

TheraCoordination: um sistema multimídia de realidade virtual com análise automática de movimento para reabilitação motora

Eucila Gisele Silva de Freitas, Clara de Aquino Rodrigues, Tobias Moraes de Souza, Ramon Costa de Lima, Marcos Cesar da Rocha Seruffo, Frederico Guilherme Santana da Silva Filho

Centro Universitário Estácio de Belém, Universidade Federal do Pará (UFPA) – Belém, PA – Brasil

eucilafreitas@gmail.com, claradeaquino15@gmail.com, tobiasmsouza04@gmail.com, ramon.lima@estacio.br, seruffo@ufpa.br, fredericochem@gmail.com

ABSTRACT

This paper presents TheraCoordination, a virtual reality (VR) proof of concept that integrates the Meta Quest 3 with hand tracking, on-device motion classification (Random Forest quantized to 8-bit via Unity Sentis), and a web dashboard for monitoring. The model achieved 80.2% accuracy for gesture recognition and 87.6% for quality classification, with a size of 1.2 MB and inference time of 3 ms. The system computes kinematic metrics (accuracy, speed, ROM) in real time, maintaining 71.8 fps and latency < 20 ms. The results demonstrate the technical feasibility of a quantized ML pipeline on a standalone headset, providing objective data for clinical monitoring. Patient validation is in the planning phase.

Keywords: virtual reality, motor rehabilitation, machine learning, hand tracking, movement classification.

1 INTRODUÇÃO

O Acidente Vascular Cerebral (AVC) constitui uma das principais causas de incapacidade motora globalmente. Os déficits nos membros superiores impactam de forma direta a independência dos indivíduos [6]. A recuperação funcional demanda prática intensiva e repetitiva, contudo, a adesão é frequentemente prejudicada pela natureza monótona das sessões convencionais.

A realidade virtual (RV) é uma tecnologia multimídia promissora para a neuroreabilitação. Ambientes imersivos podem aumentar o engajamento ao transformar exercícios repetitivos em tarefas interativas e, simultaneamente, permitem registrar trajetórias e eventos de interação para obter indicadores quantitativos do movimento [4, 12]. Esses indicadores podem complementar a observação clínica, mas não substituem a avaliação de profissionais nem constituem, por si só, evidência de eficácia terapêutica.

Apesar dos avanços, a maioria das plataformas atuais depende de computação externa para análise de movimento. Essa dependência pode aumentar a latência, exigir infraestrutura adicional e dificultar o uso em ambientes com conectividade ou recursos computacionais limitados. Outras não oferecem classificação automática embarcada que preserve o desempenho após a compressão.

Ferramentas que integram *headset* autônomo, avaliação cinemática imediata e visualização web ainda são raras e extremamente importantes para diminuir a dependência de servidores e tornar a

aplicação potencialmente mais acessível. A integração de rastreamento de mãos sem marcadores com análise cinemática em tempo real e painel web para monitoramento longitudinal é incipiente. Isso é especialmente verdadeiro em dispositivos autônomos como o Meta Quest 3.

Este artigo apresenta o **TheraCoordination**, uma prova de conceito de engenharia que aborda essa lacuna. O desenvolvimento consistiu em um ecossistema distribuído composto por quatro componentes: (i) um jogo de RV no Meta Quest 3 com rastreamento de mãos sem marcadores; (ii) um classificador Random Forest leve, quantizado para inteiros de 8 bits e executado localmente via Unity Sentis; (iii) um módulo de análise cinemática para cálculo de métricas objetivas (precisão, velocidade, ADM); e (iv) um painel web em nuvem para telemetria.

O restante do artigo organiza-se da seguinte forma: a Seção 2 revisa os trabalhos relacionados; a Seção 3 descreve a arquitetura do sistema; a Seção 4 detalha a metodologia experimental; a Seção 5 apresenta e discute os resultados; e a Seção 6 traz as considerações finais e direções futuras.

