



# DEEP LEARNING

## CASE STUDIES

# *ANN & DNN*

## *Machine Learning & Deep Learning*

- Processo indutivo
- Refinamento sucessivo
- Aprende com os dados
- Ajuste sucessivo de um modelo com base em amostras
  - Em alguns casos com acompanhamento do professor
    - Aprendizagem supervisionada (classificando de acordo com referências externas)
  - Em outros casos pela proximidade relativa dos dados
    - Aprendizagem não supervisionada (formando clusters naturais)

# *DNN*

## *Deep Learning*

- Máquina que frente a um número gigantesco de evidencias é capaz de sumarizar a essência daquilo que lhe é apresentado
  - fase de aprendizagem
- E a partir de então é capaz de aplicar seu aprendizado numa tarefa
  - Fase de síntese (*deployment*)


# *DNN*

## *Deep Learning*



### **A favor**

Coerência entre amostras de um mesmo fenômeno que se quer reconhecer  
Sempre que houver estrutura subjacente



### **Contra**

Espaço amostral muito pequeno em relação a todo o conjunto  
Ruídos / incertezas nas medidas

# *DNN* *Deep Learning*



**Reconhecer algo**

**Imagem**

**Vídeo**

**Movimento**

**Comportamento**



**Sintetizar algo**

**Imagem**

**Vídeo**

**Movimento**

**Comportamento**

# *DNN* *Deep Learning*



**Reconhecer algo**  
**Aprender**

**Tratado como unidade**  
**Ex: vídeo é um pacote de imagens**



**Sintetizar algo**  
**Fazer**

**Tratado como unidade**  
**Ex: vídeo é um pacote de imagens**

# DNN

## Deep Learning



Sistema físico

Sistema social

Sistema biológico

E suas regras / leis de comportamento

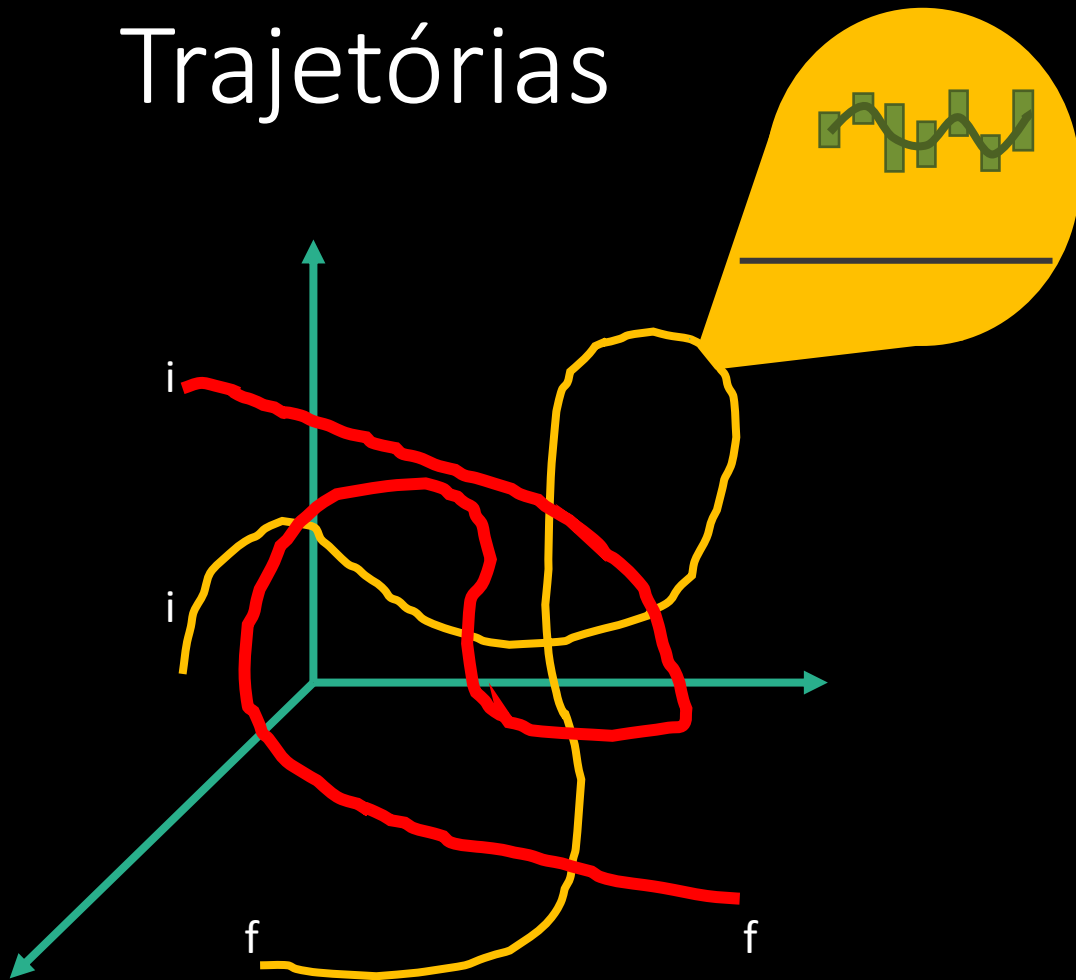


Evolução Espaço-Temporal  
(mapa de estados)

apresenta coerência / alta correlação

próximo estado provavelmente se encontra na vizinhança  
do estado anterior

# Espaço de Estados Trajetórias



Sistema com 3 dimensões (entradas)

A saída poderia estar representada na intensidade da cor ao longo da linha (não representada no desenho)

