveis, visto que são sistemas bastante específicos, sendo capazes de modelar um conjunto não muito amplo de situações.

O rastreamento visual utiliza sensores ópticos para rastrear o movimento do usuário. Eles podem ser classificados pelo uso ou não de marcadores no corpo do usuário. O sistema que utiliza marcadores é composto por câmeras que acompanham o movimento destes marcadores. Os sistemas que não utilizam marcadores tem a vantagem de não precisar que o usuário vista roupas especiais ou utilize qualquer tipo de sensor preso ao corpo. Recentemente vários estudos foram divulgados utilizando este tipo de rastreamento, especialmente fazendo uso do dispositivo Kinect, como o trabalho feito por Chang et al. [10], que avaliou a possibilidade do uso deste dispositivo para reabilitação de adultos com problemas motores.

O rastreamento não-visual é feito através da colocação de sensores sobre o corpo do usuário e coletam informações sobre os movimentos realizados no ambiente. Estes sensores podem ser magnéticos, inerciais, ultrassônicos ou mecânicos. Apesar de serem menos limitadores que o rastreamento assistido por robô, prender objetos ao usuário ou requerer que ele segure algum sensor pode comprometer a movimentação do usuário no ambiente.

III. AVALIAÇÃO DO USUÁRIO

Avaliação do usuário em ambientes virtuais de treinamento é importante para medir o nível das habilidades do usuário. Existem diferentes formas de realizar esta avaliação. Uma possível abordagem é a chamada avaliação *off-line*, onde o sistema gera relatórios que podem ser posteriormente analisados por um especialista. A avaliação *on-line* é feita em tempo real, analisando os dados da performance do usuário e fornecendo um *feedback* em tempo real [11]. Em ambientes de reabilitação, é igualmente importante avaliar a performance do usuário para que ele execute os exercícios da maneira correta, para que não ocorra o comprometimento do andamento do tratamento.

De acordo com Moraes e Machado [12], alguns dos benefícios da avaliação *on-line* são a possibilidade do usuário de identificar seus erros e corrigi-los na próxima sessão e a possível utilização dos dados da avaliação para realizar ajustes na dificuldade do nível. Desta forma, podem haver diferentes níveis de dificuldade, representando etapas diferentes do tratamento.

Uma questão importante na criação de ambientes virtuais de reabilitação é a escolha do método de avaliação. Com o avanço computacional dos últimos anos, a utilização de um modelo de avaliação em tempo real em conjunto com ambientes que exigem um maior processamento gráfico e tornou possível [13]. Portanto, é possível a criação de ambientes realistas que ao mesmo tempo forneçam *feedback* imediato ao usuário.

Ainda que muito tenha se avançado na área de computação naquilo que concerne o processamento dos dados, algumas das técnicas de avaliação possuem uma alta complexidade. Portanto, uma seleção cuidadosa do método é necessária, pois ele não deve ser complexo a ponto de comprometer a performance da simulação, nem ter uma baixa precisão, o que comprometeria a avaliação [12].

IV. MATERIAIS E MÉTODOS

Este estudo consistiu na utilização de um sensor de sEMG para captura de sinais eletromiográficos da mão e para tal, um indivíduo realizou uma série de movimentos de pulso. Após uma extração de características do sinal, o software MatLab foi utilizado para realizar a classificação dos dados utilizando o modelo *Adaptive Neuro Fuzzy Inference System* (ANFIS). Nesta seção, serão descritos os recursos e métodos utilizados neste estudo.

A. PARTICIPANTE

Os dados eletromiográficos foram coletados a partir de um indivíduo do sexo masculino de 23 anos sem qualquer deficiência motora ou mental. A coleta foi realizada na Universidade Federal da Paraíba, Brasil.

B. ELETROMIOGRAFIA

A eletromiografia é uma técnica para detecção da atividade elétrica produzida pelos músculos esqueléticos. As duas principais técnicas são as eletromiografias intramuscular e de superfície. A primeira é uma técnica na qual o sensor é inserido no corpo do usuário. Apesar de mais precisa, tem a desvantagem de ser uma técnica invasiva. A eletromiografia de superfície é um método seguro, fácil e não-invasivo para captura dos sinais elétricos dos músculos [14], pois realiza a captura dos sinais elétricos das fibras musculares através de sensores posicionados na pele do usuário.

