

Sistema de avaliação para reabilitação da mão utilizando processamento de imagens de profundidade

J.V.F. de Souza¹ and M.C.F. Castro¹

¹ Centro Universitário FEI, Departamento de Engenharia Elétrica, São Paulo, Brasil

Abstract— O presente artigo relata a implementação de uma plataforma de avaliação para reabilitação da mão de pacientes com paralisia dos membros superiores causada por AVC. O sistema implementado consome dados de uma câmera de profundidade, aplica um algoritmo preditivo para detecção dos pontos-chave da mão e compara os dados obtidos, tomando como padrão-ouro o movimento executado com a mão sem comprometimento motor do mesmo paciente e computando os desvios. Os resultados são armazenados em um banco de dados e podem ser consultados por uma interface web pelos profissionais de saúde. O sistema apresenta-se como um valioso módulo para programas de reabilitação, pois, permite acompanhar a evolução do paciente e auxilia na customização de seu tratamento, adequando-se às necessidades de cada indivíduo e potencializando os resultados da recuperação.

Keywords— AVC, Reabilitação da Mão, Modelo Preditivo, Visão Computacional.

I. INTRODUÇÃO

O Acidente Vascular Cerebral (AVC) é uma das principais causas de mortalidade cardiovascular no Brasil, e no mundo estima-se que um em cada 4 indivíduos, com mais de 25 anos, sofrerá pelo menos um AVC durante a vida [1]. Indivíduos que sobrevivem, comumente desenvolvem algumas limitações motoras que podem comprometer sua autonomia para realizar as atividades diárias, e a execução de tratamentos de reabilitação está diretamente relacionada à recuperação da mobilidade, independência e qualidade de vida. Nas últimas décadas, diversos estudos têm buscado desenvolver metodologias eficazes de reabilitação, tendo em vista as vantagens do tratamento precoce para ampliar o potencial de recuperação [2].

Um dos fatores que influencia diretamente a eficiência dos tratamentos de reabilitação é a frequência dos exercícios e a aderência do paciente ao programa e, durante o período da pandemia de Covid-19, a necessidade de distanciamento social impactou, de início, o progresso de diversos indivíduos devido à impossibilidade de frequentar as clínicas de reabilitação [2, 3, 4]. Com o objetivo de enfrentar esse desafio, ganharam destaque os estudos que propuseram a aplicação de sistemas de tele-reabilitação, permitindo que os

pacientes pudessem dar continuidade aos seus tratamentos à distância.

Sistemas que datam de duas décadas atrás ainda apresentam soluções relevantes que embasam a construção das plataformas atuais. Em [5] e em [6] foram propostos sistemas de tele-reabilitação para membros superiores integrados via internet para permitir o acompanhamento das atividades e a interação de forma remota entre o profissional de saúde e o paciente. Nesses sistemas, o paciente utilizava sensores nas mãos e luvas hápticas para a monitoração dos exercícios. Em [7] é apresentada uma revisão da literatura, que analisa as vantagens que a combinação de sistemas imersivos com técnicas de gamificação podem trazer para programas de reabilitação remota. A análise de 24 estudos, publicados entre os anos de 2015 e 2020, mostrou que a aplicação dessas técnicas permite a manutenção de programas de reabilitação de alta qualidade a baixos custos.

Uma característica marcante dos sistemas é a associação de abordagens reabilitativas com a possibilidade do paciente acompanhar, em tempo real, seu progresso, recebendo um retorno para as execuções de exercícios na forma de elogios ou pontuações, o que estimula a participação dos indivíduos no programa. Além disso, a transmissão e o armazenamento desses dados também viabilizam o acompanhamento remoto, por parte dos profissionais de saúde [7, 8]. Para que se tenha uma boa métrica de progresso é necessário tanto o levantamento qualitativo, que depende da visão do profissional, quanto o quantitativo do movimento, que pode ser obtido a partir de dados de diversas fontes, como: Eletromiografia (EMG), câmeras, dispositivos hápticos, exoesqueletos e outros sensores [9, 10, 11]. Por outro lado, um ponto a se considerar é o distanciamento entre os exercícios e as atividades diárias do paciente. Em [12] é apresentado uma plataforma que aproxima os exercícios que o paciente deve realizar de atividades cotidianas. É utilizada uma câmera Kinect para capturar os movimentos do usuário e representá-los no ambiente virtual, permitindo a interação com as atividades e aumentando a imersão no programa.