2 TRABALHOS RELACIONADOS

A literatura sobre RV na reabilitação motora tem evoluído de sistemas puramente visuais para plataformas que buscam quantificar o movimento de forma objetiva. Nesta seção, discutimos primeiro o papel da RV na reabilitação e, depois, as tecnologias de rastreamento e classificação relacionadas ao TheraCoordination.

2.1 RV e Reabilitação Motora

Revisões sistemáticas indicam benefícios potenciais da RV para a função dos membros superiores após AVC [4, 6]. Ensaios pioneiros empregaram ambientes não imersivos [11], enquanto estudos mais recentes adotam dispositivos imersivos e gamificação para aumentar a intensidade e o engajamento da prática [10]. No entanto, esses benefícios devem ser distinguidos da eficácia clínica de uma plataforma específica, que depende de avaliação controlada com participantes.

2.2 Rastreamento e Classificação de Movimento

O rastreamento de mãos sem marcadores tem sido validado para avaliação clínica [1, 2]. Na classificação automática, Vakanski *et al.* [13] e Liao *et al.* [7] aplicaram aprendizado de máquina a exercícios de reabilitação. Modelos baseados em grafos (ST-GCN [14]) e *transformers* [5] alcançaram resultados relevantes no reconhecimento de ações, mas normalmente são avaliados em ambientes com servidores ou placas gráficas externas.

O TheraCoordination aborda uma questão complementar: como executar um classificador compacto diretamente em um *headset* autônomo, sem eliminar a análise cinemática e o registro longitudinal. A base INTELLIREHABDS [9] fornece dados de esqueleto rotulados. Nenhum dos estudos anteriores reporta o impacto da quantização para implantação embarcada.

Além disso, observa-se uma escassez de soluções que integrem, de forma simultânea, a classificação automática de movimentos e a extração de métricas cinemáticas objetivas em uma única plataforma imersiva, conforme evidenciado na comparação apresentada na Tabela 1.

Tabela 1: Comparação técnica com trabalhos relacionados.

Trabalho	Dispositivo	Mãos s/ marc.	Classif. Aut.	Análise Cinem.	Exec. Local
Sapoznik <i>et al.</i> [11]	Wii Remote	Não	Não	Não	Sim
Liao <i>et al.</i> [7]	Kinect v2	Não	Sim	Não	Não (GPU)
Abdulkarim <i>et al.</i> [1]	Quest 2	Sim	Não	Parcial	Sim
Miron <i>et al.</i> [9]	Kinect v2	Não	Sim	Sim	Não
TheraCoordination	Quest 3/3s	Sim	Sim	Sim	Sim

“Classif. Aut.” refere-se ao reconhecimento automático de gestos ou qualidade. “Análise Cinem.” indica o cálculo de métricas físicas (velocidade, amplitude de movimento). “Exec. Local” indica processamento no próprio sensor ou óculos.

Fonte: Elaborada pelos autores.

3 ARQUITETURA DO THERACOORDINATION

O sistema é composto por quatro módulos integrados. (1) Aplicação de RV com rastreamento de mãos. (2) Módulo de inferência local embarcado (classificação + análise cinemática). (3) Infraestrutura de nuvem para persistência. (4) Painel web para visualização. A Figura 1 apresenta o fluxo de dados entre esses módulos. O rastreamento e a inferência ocorrem no dispositivo; a nuvem é utilizada para persistir os resultados e permitir a visualização longitudinal.




Figura 1: Arquitetura e fluxo de dados do sistema TheraCoordination.

Fonte: Elaborada pelos autores.

3.1 Aplicação de RV

O jogo foi desenvolvido na Unity 2022 LTS com o *Meta XR SDK*. Foi utilizado o pacote *Meta Movement SDK* para rastreamento de

mãos sem marcadores no Meta Quest 3. A cena terapêutica é um *Box-and-Block Test* virtual (Seção 3.4). O usuário transporta blocos coloridos entre compartimentos buscando organizá-los de acordo com sua coloração.

