



TECGRAF
PUC-RIO



Rumo a representações neurais práticas de computação gráfica em tempo real

28/02/2023

Vinícius da Silva

Resumo

- Contexto e Motivação
- Neural Implicit Mapping via Neste Neighborhoods
- Resultados


Contexto e Motivação

Grupo de pesquisa

- Neural Media
 - Regularização
 - Reconstrução
 - Compactação
 - Representações neurais 3D para computação gráfica prática
- Colaboração
 - PUC-Rio
 - IMPA
 - Universidade de Coimbra
 - Unisinos

Multi-layer Perceptrons (MLPs)

- Função f , que aproxima uma função f' qualquer [*]
- Camadas de neurônios ligadas
 - Neurônio
 - Parte linear
 - Ativação (não linear)
- Aprendizagem
 - Minimização de função de perda
$$L(f, f')$$
 - Backpropagation
 - Gradiente descendente
 - Necessita do gradiente



[*] Hornik, Kurt, Maxwell Stinchcombe, and Halbert White. "Multilayer feedforward networks are universal approximators." *Neural networks* 2.5 (1989): 359-366.

Signed Distance Functions (SDFs) neurais

- MLP: $f : \mathbb{R}^3 \rightarrow \mathbb{R}$
- Ground truth SDF: $f' : \mathbb{R}^3 \rightarrow \mathbb{R}$
- Função de perda: $L(f, f')$
- Sinusoidal Representation Networks (SIRENs) [1]
 - Ativações periódicas ($\sin(x)$)
 - Infinitamente diferenciáveis: $\sin'(x) = \cos(x)$, $\cos'(x) = -\sin(x)$
 - Permitem uso de derivadas na função de perda [2]
 - Contínuas e Suaves

[1] Sitzmann, Vincent, et al. "Implicit neural representations with periodic activation functions." *Advances in neural information processing systems* 33 (2020): 7462-7473.

[2] Novello, T., Schardong, G., Schirmer, L., da Silva, V., Lopes, H., & Velho, L. (2022). Exploring differential geometry in neural implicits. *Computers & Graphics*, 108, 49-60.

Signed Distance Functions (SDFs) neurais

- Pouca preocupação sobre tempo real
- Muitos trabalhos extraem de malhas no fim
 - Marching Cubes [*]
 - SDFs neurais são representações de transição?
- Perde-se propriedades das redes neurais
 - Continuidade
 - Suavidade

[*] We, LorenSen. "Marching cubes: A high resolution 3d surface construction algorithm." *Comput Graph* 21 (1987): 163-169.


Complicações da inferência em tempo real

- Inferência de rede neural = álgebra linear + não linearidades
 - Batch = matrizes
- Matrizes potencialmente grandes
- Sem suporte de hardware nativo no rendering
 - Shaders não lidam com matrizes $> 4 \times 4$
 - GPGPU

Inferência de redes neurais 101


Conceituação intuitiva

- Pesos
 - O que é aprendido de fato




Conceituação intuitiva

- Pesos
 - O que é aprendido de fato
- Camadas
 - O que é feito com o conhecimento aprendido



Na prática

- Matriz de pesos
 - Define como duas camadas se relacionam
- Camada
 - Operações entre as matrizes de pesos



Inferência de uma camada (parte linear)


$$\mathbf{z}^{(l)} = \mathbf{W}^{(l)} \mathbf{a}^{(l-1)} + \mathbf{b}^{(l)}$$


- Onde:
 - l é o índice da camada
 - $W^{(l)}$ é a matriz de pesos entre as camadas l e $l - 1$
 - $a^{(l-1)}$ é a matriz de entrada para a camada (vinda da computação da camada anterior)
 - $b^{(l)}$ é o viés, possibilita “transformações afim”