No entanto, verificou-se que a maioria dos trabalhos aplica as técnicas citadas para movimentos de grandes articulações do corpo, como ombro e cotovelo, sendo

escassos os trabalhos que conciliam sistemas imersivos com tecnologias integradas para monitoração dos exercícios e acompanhamento do progresso da reabilitação da mão. Nesse contexto, este trabalho propõe um sistema interativo para monitorar e avaliar a evolução de pacientes com deficiência motora da mão utilizando processamento de imagens de profundidade.

II. MATERIAIS E MÉTODOS

O sistema implementado está inserido como um componente de uma plataforma maior para reabilitação da mão. A plataforma conta com módulos dedicados para Estimulação Elétrica Funcional (FES), imersão do paciente para realização de atividades reabilitativas com uso de Realidade Virtual (RV) e um módulo Web para pacientes e profissionais de saúde configurarem e utilizarem os demais componentes. O módulo apresentado nesse trabalho, chamado de Módulo de Acompanhamento de Progresso, se insere na plataforma com o objetivo de prover o monitoramento da mobilidade da mão de forma quantitativa, permitindo o acompanhamento, por meio da interface *web*, do progresso do paciente através de métricas computadas para cada exercício realizado.

A metodologia para construção do sistema consiste em capturar imagens de profundidade, utilizando a câmera Intel RealSense D435, processar as informações para obtenção de pontos-chave das mãos do usuário e então calcular o desvio no posicionamento desses pontos com uso da métrica *Mean Per Joint Position Error* (MPJPE), que consiste na média da distância euclidiana entre dois conjuntos de pontos no espaço, uma métrica amplamente utilizada para verificar o desvio entre pontos-chave em algoritmos de *hand posing* [13, 14, 15]. Para cálculo do MPJPE são considerados como padrão-ouro os pontos-chave obtidos a partir da execução de um exercício com o uso da mão sem comprometimento motor e, como dados de acompanhamento, são utilizados os pontos da mão em reabilitação. A proposta para aplicação do sistema consiste em, ao longo da reabilitação, realizar a captura dos movimentos com a mão acometida, para que seja possível quantificar e acompanhar a evolução da mobilidade com o uso das técnicas de reabilitação.

O Módulo de Acompanhamento de Progresso pode ser dividido em quatro submódulos, os quais são descritos em maior detalhe nas seções seguintes. A Figura 1 apresenta o diagrama de comunicação dos componentes do sistema. Nessa figura, as comunicações locais, através de chamadas de métodos, são representadas por linhas sólidas, enquanto as comunicações por chamadas remotas, via protocolo HTTP, são representadas pelas linhas tracejadas. O código

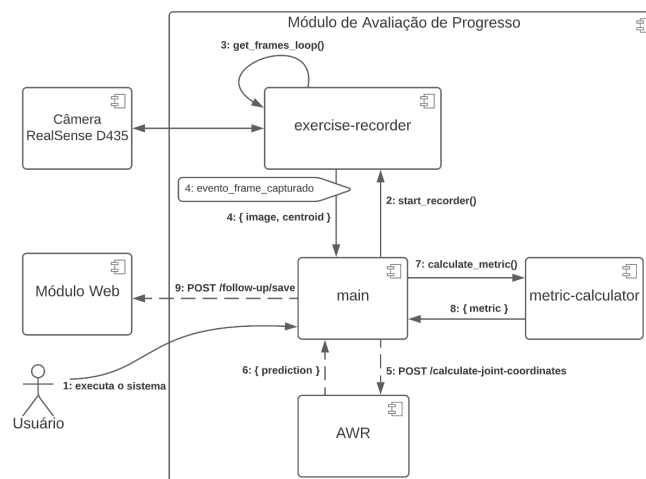


Fig. 1: Diagrama de Comunicação do Módulo de Avaliação de Progresso.