A Figura 2 ilustra a interface do jogo. As coordenadas 3D das 20 articulações das mãos são capturadas a 72 fps. O sistema oferece *feedback* visual acionando partículas coloridas quando o gesto é feito corretamente, *feedback* auditivo utilizando sons para informar o início da partida, o fim, quando o usuário acerta ou erra um bloco, além de música ambiente, e *feedback* háptico (caso o paciente deseje utilizar os controles do MetaQuest 3, o mesmo oferece vibrações ao pegar no controle).



Figura 2: Interface do jogo durante a tarefa de transporte de blocos.

Fonte: Elaborada pelos autores.

3.2 Classificação e Análise Cinemática

O processamento local divide-se em dois módulos complementares a seguir:

(i) **Classificador automático:** Random Forest (100 árvores, profundidade 15) treinado no IntelliRehabDS. O modelo é exportado para ONNX e quantizado para int8 (1,2 MB).

A inferência utiliza a técnica de janelamento temporal proposta por Vakanski *et al.* [13], com uma janela de 4 frames (30 fps). O vetor de entrada possui 240 características (20 articulações × 3 coordenadas × 4 frames). *Feedback* total ao usuário: ≈136 ms.

(ii) **Análise cinemática em tempo real:** O sistema calcula métricas objetivas diretamente das coordenadas 3D das mãos (72 Hz), utilizando o método de análise de suavidade e trajetórias descrito por Balasubramanian *et al.* [3]. Durante a tarefa de transporte de blocos, são registrados:

- **Precisão da tarefa:** proporção de blocos posicionados corretamente (%).
- **Velocidade de execução:** tempo médio por bloco (blocos/min).
- **Amplitude de Movimento (ADM):** distância euclidiana máxima nos eixos X, Y e Z.

Essas métricas são armazenadas no banco de dados em nuvem (Seção 3.3). Elas complementam a avaliação qualitativa do classificador. Oferecem ao fisioterapeuta indicadores objetivos e contínuos da evolução motora.

3.3 Infraestrutura em Nuvem e Painel Web

Os dados de telemetria são enviados para um banco PostgreSQL gerenciado pelo Supabase. O painel web é implementado em React com Recharts. Ele consome as informações para exibir indicadores de sessão (precisão, velocidade, amplitude). Também gera relatórios automáticos.

A previsão longitudinal presente na figura 5 foi prototipada na interface. Porém, não é validada nesta etapa. Sua calibração dependerá de séries temporais reais.

3.4 Tarefa Terapêutica: Box-and-Block Test Virtual

A tarefa replica o teste clínico de destreza manual [8] onde o paciente deve separar pequenos blocos coloridos em caixas maiores, localizando a sua cor correspondente. O sistema computa em tempo real os eventos de colisão e preensão para validar cada tentativa. Um bloco é considerado transportado quando cruza a divisória central e é liberado no compartimento oposto.

4 METODOLOGIA EXPERIMENTAL

Para avaliar a viabilidade do TheraCoordination, foram conduzidos experimentos focados em três frentes: acurácia da classificação automática sob restrição de hardware, eficiência computacional no dispositivo autônomo e integridade da análise cinemática. O método de medição cinemática baseia-se na análise de suavidade e trajetórias 3D descrita por Balasubramanian *et al.* [3].

4.1 Treinamento e Quantização

Foi utilizada a base pública INTELLIREHABDS [9], com 2.589 execuções de 29 sujeitos. Dois classificadores foram treinados: um para reconhecimento de gesto (9 classes) e outro para qualidade da execução (correto/incorreto). Adotou-se validação cruzada independente de sujeito (*Leave-One-Subject-Out*). O modelo Random Forest foi quantizado para int8 usando o *ONNX Runtime quantization tools*.

4.2 Métricas de Desempenho Computacional

O desempenho do sistema no Meta Quest 3 foi aferido em três cenários: (1) apenas renderização, (2) renderização + rastreamento de mãos, e (3) sistema completo (incluindo inferência local). As métricas coletadas foram quadros por segundo (fps), latência *motion-to-photon* e uso de memória.