ex: intervalos de valores de 7 medidas na sequência

Evolução temporal do sistema dinâmico

Sucessão de pontos visitados pelo sistema num período

Caso 1

Caso 2



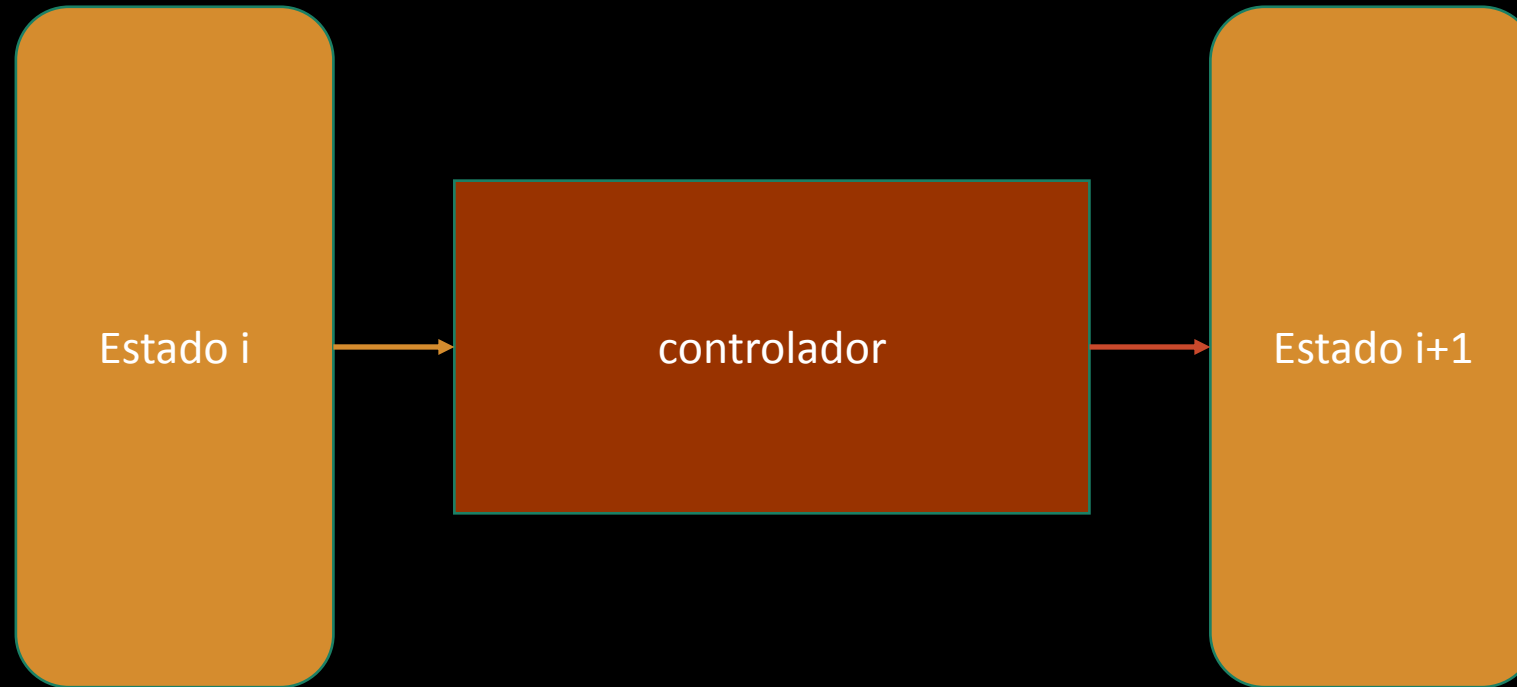
# Espaço de Estados

## Trajétórias

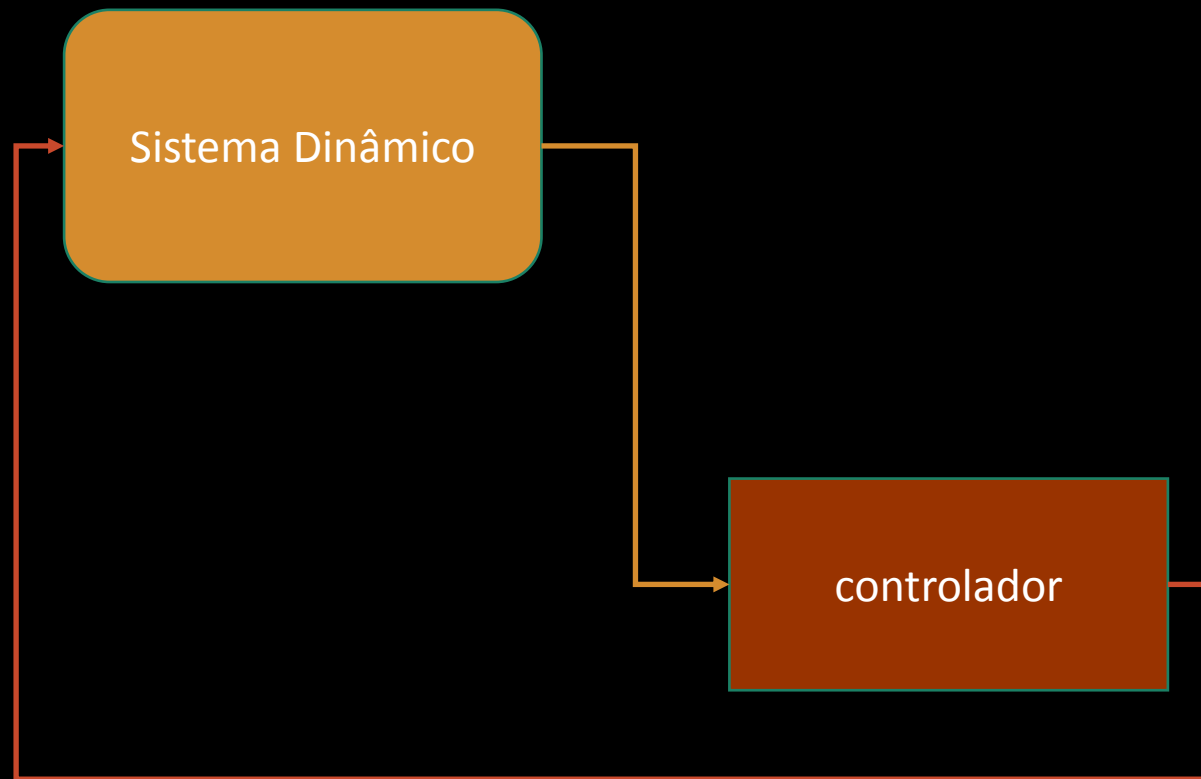
- Quando pensamos numa imagem ou numa pose podemos associa-las a um ponto num espaço de estados
  - Diferentes imagens são representadas em diferentes pontos
  - Imagens semelhantes correspondem a pontos próximos
  - Dentro de certas tolerâncias reconhecemos pontos de uma certa vizinhança como de uma mesma categoria (ou mesmo objeto a menos das pequenas variações)
  - Numa vizinhança maior podemos incluir estilos ou grupos
- Quando pensamos num vídeo ou num comportamento podemos associa-las a trajetórias no espaço de estados
  - Diferentes sequencias são representadas por diferentes trajetórias