Módulo de Avaliação de Progresso foi escrito na linguagem de programação Python e os componentes *exercise-recorder*, *main* e *metric-calculator* se comunicam através de chamadas de método locais. Devido a limitações no *hardware* utilizado para desenvolvimento, o módulo AWR teve de ser segmentado em um servidor a parte e a comunicação com ele ocorre via HTTP.

A. *exercise-recorder*

Exibe, em tempo real, as informações lidas pela câmera Intel RealSense D435 e permite a captura de imagens dos exercícios. O código desse componente utiliza a biblioteca *pyrealsense*, que encapsula os métodos de acesso às câmeras da linha RealSense e oferece recursos para leitura e processamento de informações do dispositivo. Ao ser executado, esse módulo exibe uma janela com dois painéis, permitindo a visualização dos dados RGB e de profundidade da câmera.

A lógica implementada nesse componente se baseou nos requisitos de uso do módulo seguinte, AWR. Como descrito na Seção B.o modelo preditivo necessita como entrada um *frame* com dados de profundidade e um ponto x, y, z , que representa a posição central da mão do usuário na imagem. Para cada imagem lida da câmera, é executado um algoritmo para obtenção do ponto central utilizando a abordagem de cálculo de centróide. O algoritmo utiliza as informações de profundidade e filtra, de cada imagem, todos os *pixels* cuja coordenada Z é menor que 40cm; portanto, durante o uso do sistema, o usuário deve posicionar sua mão entre 28cm (distância mínima para captura da câmera D435) e 40cm. Como resultado da filtragem, são obtidas as coordenadas dos

pixels contendo a mão na imagem e, para a obtenção do ponto central, realiza-se o cálculo da média das coordenadas verticais (coordenada Y) e horizontais (coordenada X).

Um evento foi associado à tecla *Enter* do teclado para permitir a captura de *frames* e envio ao módulo seguinte. Ao ser pressionada, uma rotina de captura e processamento da última imagem lida pela câmera é acionada. Após o processamento, tanto a imagem quanto o centroide são armazenados em arquivos TXT para posterior consulta.

B. AWR

O algoritmo *Adaptive Weighting Regression* (AWR) consiste em um modelo preditivo para detecção de pontos-chave da mão [13]. Esse modelo foi escolhido como parte da plataforma devido a seu destaque na competição de *benchmarking* de algoritmos para *Hand Posing* HANDS 2017 [16]. Esse sistema agrega os benefícios dos dois principais métodos para *hand posing*; as estratégias baseadas em detecção a partir de mapas de calor e as baseadas em métodos de regressão. As imagens de profundidade são enviadas, através de uma Rede Neural Convolutiva (CNN), para a produção de mapas de calor, os quais mantêm as estruturas espaciais, e o resultado é enviado para o modelo de regressão para extração dos pontos-chave. O sistema tira vantagem dos resultados da regressão serem diferenciáveis para conectar os dois modelos e permitir um melhor treinamento do algoritmo.

Uma versão em código aberto do modelo está disponível no Github, com parâmetros já treinados sobre o *NYU Hand Pose Dataset*, um *dataset* contendo mais de 70 mil imagens de profundidade para treinamento e mais de 8 mil imagens para teste, capturadas em um *setup* utilizando 3 sensores Kinect v1 posicionados em perspectivas diferentes do usuário, sendo um frontal e os demais para captura de visões laterais [17]. Para treinamento do modelo do AWR disponível *online* foram utilizadas somente as imagens de perspectiva frontal e 14 dos 36 pontos-chave disponibilizados pelo *NYU*. A versão já treinada do modelo foi aplicada nesse projeto e seu módulo de carga de dados foi adaptado para permitir o processamento em tempo real, visto que sua implementação original esperava ler uma lista de imagens do sistema de arquivos. Para isso, foi adicionado ao modelo um servidor HTTP que, ao receber uma requisição contendo um *frame* de profundidade e um centroide, carrega os dados em memória para que a predição seja realizada, e então retorna a estrutura de coordenadas (x, y, z) dos 14 pontos-chave como resposta.