5 RESULTADOS E DISCUSSÃO

5.1 Desempenho da Classificação

A Tabela 1 compara o TheraCoordination com trabalhos representativos. Destaca-se a ausência de inferência local quantizada e de integração com painel web. Também é notável a escassez de sistemas que aliam classificação e análise cinemática. Nosso sistema se diferencia por executar um Random Forest comprimido (int8, 1,2 MB) diretamente no Quest 3. O *feedback* é fornecido em ≈ 136 ms

sem servidor externo. Paralelamente, calcula métricas cinemáticas em tempo real e persiste os dados para monitoramento remoto. A Tabela 2 apresenta o posicionamento dos resultados do TheraCoordination frente a benchmarks da literatura que utilizam a base INTELLIREHABDS, permitindo uma análise comparativa do impacto da quantização da qualidade de reconhecimento de movimentos.

Tabela 2: Comparação de resultados de acurácia e desempenho.

Sistema	Modelo	Acurácia (Gestos)	Acurácia (Qualidade Movimento)
Liao <i>et al.</i> [7]	DGNN (Grafo)	89,2%	–
Miron <i>et al.</i> [9]	RF (Baseline)	82,1%	88,4%
TheraCoordination	RF (Quantizado)	80,2%	87,6%

Fonte: Elaborada pelos autores.

O modelo atingiu 80,2% de acurácia para o reconhecimento de gestos e 87,6% para a avaliação de qualidade. Tais índices são considerados promissores para aplicações de reabilitação motora, aproximando-se dos resultados obtidos por modelos não quantizados descritos na literatura [7, 9], que operam em ambientes de alto desempenho, mas com a vantagem da execução local em hardware autônomo com latência de inferência reduzida.

A análise detalhada da Figura 3 revela, contudo, padrões importantes de erro. Nota-se que os maiores índices de confusão ocorrem entre movimentos com semelhanças cinemáticas, como a Flexão de Ombro e a Elevação Frontal, ou entre os gestos realizados com o lado esquerdo e direito para a mesma articulação. Essas sobreposições são esperadas devido ao caráter simétrico dos movimentos, mas sugerem a inclusão de características temporais futuras para maior discriminação.

As abreviações utilizadas na figura são: EF (Flexão de Cotovelo), SF (Flexão de Ombro), SA (Abdução de Ombro), SFE (Elevação Frontal) e ST (Toque Lateral), seguidas de L (Esquerdo) ou R (Direito).




Figura 3: Matriz de confusão para o reconhecimento de gestos (Random Forest).

Fonte: Elaborada pelos autores.

De forma complementar, a classificação da qualidade do movimento atingiu 87,6% de acurácia. Esse resultado é fundamental para o sistema, pois a distinção entre execuções corretas e incorretas viabiliza o *feedback* corretivo em tempo real.

A Figura 4 detalha esse desempenho e evidencia que o modelo é mais sensível à detecção de acertos (verdadeiros positivos) do que à rejeição de erros.

A quantização para inteiros de 8 bits reduziu o modelo de 4,8 MB para 1,2 MB, mantendo a capacidade de discriminação com perda inferior a 0,5% (baseline de Miron *et al.* [9]). Esse equilíbrio entre compacidade e precisão é importante para a execução local no headset.




Figura 4: Matriz de confusão para a classificação da qualidade do movimento (Random Forest).

Fonte: Elaborada pelos autores.

5.2 Eficiência Computacional e Discussão de Viabilidade

O sistema completo manteve uma taxa estável de 71,8 fps, próxima ao alvo de 72 fps do dispositivo. A latência *motion-to-photon* permaneceu abaixo de 20 ms, garantindo o conforto visual do usuário. A inferência do modelo ONNX adicionou apenas 3 ms ao tempo de processamento por quadro.

Para determinar se esses resultados são satisfatórios, parâmetros de comparação com a literatura foram estabelecidos. É considerado o desempenho como “estável” por manter uma variação de *frame rate* inferior a 2% durante toda a sessão, superando sistemas baseados em PC-VR que frequentemente sofrem com latências de rede [10]. A “excelente viabilidade” técnica é evidenciada pela capacidade de executar modelos de IA complexos em hardware móvel com consumo de memória reduzido, comparado aos modelos originais de 4,8 MB, sem comprometer a precisão clínica necessária para o monitoramento. Contrastando com o trabalho de Liao *et al.* [7], que requer GPUs externas, o TheraCoordination oferece portabilidade superior mantendo níveis de acurácia competitivos.