# Sistemas Dinâmicos

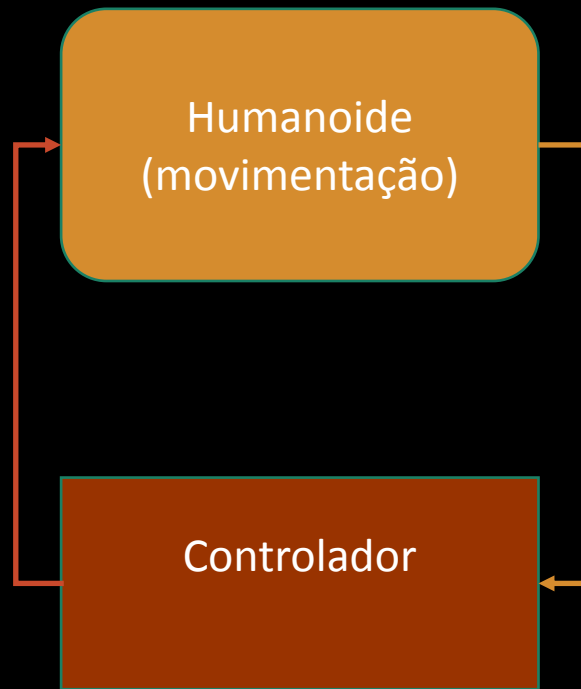
## Simuladores / Controladores



# Sistemas Dinâmicos Simuladores / Controladores

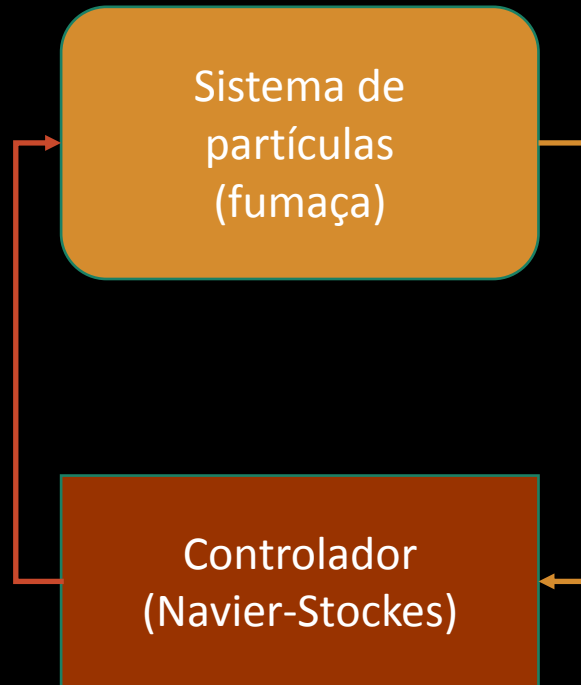


# Sistemas Dinâmicos Simuladores / Controladores




# Sistemas Dinâmicos

## Simuladores / Controladores

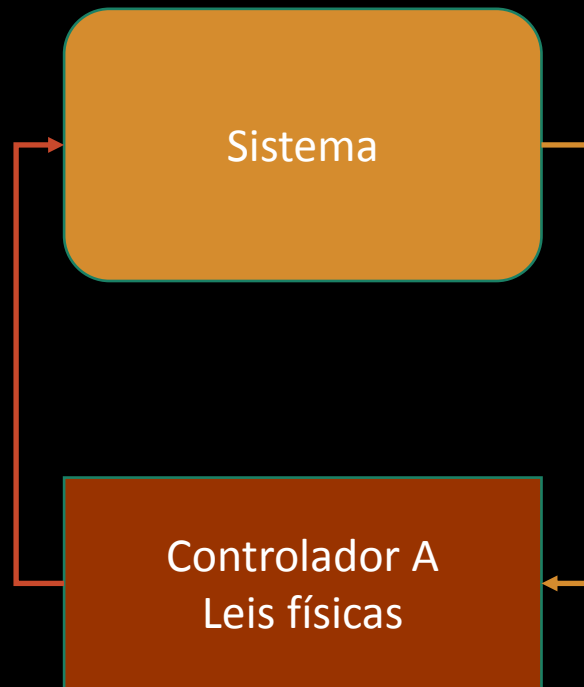


# Sistemas Dinâmicos Simuladores / Controladores



# Sistemas Dinâmicos

## Simuladores / Controladores



# Sistemas Dinâmicos

## Simuladores / Controladores

### Controlador A – simulação segundo leis físicas

- descritores do fenômeno físico observado estão incorporados as leis físicas usadas
- método tradicional
- é preciso entender (ser capaz de explicar o fenômeno)
- e então generalizar tal conhecimento na forma de uma lei