C. metric-calculator

Calcula a métrica MPJPE considerando como entrada os pontos resultantes do processamento de imagens pelo AWR. O conjunto de pontos de referência corresponde ao resultado do AWR para uma imagem da mão sem comprometimento motor, e os pontos de comparação correspondem ao resultado com uso da mão acometida. Esses conjuntos são nomeados na plataforma como padrão-ouro e acompanhamento, respectivamente.

D. main

Integra os demais componentes da plataforma. As operações e chamadas realizadas por esse módulo podem ser visualizadas em detalhes na Figura 1. Um subcomponente deste módulo, o *progress-data-loader*, autentica o usuário e envia os dados de métricas para o servidor *web*, o qual permite o acompanhamento do progresso através de um gráfico interativo, que agrupa as métricas de cada paciente por exercício.

E. Proposta Experimental

O sistema implementado faz uso da câmera D435 da Intel, a qual utiliza técnicas combinadas para captura de dados de profundidade, sendo estas: a estereoscopia, que é computada por meio dos dois sensores *imagers* presentes no dispositivo, e o processamento de dados de luz emitidos por seu projetor infravermelho. Embora a fabricante especifique em seu manual que o dispositivo é capaz de trabalhar sob condições de iluminação variadas, sabe-se que, a captura de dados por meio das câmeras é diretamente afetada pela intensidade e posicionamento da iluminação [18]. Para verificar as melhores condições de iluminação e posicionamento da câmera foi proposto um experimento com capturas em 9 configurações que utilizam diferentes combinações dessas variáveis. Também foi proposto outro experimento para validar a aplicabilidade do sistema para a proposta de acompanhamento de progresso, onde é realizado um teste funcional em laboratório, simulando sua utilização real.

Para o primeiro experimento foi elaborado um roteiro com a finalidade de verificar o comportamento da câmera em cenários diferentes de iluminação e distanciamento entre o dispositivo e a mão capturada. O experimento foi realizado com a coleta de imagens de um mesmo usuário, realizando o mesmo exercício de abertura da mão, em frente ao sensor. As configurações experimentadas foram: (A) Fonte de iluminação posicionada à frente do usuário e atrás da câmera. (B) Fonte de iluminação posicionada entre usuário e

a câmera. (C) Fonte de iluminação posicionada atrás do usuário e à frente da câmera. Para cada cenário de iluminação foram utilizadas três configurações diferentes de distanciamento entre a mão e o sensor da câmera: 28cm, 35cm e 37cm. Esses valores foram escolhidos de forma a verificar a melhor configuração do ambiente de captura enquanto ainda é mantido um baixo distanciamento entre o usuário e o sensor, o que também contribui para melhores resultados nas etapas seguintes do processamento.

Com a combinação das configurações, foram capturadas e processadas nove imagens diferentes. Para auxiliar na condução desse experimento, uma mesa de escritório foi adaptada. Foram adicionadas marcações para fixação da câmera em uma das extremidades, bem como demarcações das distâncias usadas para cada cenário, com o intuito de guiar o posicionamento das mãos do usuário. Para garantir maior conforto e precisão, também foi construído um apoio utilizando EVA e uma fita adesiva para fixação temporária em cada uma das posições de captura. Também foram utilizados dois fios de barbante para construção do apoio, os quais serviram como guias para centralização da mão do usuário durante a captura das imagens. Para obter as métricas desse experimento foi elaborado um algoritmo que realiza a leitura dos dados dos experimentos, filtra os *pixels* dentro da distância de 40cm da câmera, assim como realizado para definição do centroide, e transforma a imagem original em binária, onde cada *pixel* pode conter somente o valor 0, caso sua profundidade seja superior ao limiar, ou 1, caso contrário. Então o algoritmo corta a imagem de forma a deixar a mão capturada como objeto central. Os *frames* resultantes são tratados com um filtro de média, responsável por reduzir os ruídos e melhorar as bordas da imagem. Por fim, é computada a métrica *Root Mean Square Error* (RMSE), que consiste no cálculo da raiz quadrada do erro quadrático médio de cada imagem original em relação à sua correspondente após o tratamento. Essa métrica foi escolhida por ser comumente adotada para quantificar a qualidade de imagens de profundidade [19, 20, 21].