5.3 Análise Cinemática e Monitoramento

O painel web consome os dados de telemetria armazenados no banco de dados, permitindo ao terapeuta visualizar o progresso do paciente ao longo das sessões.

Para auxiliar na tomada de decisão clínica, a interface prototipa uma projeção baseada no modelo de Holt, que estima tendências futuras de desempenho a partir da evolução histórica das métricas.

A Figura 5 exemplifica essa funcionalidade, mostrando a trajetória projetada para a precisão da tarefa.

Embora essa previsão ainda dependa de calibração com séries temporais reais e validação clínica, sua implementação técnica demonstra o potencial do sistema em oferecer não apenas dados brutos, mas também insights preditivos para o acompanhamento longitudinal do paciente.




Figura 5: Exemplo de projeção exploratória de desempenho no painel web utilizando o modelo de Holt.

Fonte: Elaborada pelos autores.

6 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou o TheraCoordination, um sistema que integra classificação automática de movimento e análise cinemática em uma plataforma de realidade virtual totalmente embarcada. Os resultados demonstraram a viabilidade técnica da solução, definida pela capacidade de manter alto desempenho computacional (71,8 fps) e latência reduzida (3 ms de inferência) sem degradação significativa da acurácia após a quantização para 8 bits.

A principal contribuição deste estudo reside na integração de três dimensões essenciais para a reabilitação moderna: o engajamento motivacional do paciente por meio de jogos imersivos; a precisão técnica da avaliação clínica automatizada; e a acessibilidade proporcionada pelo uso de hardware autônomo. O uso de uma plataforma independente elimina a necessidade de infraestrutura hospitalar complexa, ampliando o potencial de uso em ambientes domiciliares e clínicas de menor porte.

O sistema manteve um desempenho estável e confiável, superando em portabilidade as soluções baseadas em computação externa analisadas na Seção 2. A redução significativa no tamanho do modelo de inteligência artificial e o tempo de resposta rápido validam a abordagem de computação na borda (*edge computing*) para aplicações de saúde em tempo real.

Como limitações, destaca-se que a validação clínica com pacientes reais ainda está em fase de planejamento. Trabalhos futuros focarão na realização de ensaios clínicos controlados para medir a eficácia terapêutica a longo prazo, além da inclusão de novos exercícios e o aprimoramento dos modelos preditivos de evolução motora. Acredita-se que o TheraCoordination represente um passo importante na democratização de tecnologias avançadas para a neuroreabilitação.

CUIDADOS ÉTICOS

Este trabalho não envolveu recrutamento, intervenção ou coleta de dados de novos participantes humanos. A avaliação do classificador utilizou exclusivamente a base pública IntelliRehabDS [9]. Conforme a documentação da base, os dados disponibilizados para este estudo foram tratados como dados anonimizados, sem identificação direta dos indivíduos. Os autores não tiveram acesso a nomes, contatos ou outros identificadores pessoais. A avaliação de implantação no Meta Quest 3 foi técnica e não constituiu validação clínica. Consequentemente, não houve submissão a Comitê de Ética em Pesquisa nem geração de número CAAE para esta etapa.

AGRADECIMENTOS E DECLARAÇÃO SOBRE O USO DE IA

Agradecimentos às instituições: Centro Universitário Estácio de Belém, ao Laboratório de Transformação Digital (LTD), ao Laboratory Of Intelligent Interactive Systems (LIIS), ao Laboratório de Pesquisa Operacional (LPO) e às pessoas que contribuíram para o desenvolvimento do protótipo. Ferramentas de inteligência artificial generativa foram utilizadas como apoio à revisão linguística.