# Sistemas Dinâmicos

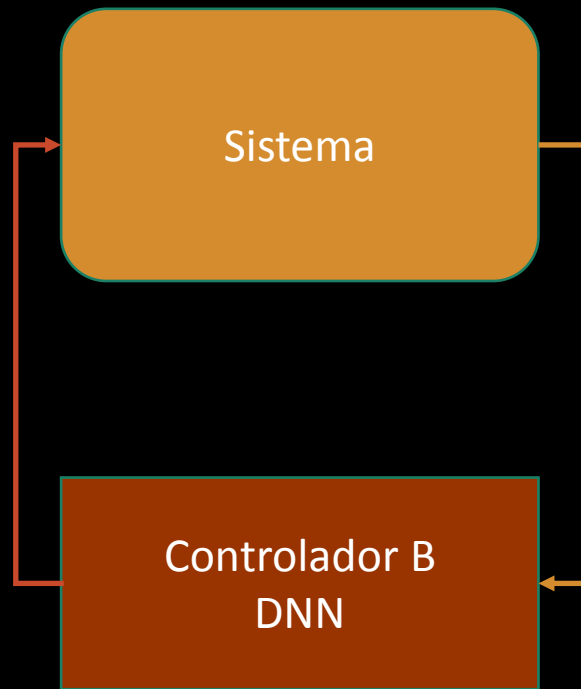
## Simuladores / Controladores

### Controlador A – simulação segundo leis físicas

- Importante observar o passo (intervalo) computacional para produzir a evolução do que se observa
- Questão de ordem prática para evitar que o sistema acabe divergindo da expectativa (trajetória se afaste da esperada), na medida em que a simulação é uma aproximação de tempo discreto de um fenômeno provavelmente contínuo
- Por exemplo movimentação de uma partícula sobre efeito de um campo (forças)
- Correções podem ser feitas com alguma periodicidade

# Sistemas Dinâmicos

## Simuladores / Controladores (*Deep Learning*)




# Sistemas Dinâmicos

## Simuladores / Controladores (*Deep Learning*)

Controlador B – simulação segundo coerência espaço temporal

- precisa ser treinado para adquirir os descritores que regem o fenômeno físico observado
- novo método que vem revolucionando muitas aplicações
- basta ser capaz de observar exaustivamente e então replicar o fenômeno
- ou produzir um fenômeno que tenha na sua essência algo que seja típico dos fenômenos previamente observados

# Redes Neurais aproximadores universais de funções arbitrárias



Rede Neural:

Aproximador de funções arbitrárias, devido a não linearidade intrínseca ao neurônio

Procura pela função que melhor se ajusta aos pontos observados

$y = f(x, w)$  onde  $w$  é um parâmetro de ajuste e  $f$  a função de mapeamento  $x \rightarrow y$

# Redes Neurais

## aproximadores universais de funções arbitrárias

- Observem que a curva (função aproximada) uma vez obtida, pode ser avaliada para qualquer valor de  $x$ , extrapolando o universo inicial observado (conjunto de pontos de treinamento)
- Ou seja, a função (se bem encontrada e representativa) tem enorme valia para predizer os valores de  $y$  para quaisquer valores de  $x$

# Deep Neural Networks

## Convolutional Neural Networks

DNN/CNN – extrai atributos descritivos do fenômeno observado

- Isso é feito no processo de aprendizagem (treinamento)

Síntese com DNN treinada

- No caso dos movimentos dos fluidos, isso significa ser capaz de indicar o novo estado de ocupação espaço temporal, a partir do conhecimento do estado atual e dos descritores (implícitos nos pesos da rede) adquiridos ou ajustados com o treinamento anterior