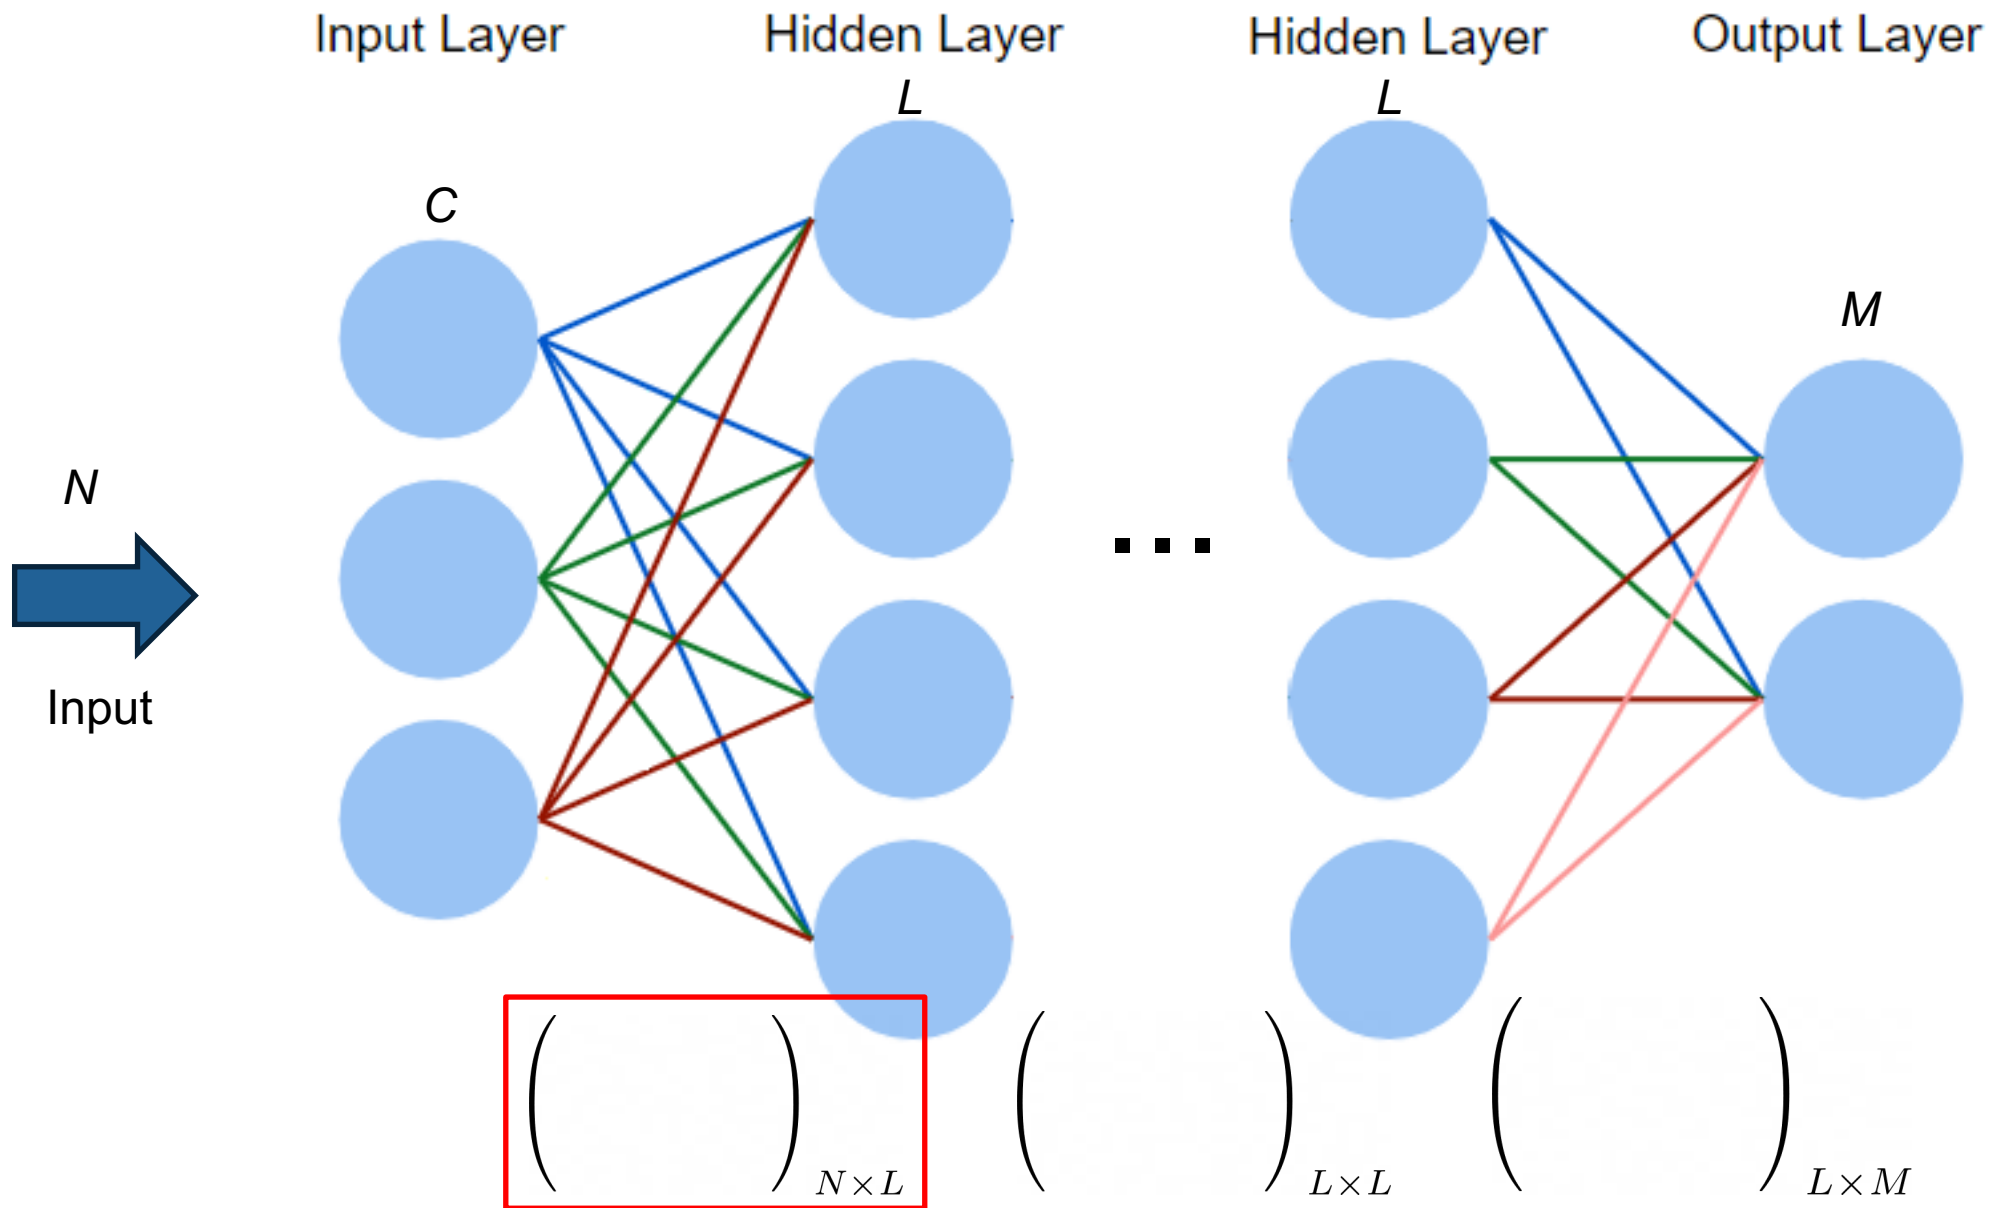
Inferência de uma camada (parte não-linear)