O segundo passo experimental teve o objetivo de verificar a viabilidade de aplicação da plataforma para quantificar o progresso de um usuário na execução de um exercício. A hipótese proposta nesse estudo é de que o valor da métrica MPJPE seria suficiente para quantificar o progresso do usuário. Para validar essa hipótese, o procedimento consiste em utilizar o resultado da melhor configuração identificada no experimento anterior para então realizar uma sequência de uso da plataforma simulando um cenário real. Sendo assim, o experimento inicia-se com a captura do padrão-ouro, com uma das mãos realizando o exercício de




Fig. 2: Imagens capturadas no experimento, no painel da esquerda os dados originais e à direita as mesmas imagens após o processamento pelo filtro de média. As imagens do topo correspondem a fonte de iluminação à frente do usuário e atrás da câmera, no centro a fonte de iluminação está entre o usuário e a câmera e na parte de baixo a fonte de iluminação está atrás do usuário e à frente da câmera.

abertura de mão e, subsequentemente, realiza-se uma sequência de capturas de acompanhamento com a outra mão, representando o lado acometido. Com a segunda sequência de capturas, são realizadas execuções parciais do movimento a fim de analisar se os resultados da métrica são proporcionais ao desvio intencionalmente aplicado ao movimento.

III. RESULTADOS

Visando melhorar a usabilidade do sistema foi adicionada uma interface gráfica que permite configurar: 1) O modo de uso do sistema (padrão-ouro ou acompanhamento); 2) Qual das mãos do usuário está sendo capturada; 3) O nome do exercício e 4) As credenciais do paciente para armazenamento da métrica calculada. Essa interface também auxiliou na execução dos experimentos de validação da plataforma, cujos resultados são apresentados a seguir.

Com respeito ao experimento de luz e posicionamento, as imagens originais e resultantes do tratamento com o filtro de média, para cada cenário de iluminação e nas três configurações de distanciamento entre a mão e o sensor da câmera, são apresentadas na Figura 2. Os resultados do cálculo da métrica RMSE são apresentados na Tabela 1.

Table 1: Resultados da métrica RMSE para cada experimento

Iluminação/Distância	28cm	35cm	37cm
(A) Diretamente na mão	0,091	0,107	0,118
(B) Perpendicular ao usuário	0,091	0,115	0,115
(C) Diretamente na câmera	0,091	0,109	0,121

IV. DISCUSSÃO




Fig. 3: Imagens capturadas no experimento funcional.

Table 2: Resultados do experimento funcional. A coluna Classificação Subjetiva do Movimento (CSM) apresenta a forma como o usuário classificou a qualidade da execução.

Movimento	CSM	MPJPE
(A) Extensão completa (imóvel)	Ideal	6,034
(B) Extensão parcial 1	Ruim	61,571
(C) Extensão parcial 2	Médio	30,346
(D) Extensão completa	Bom	12,438

Como pode ser observado na Tabela 1, o distanciamento que provocou menor valor de RMSE foi de 28cm, sendo o valor da métrica o mesmo para as três configurações de iluminação. Sendo assim, para execução do experimento funcional foi escolhida a iluminação diretamente na mão, cenário (A). Logo após a captura do padrão-ouro com a mão esquerda, foi realizada a captura de uma imagem de acompanhamento com o usuário mantendo o posicionamento da mão imóvel, para servir de referencial, e então, foram realizados os demais cenários com a mão direita. A Tabela 2 exhibe os resultados da métrica para os movimentos apresentados na Figura 3. Todas as imagens foram invertidas para exibir as capturas como se realizadas para a mão direita, para facilitar a análise visual dos resultados.

O experimento de posicionamento buscou identificar a melhor disposição física para uso da câmera. Seus resultados podem apoiar a configuração primária de ambientes clínicos para o uso do sistema. De acordo com os resultados, a câmera D435 apresentou melhor sensibilidade quando utilizada em distâncias menores (28cm), onde foi obtido, para as três abordagens de iluminação, o menor valor de RMSE. Isso sugere que uma maior proximidade entre a mão e o sensor garantem maior qualidade dos dados. Pode-se observar que, na menor distância, a câmera ofereceu o mesmo valor de RMSE em todas as configurações de iluminação. Presume-se que isso se dê em decorrência da capacidade de processamento de dados de luz advindos do projetor infravermelho, que pode compensar condições ruins de iluminação para os sensores *imagers*. Essa constatação é uma característica positiva e indica que o sistema pode ser utilizado tanto em ambientes clínicos quanto remotos sem grandes perdas na qualidade dos resultados obtidos.