# Deep Neural Networks

## Convolutional Neural Networks

### DNN

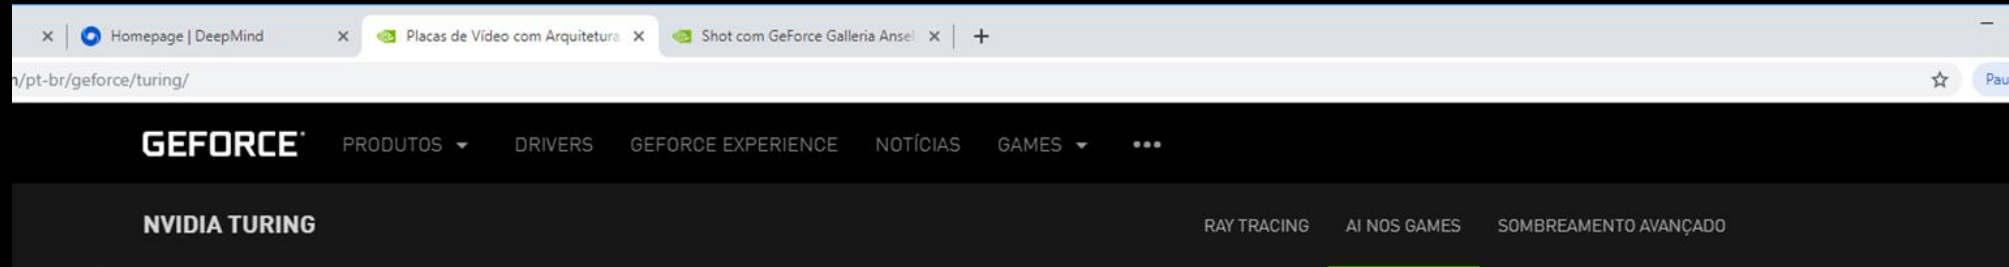
- possuem múltiplas camadas
- normalmente teriam todas as conexões possíveis entre duas camadas sucessivas
- ótimas para generalizar, mas difíceis de treinar

### CNN

- possuem múltiplas camadas
- possuem apenas algumas das possíveis conexões entre duas camadas sucessivas (clusters), e com isso atuam reduzindo a dimensionalidade do problema a cada passo
- ainda são boas para generalizar, e mais fáceis de treinar

# CNN

## Redes Convolucionais



### GRÁFICOS APRIMORADOS PELA MAIS ATUAL IA

A inteligência artificial está impulsionando o maior avanço tecnológico da história, e a arquitetura Turing está levando esse avanço para a computação gráfica. Equipada com Tensor Cores que podem proporcionar mais de 100 TFLOPs de potência de computação para IA. As GPUs Turing podem executar algoritmos de IA poderosos em tempo real para criar imagens nítidas, claras e realistas, bem como efeitos especiais até então impossíveis.








# Discussão



Quão generalistas conseguiremos ser quando procurando usar redes neurais para resolver problemas?



Basta conseguirmos representar todos os parâmetros que influenciam num comportamento, e ter capacidade computacional, e dados suficientes para treinar as redes? Para podermos então usá-las nas previsões que queiramos fazer no contexto dos cenários propostos



ACM SIGGRAPH 2017  
annual conference – paper videos  
preview

# Deep Learning

## Aplicações


### Movimento de corpo rígido ou articulado (mecânica)

- cinemática e dinâmica
- Bipe (aprendendo a andar)

### Movimento em fluidos (mecânica dos fluidos)

- Navier-Stokes solver
- linear e/ou turbulento
- grids ou partículas

ACM  
SIGGRAPH  
2017  
Autonomous  
Characters





DeepLoco: Dynamic Locomotion Skills Using Hierarchical Deep Reinforcement Learning

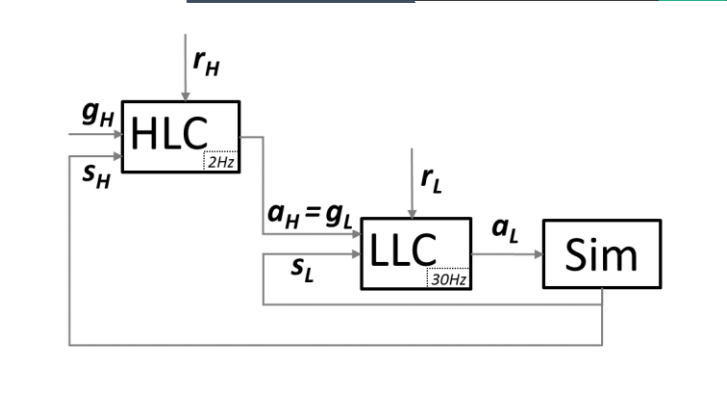




- *Xue Bin Peng, Glen Berseth, Kangkang Yin, Michiel Van De Panne*  
Article: [[pdf](#)] Supplemental Material: [[zip](#)]