$$\mathbf{a}^{(l)} = \phi(\mathbf{z}^{(l)})$$


- Onde:
 - l é o índice da camada
 - $z^{(l)}$ é o parte linear da inferência
 - ϕ é a função de ativação (não-linear)
 - $\sin(x)$ nas SIRENs

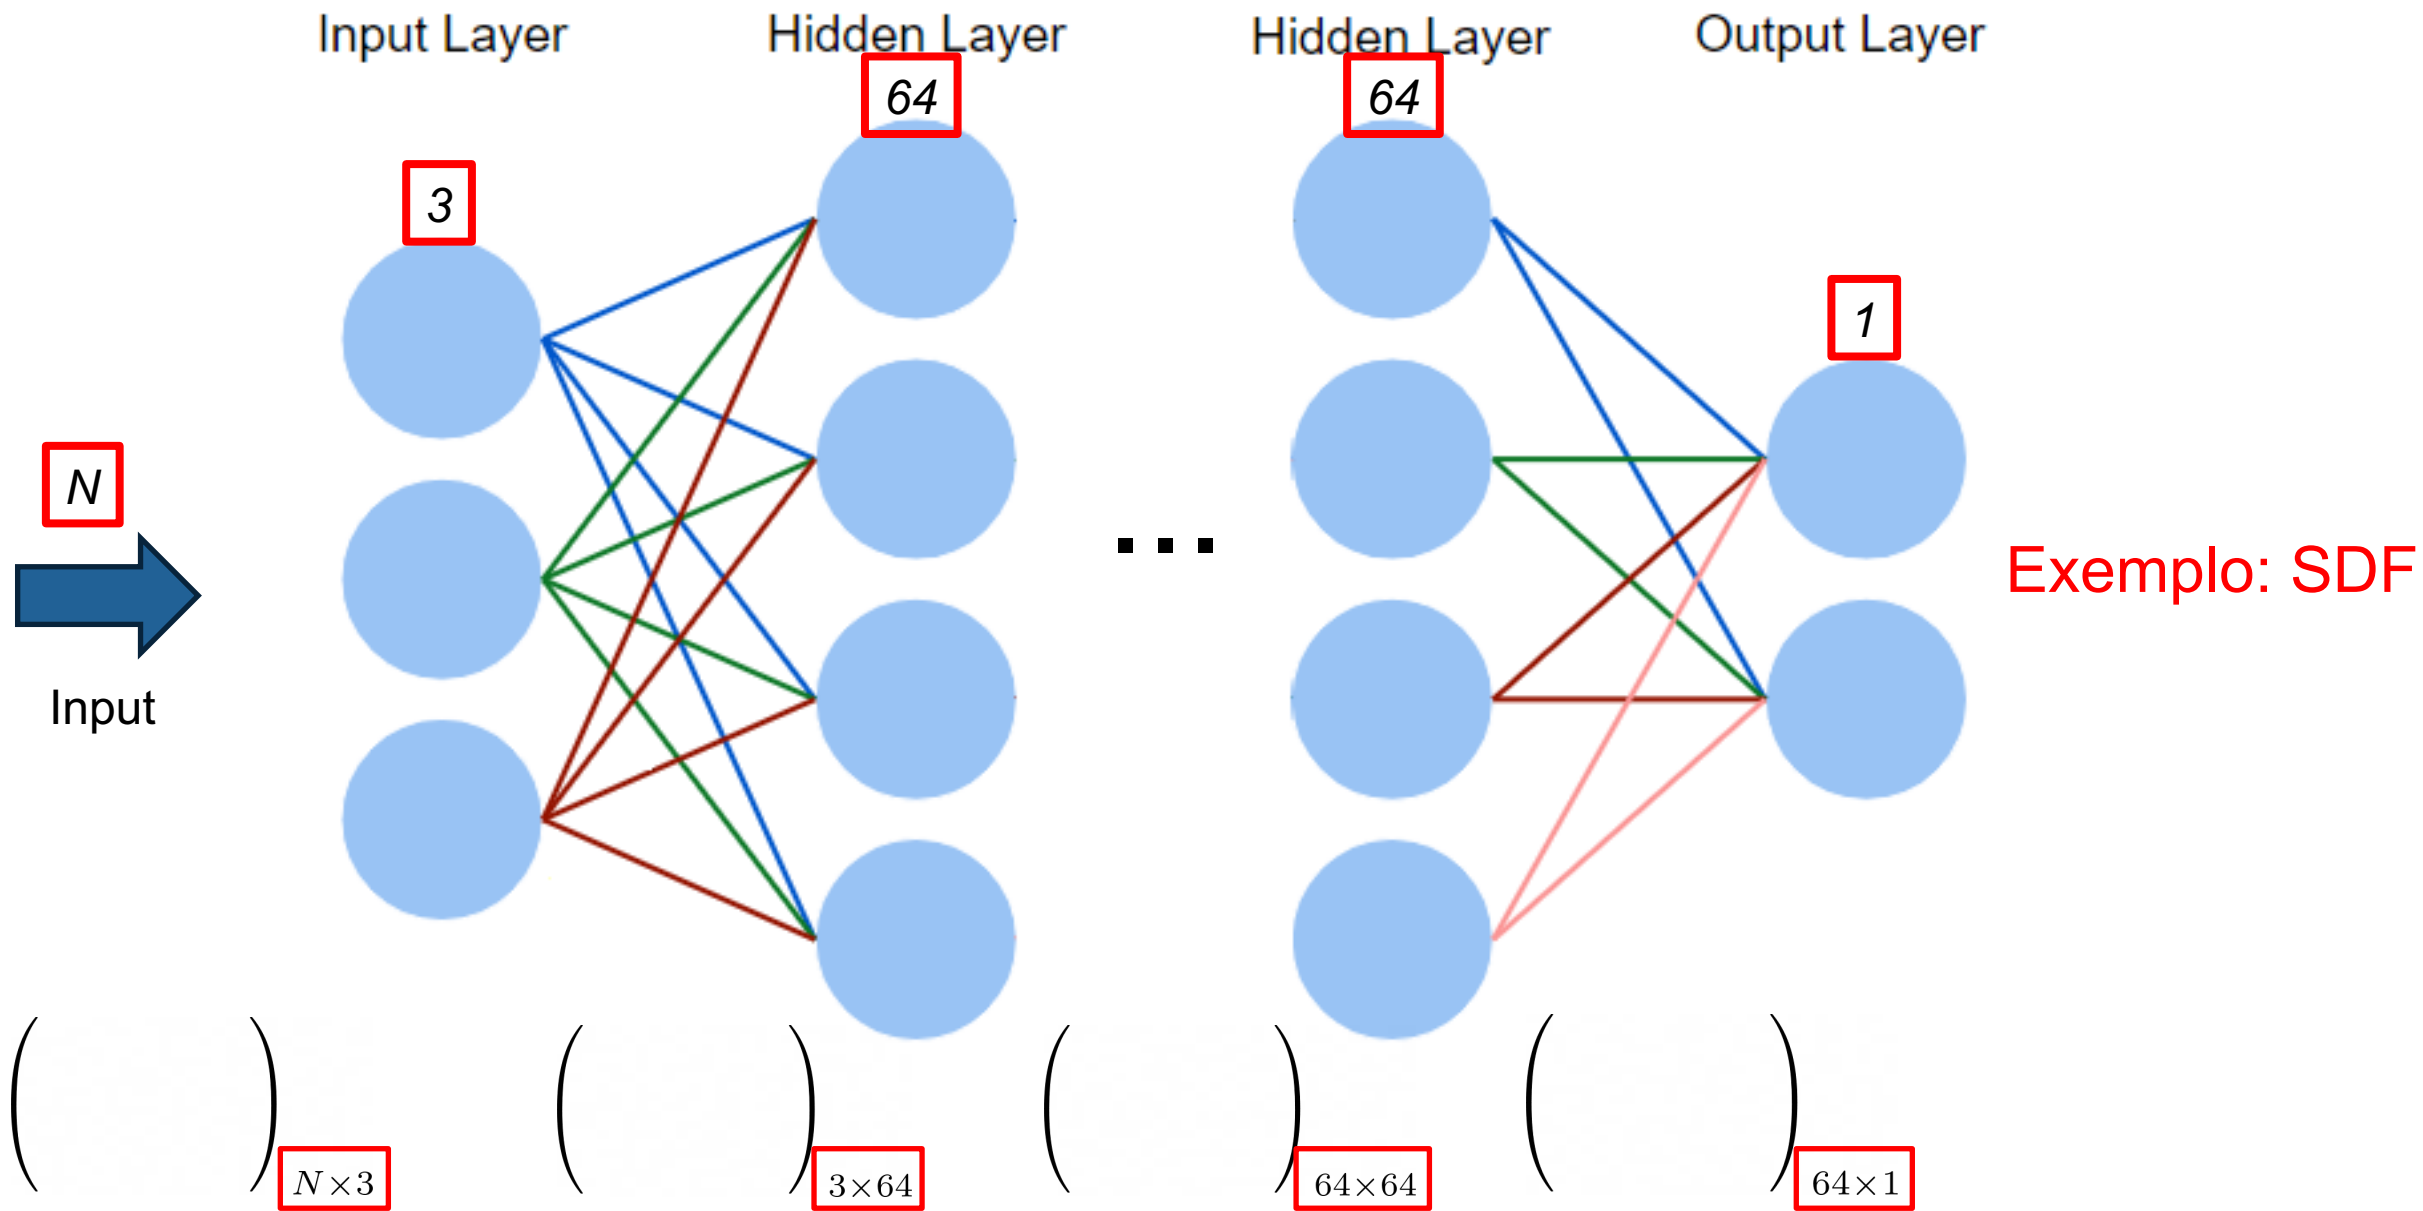












Por que isso importa?