No experimento funcional foi possível acompanhar o uso do sistema em cenários que simulam a aplicação real e pode-se observar que a métrica utilizada apresenta valores proporcionais à percepção subjetiva do exercício realizado. Considerando que o objetivo do experimento era reproduzir a extensão dos dedos como na imagem do padrão-ouro, o desvio obtido com a mão relativamente imóvel (Figura 3 (A)) foi de 6,034, um valor baixo, porém distante do ideal para essa situação, que deveria resultar em um desvio igual a zero. Na sequência de movimentos que simulam a evolução do paciente (Figura 3 (B), (C) e (D)) obteve-se, inicialmente um valor de desvio alto de 61,571 para a situação em que os dedos estão flexionados, um desvio médio de 30,346 para uma situação em que os dedos estão parcialmente flexionados e um desvio baixo de 12,438 para a situação de extensão dos dedos, semelhante ao padrão-ouro. Essa diferença pode ser devida a pequenos deslocamentos ou rotações da mão, que impactam nos resultados da métrica.

Os achados aqui documentados podem ser de grande valia para aplicação em sistemas de tele-reabilitação. Pode-utilizar da câmera como ferramenta de acompanhamento no lugar de dispositivos hápticos ou sensores de movimento [6, 5]. Esse dispositivo apresenta vantagens em comparação a outros, vestíveis: menor custo, facilidade de configuração, e menor complexidade de adaptação para uso com pacientes diferentes. Outra vantagem está no ganho de imersão dos pacientes durante o uso do sistema, pois essa abordagem permite a visualização, em tempo real da métrica atingida em cada exercício [8]. A plataforma construída também poderia ser utilizada como um módulo adicional para

sistemas que usam câmeras RGB-D para captura de dados, visando a imersão do usuário em ambientes virtuais [12].

V. CONCLUSÃO

Esse artigo apresentou uma plataforma para acompanhamento do progresso na reabilitação da mão com uso de processamento de imagens e de métricas sobre os resultados de um modelo preditivo de *hand posing*. Foram realizados experimentos com o sistema para analisar as melhores condições de uso e validar sua viabilidade como ferramenta de avaliação. Pode-se inferir que o sistema desenvolvido apresenta-se como um mecanismo viável para acompanhamento quantitativo do progresso e, quando aliado à análise qualitativa de um profissional da saúde, pode complementar as ferramentas necessárias para melhor elaboração de tratamentos reabilitativos customizados. Os resultados obtidos nos testes funcionais foram promissores. Contudo, ainda são necessárias avaliações clínicas para confirmação da aplicabilidade em cenários reais. Como trabalhos futuros pode-se melhorar o treinamento do modelo preditivo, considerando perspectivas diferentes de câmera para aperfeiçoar os resultados do algoritmo. Também pode-se melhorar o módulo de métricas minimizando a influência de movimentos de rotação e deslocamento da mão no resultado da métrica MPJPE.

CONFLITO DE INTERESSES

Os autores declaram que não existem conflitos de interesse.

REFERENCES

1. WORLD STROKE ORGANIZATION ANNUAL REPORT 2020
2. Moradi Vahideh et al.. Telework and telerehabilitation programs for workers with a stroke during the COVID-19 pandemic: A commentary *Work*. 2021;68:77–80.
3. Vitturi Bruno Kuszniir. The COVID-19 Pandemic Sacrificed the Excellence of Stroke Care Worldwide *SN Comprehensive Clinical Medicine*. 2021;3:1696–1698.
4. Chang Min Cheol, Boudier-Revéret Mathieu. Usefulness of Telerehabilitation for Stroke Patients during the COVID-19 Pandemic *American Journal of Physical Medicine and Rehabilitation*. 2020;99:582.
5. Holden Maureen K., Dyar Thomas A., Dayan-Cimadoro Lilian. Telerehabilitation using a virtual environment improves upper extremity function in patients with stroke *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2007;15:36–42.
6. Golomb Meredith R., McDonald Brenna C., Warden Stuart J., et al. In-Home Virtual Reality Videogame Telerehabilitation in Adolescents With Hemiplegic Cerebral Palsy *Archives of Physical Medicine and Rehabilitation*. 2010;91:1–8.e1.

