

<p style="text-align: center;">Universidade de Pernambuco Programa de Pós-Graduação em Engenharia da Computação (PPGEC)</p>
<p style="text-align: center;">Proposta de Dissertação de Mestrado</p>
<p>Área: Inteligência Computacional</p>
<p>Título: Aprendizado Federado para Renderização Neural em Dispositivos de Realidade Virtual</p>
<p>Orientador – Bruno José Torres Fernandes (bjtf@ecomppoli.br) Coorientador – Ícaro Lins Leitão da Cunha (icaro.cunha@ufape.edu.br)</p>
<p>Descrição – A realidade virtual (VR) tem se consolidado como tecnologia central em aplicações de entretenimento, treinamento profissional e educação imersiva [1]. A popularização de dispositivos standalone amplia o acesso a esses ambientes, mas impõe fortes restrições computacionais em comparação com GPUs dedicadas de desktop [2]. Técnicas clássicas de renderização em tempo real e fotorrealista — incluindo iluminação global fisicamente baseada e efeitos avançados de luz e sombra — tornam-se caras demais para hardware móvel, limitando a qualidade visual alcançável.</p> <p>Nesse cenário, a renderização neural surge como alternativa promissora, permitindo substituir etapas intensivas do pipeline gráfico por modelos de aprendizado profundo [3]. Abordagens de super-resolução neural possibilitam renderizar em baixa resolução e reconstruir detalhes de alta frequência por meio de redes treinadas especificamente para esse fim [4]. Técnicas de neural relighting aproximam efeitos complexos de iluminação, sombras suaves e reflexos em tempo real [5], enquanto foveated rendering explora a acuidade visual decrescente na periferia para concentrar o poder de renderização na região central da visão [6]. Tais componentes são especialmente atraentes para VR standalone, em que é crucial equilibrar qualidade visual, taxa de quadros e conforto do usuário.</p> <p>Por outro lado, o treinamento desses modelos de aprendizado de máquina depende de grandes volumes de dados visuais, frequentemente heterogêneos e distribuídos entre diferentes dispositivos e contextos de uso [7]. A centralização desses dados pode ser inviável tanto por limitações de banda quanto por questões de privacidade e segurança. O aprendizado federado (Federated Learning – FL) oferece uma alternativa para treinar modelos de forma colaborativa em dados distribuídos, sem a necessidade de agregá-los em um servidor central [8]. Nessa abordagem, cada dispositivo treina localmente seu modelo e compartilha apenas atualizações de parâmetros, preservando privacidade, reduzindo o tráfego de dados sensíveis e explorando a capacidade computacional periférica [9][10]. Além disso, o FL é adequado a cenários com heterogeneidade de dispositivos, comunicação limitada e necessidade de atualização contínua do modelo [11][12].</p> <p>Diante desse contexto, este projeto propõe investigar a aplicação de aprendizado federado para treinar e adaptar modelos de super-resolução neural, neural relighting e fixed foveated rendering em dispositivos autônomos de realidade virtual. A proposta é utilizar um ambiente federado em que múltiplos dispositivos standalone contribuam para o aprimoramento colaborativo desses modelos, sem compartilhar diretamente seus dados</p>

visuais. O estudo buscará avaliar em que medida o FL melhora a capacidade de generalização dos modelos para diferentes usuários e ambientes, mantendo a privacidade e reduzindo a necessidade de coleta centralizada de dados. Serão analisados indicadores como qualidade visual, taxa de quadros, temperatura do dispositivo e impacto no conforto do usuário, com foco em VR standalone de baixo custo.

Espera-se que a combinação de técnicas de renderização neural com aprendizado federado resulte em modelos mais eficientes e adaptativos para VR, contribuindo para soluções visualmente mais ricas e computacionalmente viáveis em hardware limitado, ampliando o potencial de aplicações imersivas em cenários reais de uso.

Referências Bibliográficas

- [1] Al-Ansi, A. M, et al. Analyzing augmented reality (AR) and virtual reality (VR) recent development in education. *Social Sciences & Humanities Open*, v. 8, n. 1, 2023.
- [2] AKENINE-MÖLLER, T.; HAINES, E.; HOFFMAN, N. *Real-Time Rendering*. 4. ed. A K Peters/CRC Press, 2018.
- [3] Yan, X. et al. Neural Rendering and Its Hardware Acceleration: A Review. *ArXiv*, 2024.
- [4] WANG, X. et al. Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic Data. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, 2021.
- [5] ZHANG, L. et al. Neural Video Portrait Relighting in Real-Time via Consistency Modeling. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021.
- [6] GUENTER, B. et al. Foveated 3D Graphics. *ACM Transactions on Graphics (TOG)*, v. 31, n. 6, p. 164:1–164:10, 2012.
- [7] NGUYEN, G. et al. Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, v. 52, p. 77–124, 2019.
- [8] MCMAHAN, H. B. et al. Communication-efficient learning of deep networks from decentralized data. In: *International Conference on Artificial Intelligence and Statistics*, 2016.
- [9] ALEDHARI, M. et al. Federated learning: A survey on enabling technologies, protocols, and applications. *IEEE Access*, v. 8, p. 140699–140725, 2020.
- [10] GOSSELIN, R. et al. Privacy and security in federated learning: A survey. *Applied Sciences*, 2022.

[11] SHAHID, O. et al. Communication efficiency in federated learning: Achievements and challenges. *arXiv preprint*, arXiv:2107.10996, 2021.

[12] ABHISHEKV, A. et al. Federated learning: Collaborative machine learning without centralized training data. *International Journal of Engineering Technology and Management Sciences*, 2022.