- Medida para quantidade de computação na inferência
- Objetivo: melhor performance
 - Diminuir dimensões das matrizes e quantidade de multiplicações
 - Aumentar representatividade das redes

Neural Implicit Mapping via Nested Neighborhoods

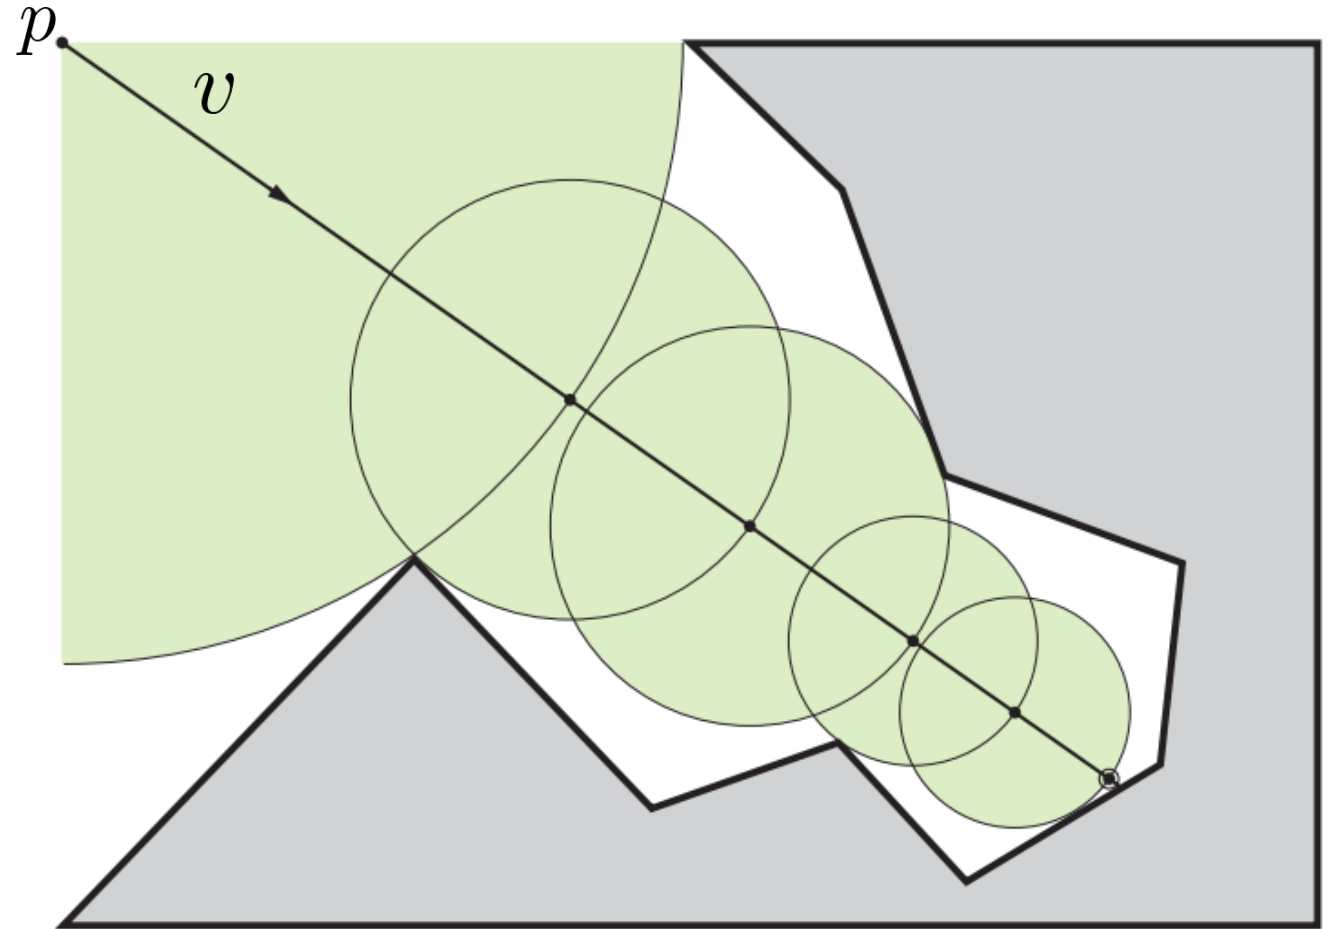
Ideias chave

- Diminuir dimensões das matrizes
 - Representação multiescala
 - Sphere tracing [*] multiescala
- Aumentar representatividade das redes
 - Atributos de superfície
 - Definidos na vizinhança tubular

[*] Hart, John C. "Sphere tracing: A geometric method for the antialiased ray tracing of implicit surfaces." *The Visual Computer* 12.10 (1996): 527-545.