O dispositivo de captura de sinais eletromiográficos utilizado neste trabalho foi o Myo, desenvolvido e lançado pela Thalmic Labs em 2014 que realiza a captura das atividades bioelétricas dos músculos a partir da superfície da pele e traduz estas informações em um gesto [15].

O dispositivo, que pode ser visualizado na Fig. 2, consiste de um bracelete que deve ser vestido no antebraço, acima do cotovelo, e que possui oito módulos para captura de sinais. Além destes sensores, o Myo possui um giroscópio, um acelerômetro e um magnetômetro para medir a rotação e a movimentação do braço do usuário. O Myo é capaz de reconhecer um pequeno conjunto de gestos, que estão ilustrados na Fig. 2. O bracelete se comunica com as aplicações através de uma interface Bluetooth, que tolera uma distância entre 10 e 15 metros entre o receptor do sinal e o dispositivo. O Myo é de fácil controle, não sofre de limitações de espaço e movimento e demanda pouco esforço físico [16].

Apesar de reconhecer um conjunto limitado de gestos, que é suficiente para aplicações do cotidiano, o potencial do Myo como ferramenta para auxiliar na reabilitação está na capacidade de prover os dados eletromiográficos capturados pelos 8 sensores. Estes dados podem ser processados e avaliados por um modelo de classificação para serem incorporados em um ambiente de reabilitação.

C. GERAÇÃO DOS DADOS

Inicialmente, foram escolhidos 4 exercícios de pulso diferentes para serem classificados: a flexão, extensão e os desvios ulnar e radial. Embora possam parecer similares, estes exercícios são tratados de forma diferente na Fisioterapia e são alguns dos movimentos de pulso descritos por Lippert [17] e ilustrados na Fig. 3. Os exercícios foram realizados vestindo o dispositivo e feitos em um intervalo curto de tempo (inferior a 3s) sempre partindo da posição neutra, com os dados das medições elétricas sendo salvos em um arquivo de texto para posterior análise. Tentou-se realizar os exercícios da mesma forma para propósitos da classificação, no entanto uma variabilidade natural dos dados fornecidos pelo dispositivo é

esperada, visto que dificilmente todos os exercícios foram executados de maneira igual.



Figura 2. Dispositivo utilizado no trabalho e gestos reconhecidos por ele.




Figura 3. Movimentos considerados na análise. Adaptado de Lippert [17].

Para obtenção e gravação dos dados em um arquivo para análise, foi criado um programa na linguagem C++, utilizando o Microsoft Visual Studio em conjunto com a biblioteca padrão do Myo para acessar os dados e exportá-los para o formato desejado.

Foram geradas então, para o conjunto de teste, 360 amostras (90 para cada exercício) e para o conjunto de treinamento foram geradas 120 amostras (30 para cada exercício). As medições foram obtidas sobre um mesmo indivíduo, vestindo o mesmo dispositivo sem retirá-lo para ressincronização ou outra tarefa qualquer. A representação gráfica de uma das amostras para o movimento de extensão está ilustrada na Fig. 4.

D. EXTRAÇÃO DAS CARACTERÍSTICAS

A extração de características é o processo de transformar os dados originais em variáveis chamadas de características, que são utilizadas para treinar o modelo de avaliação [18]. Neste trabalho foi utilizado um método de extração de dados em

que, para cada sensor i , apenas os maiores e os menores valores registrados são utilizados, resultando na criação de duas características para cada sensor.




Figura 4. Sinais eletromiográficos registrados pelos oito sensores para um mesmo exercício de extensão.

Considerando um sinal x de tamanho t , temos que para um sensor i , as características \hat{x}_{min} e \hat{x}_{max} são dadas por:

$$\hat{x}_{min}(i) = \min(x_{1:t}) \quad (1)$$

$$\hat{x}_{max}(i) = \max(x_{1:t}) \quad (2)$$

Como Myo possui 8 sensores e para cada sensor são criadas duas características, são geradas 16 características que são utilizadas para descrever um determinado movimento.

E. MODELO DE AVALIAÇÃO

Para este trabalho, o modelo de avaliação escolhido foi o ANFIS (*Adaptive Neuro Fuzzy Inference System*). O ANFIS é um modelo de integração *fuzzy* baseado na arquitetura de Takagi-Sungeno onde o sistema de inferência *fuzzy* é otimizado através do treinamento com redes neurais artificiais [19].