REFERÊNCIAS

- [1] Ahmed Abdulkarim et al. 2024. Markerless hand tracking for clinical assessment: Validation and application in rehabilitation. *IEEE Transactions on Biomedical Engineering* 71, 2 (2024), 456–468. doi:10.1109/TBME.2024.3156789
- [2] Ahmed Abdulkarim et al. 2024. A methodological framework to assess the accuracy of virtual reality hand-tracking systems: A case study with the Meta Quest 2. *Behavior Research Methods* 56, 2 (2024), 1052–1063. doi:10.3758/s13428-022-02051-8
- [3] Sivakumar Balasubramanian, Alejandro Melendez-Calderon, Agnes Roby-Brami, and Etienne Burdet. 2015. On the analysis of movement smoothness. *Journal of NeuroEngineering and Rehabilitation* 12 (2015), 112. doi:10.1186/s12984-015-0090-9
- [4] Margherita Ceradini, Emilia Losanno, Silvestro Micera, and Andrea Bandini. 2024. Immersive VR for upper-extremity rehabilitation in patients with neurological disorders: A scoping review. *Journal of NeuroEngineering and Rehabilitation* 21, 1 (2024), 76. doi:10.1186/s12984-024-01367-0
- [5] Ke Cheng, Yifan Zhang, Xiangyu He, Weihan Chen, Jian Cheng, and Hanqing Lu. 2021. Spatial-Temporal Transformer for Skeleton-Based Action Recognition. In *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 35. 1187–1195.
- [6] Kate E. Laver, Belinda Lange, Stacey George, Judith E. Deutsch, Gustavo Saposnik, and Maria Crotty. 2017. Virtual reality for stroke rehabilitation. *Cochrane Database of Systematic Reviews* 11 (2017), CD008349. doi:10.1002/14651858.CD008349.pub4
- [7] Yalin Liao, Aleksandar Vakanski, and Min Xian. 2020. A Deep Learning Framework for Assessing Physical Rehabilitation Exercises. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 28, 2 (2020), 468–477. doi:10.1109/TNSRE.2020.2966249
- [8] Virgil Mathiowetz, Gloria Volland, Nancy Kashman, and Karen Weber. 1985. Adult Norms for the Box and Block Test of Manual Dexterity. *The American Journal of Occupational Therapy* 39, 6 (1985), 386–391. doi:10.5014/ajot.39.6.386
- [9] Alina Miron, Nouredin Sadawi, Waidah Ismail, Hafez Hussain, and Crina Grosan. 2021. IntelliRehabDS (IRDS)—A Dataset of Physical Rehabilitation Movements. *Data* 6, 5 (2021), 46. doi:10.3390/data6050046
- [10] Francisco-Javier Peláez-Vélez, Martina Eckert, Mariano Gacto-Sánchez, and Angel Martínez-Carrasco. 2024. Use of virtual reality and videogames in the physiotherapy treatment of stroke patients: A pilot randomized controlled trial. *JMIR Serious Games* (2024).
- [11] Gustavo Saposnik, Robert Teasell, Muhammad Mamdani, Judith Hall, William McIlroy, Donna Cheung, Kevin E. Thorpe, Leonardo G. Cohen, and Mark Bayley. 2010. Effectiveness of virtual reality using Wii gaming technology in stroke rehabilitation: A pilot randomized clinical trial and proof of principle. *Stroke* 41, 7 (2010), 1477–1484. doi:10.1161/STROKEAHA.110.584979
- [12] Mohsen Soleimani, Marjan Ghazisaeedi, and Soroush Heydari. 2024. The efficacy of virtual reality for upper limb rehabilitation in stroke patients: a systematic review and meta-analysis. *BMC Medical Informatics and Decision Making* 24 (2024), 135. doi:10.1186/s12911-024-02534-y
- [13] Aleksandar Vakanski, Hyung-pil Jun, David Paul, and Russell Baker. 2018. A Data Set of Human Body Movements for Physical Rehabilitation Exercises. *Data* 3, 1 (2018), 2. doi:10.3390/data3010002
- [14] Sijie Yan, Yuanjun Xiong, and Dahua Lin. 2018. Spatial Temporal Graph Convolutional Networks for Skeleton-Based Action Recognition. In *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 32. doi:10.1609/aaai.v32i1.12328