Background: Sphere Tracing [*]

- Seja:
 - f uma Signed Distance Function (SDF)
 - $\gamma(t) = p + tv$ um raio de origem p e direção v
- Encontrar t onde $\gamma(t)$ intersecte a superfície $f = 0$



[*] Hart, John C. "Sphere tracing: A geometric method for the antialiased ray tracing of implicit surfaces." *The Visual Computer* 12.10 (1996): 527-545.

Background: Sphere Tracing [*]


- Algoritmo:

- Iterar usando

$$t_i = f(p_i)$$

$$p_{i+1} = p_i + t_i v$$

- Até chegar perto o suficiente



[*] Hart, John C. "Sphere tracing: A geometric method for the antialiased ray tracing of implicit surfaces." *The Visual Computer* 12.10 (1996): 527-545.

Background: Sphere Tracing [*]

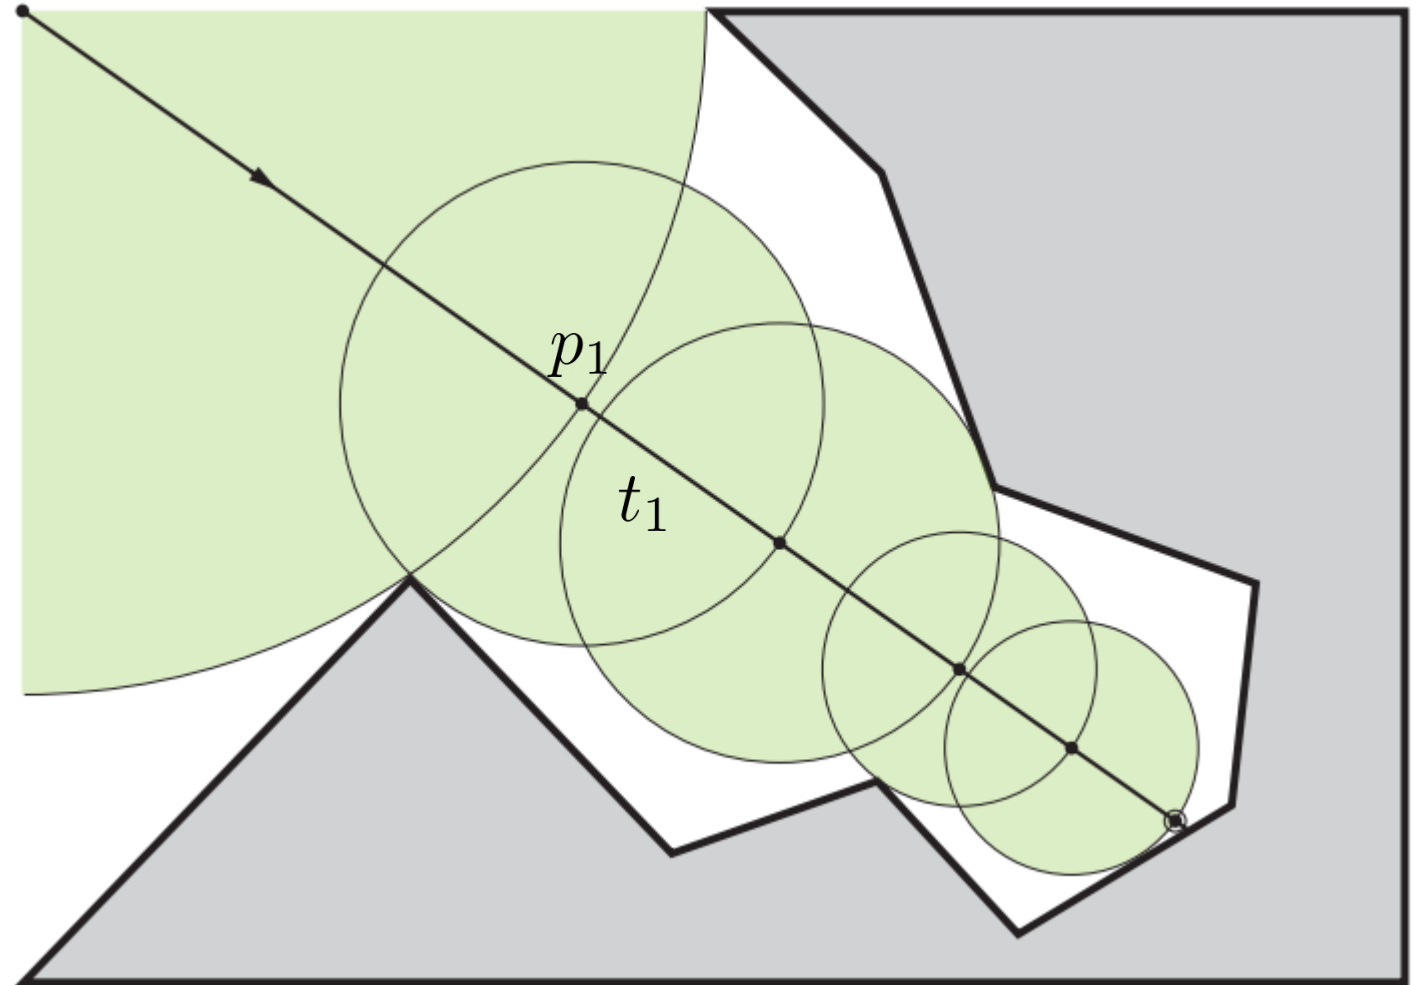
- Algoritmo:

- Iterar usando

$$t_i = f(p_i)$$

$$p_{i+1} = p_i + t_i v$$

- Até chegar perto o suficiente



[*] Hart, John C. "Sphere tracing: A geometric method for the antialiased ray tracing of implicit surfaces." *The Visual Computer* 12.10 (1996): 527-545.