A lógica *fuzzy* foi desenvolvida para trabalhar com problemas que tratam com dados incertos ou imprecisos, pois em um conjunto *fuzzy*, um elemento pode pertencer parcialmente a um conjunto, diferentemente do que preconiza a lógica clássica. Um sistema de inferência *fuzzy* é, portanto, uma arquitetura que processa um conjunto de variáveis de entrada para uma variável de saída utilizando lógica *fuzzy* através de um conjunto de regras definidas pelos dados do sistema ou modelada pelo conhecimento de um especialista [20]. No entanto, um dos problemas com a lógica *fuzzy* é que não existe um procedimento sistemático para a modelagem das regras utilizadas no sistema de inferência, portanto a integração de redes neurais é uma estratégia interessante do ANFIS, visto que elas tem a habilidade de se adaptar aos dados e se auto organizar como estrutura [21].

Para melhorar a eficiência do treinamento, e alguns problemas existentes ao se utilizar redes neurais, como o problema dos mínimos locais, um algoritmo de aprendizagem híbrido foi criado por este sistema, onde é feita a combinação da abordagem de gradiente descendente e dos mínimos quadrados [19]. O ANFIS possui uma boa capacidade de aprendizado, construção e classificação, além de ser capaz de melhorar a complicada conversão do conhecimento especialista aos sistemas *fuzzy* [22]. Optou-se por este método também pelo fato que, nos testes iniciais, foi o que melhor se comportou na classificação dos dados eletromiográficos.

F. ANÁLISE DOS DADOS

Neste trabalho, foi utilizado o coeficiente de Kappa de Cohen para análise dos dados. O Kappa é uma medida robusta, comumente utilizada em trabalhos científicos como uma medida de associação para descrever e avaliar o grau de concordância entre as classificações [23]. O coeficiente Kappa varia entre 0 e 1, onde 0 significa discordância total, e o 1 significa a total concordância. É um valor padronizado e portanto interpretado da mesma forma em vários estudos. Para Cohen, um valor de Kappa superior a .81 pode ser considerado como quase perfeito [24].

O coeficiente Kappa é comumente calculado sobre as matrizes de confusão (também chamadas de matrizes de concordância). Cada coluna (i, j) dessa matriz indica a quantidade de elementos da classe i que foram classificados como elementos da classe j pelo modelo de decisão.

V. RESULTADOS

Para o processamento dos dados foi utilizada a Fuzzy Logic Toolbox do Matlab, que contém o ANFIS em suas funcionalidades. O sistema foi executado em uma máquina com processador Intel Core i5, 6GB de memória RAM e utilizando o sistema operacional Windows 10. Os resultados foram apresentados na forma de uma matriz de confusão, que expressa a quantidade de casos de teste que foram classificados corretamente, além do coeficiente Kappa.

Os resultados da tabela 1 mostram que o classificador teve um excelente desempenho na validação do próprio conjunto de treinamento, sendo capaz de acertar todos os casos (taxa de acerto de 100.0%), o que corresponde a um coeficiente Kappa de 1. No entanto, este resultado já era esperado visto que este foram os dados sobre os quais o modelo foi treinado.

Os resultados da tabela 2 correspondem a classificação utilizando o conjunto de teste. O modelo de avaliação foi capaz de acertar 344 de 360 casos (taxa de acerto de 95.56%). O que corresponde a um coeficiente Kappa de 0.9407, o que pode ser considerado adequado para um sistema de avaliação em tempo real.

Pode-se dizer que o modelo teve um excelente desempenho na classificação dos movimentos a partir dos sinais eletromiográficos gerados pelo Myo. Em aplicações de reabilitação, a execução correta dos movimentos é essencial para o tratamento, logo, a existência de um sistema avaliador torna-se necessária, visando fornecer uma maior segurança ao

usuário [25]. Pelos resultados obtidos nestes testes iniciais, também pode-se afirmar que o Myo se mostrou uma ferramenta com potencial para ser utilizado em aplicações de reabilitação, visto que é um equipamento leve, simples e que permite uma maior liberdade de movimentos do usuário.

TABELA I.
MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO UTILIZANDO O CONJUNTO DE TREINAMENTO.

	Extensão	Flexão	D. Radial	D. Ulnar
Extensão	30	0	0	0
Flexão	0	30	0	0
D. Radial	0	0	30	0
D. Ulnar	0	0	0	30

TABELA II.
MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO UTILIZANDO O CONJUNTO DE TESTES.