7. Berton Alessandra, Longo Umile Giuseppe, Candela Vincenzo, et al. Clinical Medicine Virtual Reality, Augmented Reality, Gamification, and Telerehabilitation: Psychological Impact on Orthopedic Patients' Rehabilitation *J. Clin. Med.* 2021;2020:13.
8. Anton David, Goni Alfredo, Illarramendi Arantza, Torres-Unda Juan Jose, Seco Jesus. KiReS: A Kinect-based telerehabilitation system in 2013 *IEEE 15th International Conference on e-Health Networking, Applications and Services (Healthcom 2013)*IEEE 2013.
9. Costa-García Álvaro, Ozaki Ken, Yamasaki Hiroshi, et al. Model for prompt and effective classification of motion recovery after stroke considering muscle strength and coordination factors *Journal of NeuroEngineering and Rehabilitation*. 2019;16.
10. Capecchi Marianna, Ceravolo Maria Gabriella, Ferracuti Francesco, et al. A Hidden Semi-Markov Model based approach for rehabilitation exercise assessment *Journal of Biomedical Informatics*. 2018;78:1–11.
11. Farulla Giuseppe Airò, Pianu Daniele, Cempini Marco, et al. Vision-Based Pose Estimation for Robot-Mediated Hand Telerehabilitation *Sensors*. 2016;16:208.
12. Adams Richard J., Lichter Matthew D., Ellington Allison, et al. Virtual Activities of Daily Living for Recovery of Upper Extremity Motor Function *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2018;26:252–260.
13. Huang Weiting, Ren Pengfei, Wang Jingyu, Qi Qi, Sun Haifeng. AWR: Adaptive weighting regression for 3D hand pose estimation *AAAI 2020 - 34th AAAI Conference on Artificial Intelligence*. 2020:11061–11068.
14. Xiong Fu, Zhang Boshen, Xiao Yang, et al. A2J: Anchor-to-Joint Regression Network for 3D Articulated Pose Estimation from a Single Depth Image 2019.
15. Moon Gyeongsik, Chang Ju Yong, Lee Kyoung Mu. V2V-PoseNet: Voxel-to-Voxel Prediction Network for Accurate 3D Hand and Human Pose Estimation from a Single Depth Map 2018.
16. Kim Tae-Kyun, Argyros Antonis, Garcia-Hernando Guillermo, et al. HANDS 2017 2017.
17. Tompson Jonathan, Stein Murphy, Lecun Yann, Perlin Ken. Real-Time Continuous Pose Recovery of Human Hands Using Convolutional Networks *ACM Transactions on Graphics*. 2014;33.
18. Intel . Beginner's guide to depth 2019.
19. Zhang Xinhong, Chu Yanping, Zhang Junliang, Zhang Fan. A New Quality Evaluation Method of Binary Images in *Advanced Intelligent Computing Theories and Applications. With Aspects of Artificial Intelligence* (Huang De-Shuang, Zhang Xiang, Reyes García Carlos Alberto, Zhang Lei. , eds.)(Berlin, Heidelberg):271–278Springer Berlin Heidelberg 2010.
20. Sadykova Diana, James Alex Pappachen. Quality assessment metrics for edge detection and edge-aware filtering: A tutorial review in 2017 *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*:2366-2369 2017.
21. Dogan Safak, Haddad Nasser, Ekmekcioglu Erhan, Kondo M. Ahmet. No-Reference Depth Map Quality Evaluation Model Based on Depth Map Edge Confidence Measurement in Immersive Video Applications *Future Internet*. 2019;11:204.

Enter the information of the corresponding author:

Autor: João Victor Fernandes de Souza
Instituto: Centro Universitário FEI
Rua: Av. Humberto de Alencar Castelo Branco, 3972-B
Cidade: São Bernardo do Campo - SP
País: Brasil
Email: jvictorf@fei.edu.br