Background: Sphere Tracing [*]


- Algoritmo:

- Iterar usando

$$t_i = f(p_i)$$

$$p_{i+1} = p_i + t_i v$$

- Até chegar perto o suficiente



[*] Hart, John C. "Sphere tracing: A geometric method for the antialiased ray tracing of implicit surfaces." *The Visual Computer* 12.10 (1996): 527-545.

Neural Implicit Mapping via Nested Neighborhoods


(Contribuições)

Sphere Tracing Multiescala

- Sphere Tracing é iterativo
 - Iterações rápidas = melhor performance
- Seja f uma SDF neural
 - Controle fino do trade-off de capacidade da rede
 - Diminuir tamanho das matrizes
 - **Viés espectral (Spectral Bias)**
 - Aumentar representatividade das redes
 - **Vizinhança tubular**
 - Não trivial usando SDFs clássicas

Viés espectral [*]

- Redes neurais têm viés para as frequências baixas
 - Elas são aprendidas primeiro
- Ideia: redes de menor capacidade como aproximação



1 matriz 64x64
(escondida)




3 matrizes 256x256
(escondidas)

[*] Rahaman, Nasim, et al. "On the spectral bias of neural networks." *International Conference on Machine Learning*. PMLR, 2019.

Vizinhas tubulares


- Sem supervisão da SDF no treinamento
- Seja:
 - f uma SDF de uma superfície S
 - p um ponto em S



Vizinhas tubulares

- Sem supervisão da SDF no treinamento
- Seja:
 - f uma SDF de uma superfície S
 - p um ponto em S
- A normal de S em p é dada por:

$$N(p) = \frac{\nabla f(p)}{\|\nabla f(p)\|}$$




Vizinhas tubulares

- Sem supervisão da SDF no treinamento
- Seja:
 - f uma SDF de uma superfície S
 - p um ponto em S
- A normal de S em p é dada por:

$$N(p) = \frac{\nabla f(p)}{\|\nabla f(p)\|}$$

- Se nos deslocarmos δ na direção $N(p)$:

$$p' = p + \delta N(p)$$




Vizinhas tubulares

- Sem supervisão da SDF no treinamento
- Seja:
 - f uma SDF de uma superfície S
 - p um ponto em S
- A normal de S em p é dada por:

$$N(p) = \frac{\nabla f(p)}{\|\nabla f(p)\|}$$

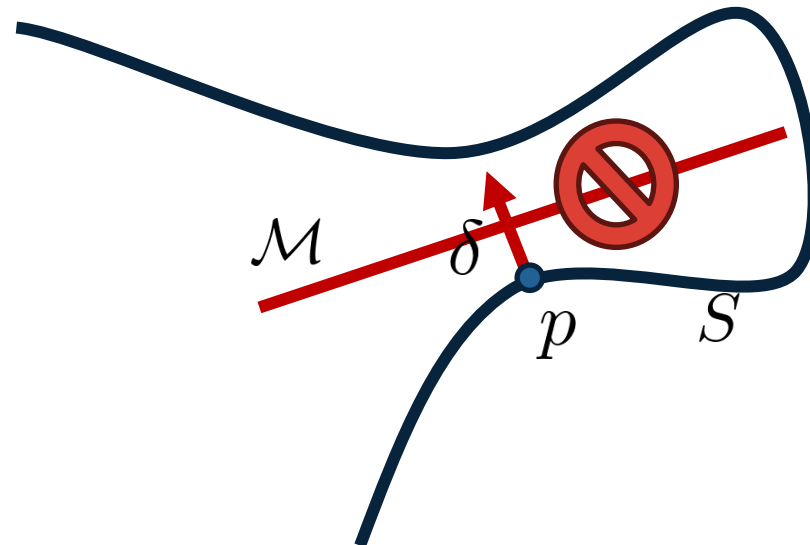
- Se nos deslocarmos δ na direção $N(p)$:
- $$p' = p + \delta N(p)$$
- Vemos que:

$$f(p') = f(p + \delta N(p)) = \delta$$




Vizinhas tubulares



- Importante: δ deve ser pequeno
 - Não pode passar o eixo medial \mathcal{M}



Treinamento na vizinhas tubular na prática




Treinamento na vizinhas tubular na prática




Vizinhas aninhadas

- Ideia: usar diferentes SDFs neurais no Sphere Tracing
- Seja:
 - S uma superfície
 - S_1 e S_2 versões mais grosseiras de S , ordenadas por capacidade de rede
- Intersecte vizinhanças de S_1 e S_2 antes de S
 - Menor custo por iteração
- Condição:
 - As vizinhanças devem estar aninhadas
 - Elimina falsos negativos