	Extensão	Flexão	D. Radial	D. Ulnar
Extensão	90	0	0	0
Flexão	1	88	1	0
D. Radial	0	2	87	1
D. Ulnar	1	2	8	79

VI. CONCLUSÕES

A utilização de sistemas de interação natural de baixo custo em aplicações de reabilitação traz benefícios tanto para o usuário do sistema como para os profissionais de saúde. Para o paciente, a possibilidade de realizar parte do tratamento em casa reduz os custos e contribui para a manutenção do interesse nos exercícios. Além disso, a utilização de rotinas de avaliação nestes sistemas fornecem feedback instantâneo para o usuário, permitindo a realização dos exercícios sem o acompanhamento constante de um fisioterapeuta.

Neste trabalho, foram realizados testes para verificar a possibilidade de utilização de um dispositivo de sEMG junto a um sistema de reabilitação. Para tal, amostras foram geradas através da captura de sinais eletromiográficos através do dispositivo Myo e após o processamento, foram submetidos a um modelo de avaliação para a identificação de quatro gestos de movimentação de pulso.

Os resultados dos testes mostraram que é possível a utilização de um dispositivo de sEMG para classificação de exercícios de reabilitação. O modelo ANFIS também se mostrou adequado para classificação dos sinais eletromiográficos. Portanto, estes dispositivos podem se tornar uma ferramenta importante no processo de reabilitação de pacientes que sofreram algum problema de saúde que tenha causado o comprometimento de movimentos da mão.

Como trabalho futuro, deseja-se implantar este método de avaliação em um sistema real que utilize um dispositivo de sEMG e realizar testes com uma amostra maior de indivíduos, bem como com um número maior de movimentos.

AGRADECIMENTOS

Os autores agradecem a CAPES e ao CNPq (processo 310561/2012-4) pelo financiamento parcial deste projeto.

REFERÊNCIAS

- [1] WHO, "Global status report on noncommunicable diseases 2014," World Health, p. 176, 2014.
- [2] L. S. Williams, M. Weinberger, L. E. Harris, D. O. Clark, and J. Biller, "Development of a stroke-specific quality of life scale.," *Stroke.*, vol. 30, no. 7, pp. 1362–1369, 1999.
- [3] A. L. Betker, A. Desai, C. Nett, N. Kapadia, and T. Szturm, "Game-based exercises for dynamic short-sitting balance rehabilitation of people with chronic spinal cord and traumatic brain injuries.," *Phys. Ther.*, vol. 87, no. 10, pp. 1389–1398, 2007..
- [4] R. Boian, a. Sharma, C. Han, a. Merians, G. Burdea, S. Adamovich, M. Recce, M. Tremaine, and H. Poizner, "Virtual reality-based post-stroke hand rehabilitation," *Stud. Health Technol. Inform.*, vol. 85, pp. 64–70, 2002.
- [5] B. Lange, C. Y. Chang, E. Suma, B. Newman, A. S. Rizzo, and M. Bolas, "Development and evaluation of low cost game-based balance rehabilitation tool using the microsoft kinect sensor," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2011, pp. 1831–1834, 2011.
- [6] L. Yao, H. Xu, and A. Li, "Kinect-based rehabilitation exercises system: therapist involved approach.," *Biomed. Mater. Eng.*, vol. 24, no. 6, pp. 2611–8, 2014..
- [7] A. Valli, "The design of natural interaction," *Multimed. Tools Appl.*, vol. 38, no. 3, pp. 295–305, 2008..
- [8] H. Zhou and H. Hu, "Human motion tracking for rehabilitation-A survey," *Biomedical Signal Processing and Control*, v. 3, n. 1, p. 1-18, 2008.
- [9] G. B. Prange, M. J. A. Jannink, C. G. M. Groothuis-Oudshoorn, H. J. Hermens, and M. J. IJzerman, "Systematic review of the effect of robot-aided therapy on recovery of the hemiparetic arm after stroke" *Journal of rehabilitation research and development*, v. 43, n. 2, p. 171, 2006.
- [10] Y.-J. Chang, S.-F. Chen, and J.-D. Huang, "A Kinect-based system for physical rehabilitation: A pilot study for young adults with motor disabilities," *Res. Dev. Disabil.*, vol. 32, no. 6, pp. 2566–2570, 2011.
- [11] R. M. Moraes and L. S. Machado, "Psychomotor skills assessment in medical training based on virtual reality using a Weighted Possibilistic approach," *Knowledge-Based Systems*, v. 70, p. 97-102, 2014.
- [12] R. M. Moraes and L. S. Machado, "Assessment Systems for Training Based on Virtual Reality : A Comparison Study", *SBC Journal on 3D Interactive Systems*, v. 3, n. 1, p. 9-16, 2012.
- [13] C. R. Larsen, J. Oestergaard, B. S. Ottesen, and J. L. Soerensen, "The efficacy of virtual reality simulation training in laparoscopy: A systematic review of randomized trials," *Acta Obstet. Gynecol. Scand.*, vol. 91, no. 9, pp. 1015–1028, 2012.
- [14] E. Criswell, "Cram's introduction to surface electromyography" . Jones & Bartlett Publishers, 2010.
- [15] K. Xu, J. Mai, L. He, X. Yan, and Y. Chen, "Surface electromyography of wrist flexors and extensors in children with hemiplegic cerebral palsy.," *PM R*, vol. 7, no. 3, pp. 270–5, 2015.
- [16] M. McCullough, H. Xu, J. Michelson, M. Jackoski, W. Pease, W. Cobb, W. Kalesky, J. Ladd, and B. Williams, "Myo arm," in *Proceedings of the ACM SIGGRAPH Symposium on Applied Perception - SAP '15*, 2015, pp. 107–113.
- [17] L. S. Lippert, "Clinical kinesiology and anatomy". FA Davis, 2011.
- [18] N. Pentreath, "Machine Learning with Spark". Packt Publishing, 2015.
- [19] J.-S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system". *Systems, Man and Cybernetics, IEEE Transactions on*, v. 23, n. 3, p. 665-685, 1993.
- [20] M. H. Kazeminezhad, A. Etemad-Shahidi, and S. J. Mousavi, "Application of fuzzy inference system in the prediction of wave parameters," *Ocean Eng.*, vol. 32, no. 14–15, pp. 1709–1725, 2005.