Atributos de superfície

- SDF restrita a uma vizinhança
 - Pode ser vista como um atributo
 - Não é constante ao longo do campo normal
- Podemos pensar em outros atributos
 - Normais
 - Texturas
 - Constantes ao longo do campo normal
$$g(p') = g(p), \forall p' = p + \delta N(p)$$
 - Onde δ varia na vizinhança




Neural attribute mapping

- Atributos de superfície
 - Podem ser mapeados para outra vizinhança
 - Transferência de atributos da vizinhança de uma superfície detalhada para a vizinhança de uma grosseira
 - Não requer parametrização
- Condição: aninhamento das vizinhanças


Framework de renderização

- Seja:
 - Superfícies S_1 , S_2 , S
 - Ordenadas por capacidade da rede
- Primeiro intersectamos a vizinhança de S_1 , chegando a q_1
- Então, intersectamos S_2 , chegando a q_2
- Finalmente mapeamos a normal N da vizinhança de S para q_2




Framework de renderização

- Observações
 - Para a última SDF avaliada antes do mapeamento intersectamos a superfície diretamente (S_2 no exemplo)
 - Mapeamento sem parametrização (atributo avaliado diretamente na coordenada q_2 , usando o gradiente da SDF de S)
 - N_2 é descartada




Resultados


Neural Normal Mapping



1 matriz 64x64



Mapping 3
matrizes 256x256



3 matrizes
256x256

Multiscale Sphere Tracing



1 matriz 64x64



Mapping 3
matrizes 256x256

2 matrizes 256x256,
mapping 3 matrizes 256x256


Normal mapping para malha




Mapping 3
matrizes 256x256

Marching cubes 1
matriz 64x64


Suavidade das normais



Comparação




Nosso



NGLOD [*], config.
tempo real

[*] Takikawa, Towaki, et al. "Neural geometric level of detail: Real-time rendering with implicit 3d shapes." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021.

Comparação




Nosso




NGLOD [*], config.
não é tempo real

[*] Takikawa, Towaki, et al. "Neural geometric level of detail: Real-time rendering with implicit 3d shapes." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021.

Comparação



Nosso




IDF [*], marching
cubes

[*] Wang, Yifan, Lukas Rahmann, and Olga Sorkine-Hornung. "Geometry-consistent neural shape representation with implicit displacement fields." *The Tenth International Conference on Learning Representations*. OpenReview, 2022.

Texture mapping



Texture mapping



**Neural Implicit Mapping via Nested
Neighborhoods: real-time rendering of
neural SDFs with textures**

O que não entraremos em detalhe


Cálculo de normais analítico baseado em GEMM [*]

- Gradiente no forward da rede
- Sem back-propagation
- Sem grafo computacional
- Baseado no algoritmo General Matrix Multiply (GEMM [*])

[*] Dongarra, Jack J., et al. "A set of level 3 basic linear algebra subprograms." *ACM Transactions on Mathematical Software (TOMS)* 16.1 (1990): 1-17.

SDFs neurais dinâmicas

- 4D: parâmetro tempo
- Famílias de SDFs [*]
- Aninhamento das famílias



[*] Novello, T., Da Silva, V., Schardong, G., Schirmer, L., Lopes, H., & Velho, L. (2023). Neural Implicit Surface Evolution. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 14279-14289).

Problemas em aberto

Localização

- Superfície tende a ser suavizada
 - SDF global
- Tentativas de localização atualmente geram artefatos
 - Estruturas de aceleração descontínuas (Octrees)
- Gaussianas são uma opção?



NGLOD [*], config.
tempo real

[*] Takikawa, Towaki, et al. "Neural geometric level of detail: Real-time rendering with implicit 3d shapes." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021.

Edição

- Malhas são facilmente editáveis
- SDFs neurais ainda não
- Treinamento progressivo?
 - Instant NGP[*]

[*] Müller, Thomas, et al. "Instant neural graphics primitives with a multiresolution hash encoding." *ACM Transactions on Graphics (ToG)* 41.4 (2022): 1-15.

Animação

- Já é possível treinar SDFs dinâmicas
 - Neural Implicit Surface Evolution [*]
- É preciso mais controle
 - Key-frames?
 - Localização temporal (interpolação?)
 - Localização espacial (bones?)
 - Desafio: manter propriedades de SDF

[*] Novello, T., Da Silva, V., Schardong, G., Schirmer, L., Lopes, H., & Velho, L. (2023). Neural Implicit Surface Evolution. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 14279-14289).

Frutos do Neural Media

- Neural Implicit Surface Evolution [1]
 - ICCV 2023
- Neural Implicit Morphing of Face Images [2]
 - **Aceito no CVPR 2024!**




[1] Novello, T., Da Silva, V., Schardong, G., Schirmer, L., Lopes, H., & Velho, L. (2023). Neural Implicit Surface Evolution. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 14279-14289).

[2] Schardong, Novello, Paz, Medvedev, Da Silva, Velho, Gonçalves. "Neural Implicit Morphing of Face Images." *CVPR 2024. To appear.*



Mais informações e
colaborações:

Vinícius da Silva
viniciuss@tecgraf.puc-rio.br



<https://dsilvavinicius.github.io/>