- [21] F. J. Chang and Y. T. Chang, "Adaptive neuro-fuzzy inference system for prediction of water level in reservoir," *Adv. Water Resour.*, vol. 29, no. 1, pp. 1–10, 2006.
- [22] Y. Lei, Z. He, Y. Zi, and Q. Hu, "Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs," *Mech. Syst. Signal Process.*, vol. 21, pp. 2280–2294, 2007.
- [23] J. Cohen, "A coefficient of agreement for nominal scales," *Educ. Psychol. Meas.*, vol. XX, no. 1, pp. 37–46, 1960.
- [24] M. L. Mchugh, "Interrater reliability : the kappa statistic", *Biochemia Medica*, v. 22, n. 3, pp. 276-282, 2012.
- [25] A. Da Gama and T. Chaves, "Ikapp–A Rehabilitation Support System using Kinect," *Proceedings of the 14th Symposium on Virtual and Augmented Reality*. 2012.



Thiago Vinícius Vieira Batista possui graduação em Ciência da Computação pela Universidade Federal da Paraíba (2015), e atualmente é mestrando pelo Programa de Pós Graduação em Modelos de Decisão e Saúde, na mesma instituição.



Ronei Marcos de Moraes é professor titular do Departamento de Estatística da Universidade Federal da Paraíba. Possui mestrado em Engenharia Elétrica pela Universidade Federal da Paraíba (1992), doutorado em Computação Aplicada pelo Instituto Nacional de Pesquisas Espaciais (1998) e pós-doutorados pela Escola Politécnica da USP (2001) e Université Toulouse III Paul Sabatier (2013).



Liliane dos Santos Machado é professora associada do Departamento de Informática da Universidade Federal da Paraíba. Possui mestrado em Computação Aplicada pelo Instituto Nacional de Pesquisas Espaciais (1997), doutorado em Engenharia Elétrica pela Universidade de São Paulo em 2003 e pós-doutorado pela Université Toulouse III Paul Sabatier (2013).



(1996).

Ana Maria Gondim Valença é professora titular do Departamento de Clínica e Odontologia Social da Universidade Federal da Paraíba. Possui mestrado em Odontologia (Odontopediatria) pela Universidade Federal do Rio de Janeiro (1987) e doutorado em Odontologia (Odontologia Social) pela Universidade Federal Fluminense