Rede hierárquica (dois níveis) de controladores

- Um para planejamento – longo termo
- Um para ação – curto termo

ACM  
SIGGRAPH  
2017  
Autonomous  
Characters





# ACM SIGGRAPH 2017 Autonomous Characters

ACM  
SIGGRAPH  
2017  
Fluids

## Fluido Dinâmica Computacional

- fluxos turbulentos – particularmente difíceis para NN pois tem um comportamento caótico
  - aparentemente ruidoso, embora siga uma lei difícil de ser extraída
  - não trataremos destes detalhes aqui
  - mas explora similaridade entre representações de alta e baixa granularidade
  - permitindo gerar simulacoes de alta granularidade a partir de outras de menor granularidade

# ACM SIGGRAPH 2017

## Deep Learning Fluids

### Data-Driven Synthesis of Smoke Flows with CNN-based Feature Descriptors



- *Mengyu Chu, Nils Thuerey*  
Article: [[pdf](#)] supplemental  
Material: [[zip](#)]

### Variação da densidade ao longo do Espaço-Tempo

- Densidade / Viscosidade / Fluxo /  
Pressão / ....
- Aprendizado de similaridade dos  
fluxos







# ACM SIGGRAPH 2019 annual conference – paper videos preview

<https://www.youtube.com/watch?v=EhDr3Rs5fT>  
U

ACM  
SIGGRAPH  
2019  
Neural  
Rendering

Neural Volumes: Learning Dynamic Renderable Volumes from Images

- *Stephen Lombardi, Tomas Simon, Jason Saragih, Gabriel Schwartz, Andreas Lehrmann, Yaser Sheikh*

Article: [[pdf](#)]

Auxiliary Material: [[zip](#)]

Auxiliary Video: [[mp4](#)] [065](#)

ACM  
SIGGRAPH  
2019  
Neural  
Rendering

Deferred Neural Rendering: Image Synthesis using  
Neural Textures

- *Justus Thies, Michael Zollhöfer, Matthias Niessner*

Article: [[pdf](#)]

Auxiliary Video: [[mp4](#)] [066](#)

ACM  
SIGGRAPH  
2019  
Capture &  
Control

Learning to Fly: Computational Controller Design  
for Hybrid UAVs with Reinforcement Learning

- *Jie Xu, Tao Du, Michael Foshey, Beichen Li,  
Bo Zhu, Adriana Schulz, Wojciech Matusik*

Article: [[pdf](#)]

Auxiliary Video: [[mp4](#)] [042](#)

ACM  
SIGGRAPH  
2019  
Image Science

## Hyperparameter Optimization in Black-box Image Processing using Differentiable Proxies

- *Ethan Tseng, Felix Yu, Yuting Yang, Fahim Mannan, Karl St. Arnaud, Derek Nowrouzezahrai, Jean-François Lalonde, Felix Heide*

Article: [[pdf](#)]

Auxiliary Material: [[zip](#)]

Auxiliary Video: [[mp4](#)] [027](#)

ACM  
SIGGRAPH  
2019  
Learning to  
Move

Learning Character-Agnostic Motion for Motion Retargeting in 2D

- *Kfir Aberman, Rundi Wu, Dani Lischinski, Baoquan Chen, Daniel Cohen-Or*

Article: [[pdf](#)]

Auxiliary Video: [[mp4](#)] [075](#)

ACM  
SIGGRAPH  
2019  
Relighting &  
View Synthesis

## Deep Reflectance Fields High-Quality Facial Reflectance Field Inference from Color Gradient Illumination

- *Abhimitra Meka, Christian Häne, Rohit Pandey, Michael Zollhöfer, Sean Fanello, Graham Fyffe, Adarsh Kowdle, Xueming Yu, Jay Busch, Jason Dourgarian, Peter Denny, Sofien Bouaziz, Peter Lincoln, Matt Whalen, Geoff Harvey, Jonathan Taylor, Shahram Izadi, Andrea Tagliasacchi, Paul Debevec, Christian Theobalt, Julien Valentin, Christoph Rhemann*

Article: [[pdf](#)]

Auxiliary Video: [[mp4](#)] [077](#)

ACM  
SIGGRAPH  
2019  
Relighting &  
View Synthesis

Multi-view Relighting using a Geometry-Aware Network

- *Julien Philip, Michaël Gharbi, Tinghui Zhou, Alexei A. Efros, George Drettakis*  
Article: [[pdf](#)]  
Auxiliary Material: [[zip](#)]  
Auxiliary Video: [[mp4](#)] [078](#)



ACM  
SIGGRAPH  
2019  
Deep End

MeshCNN: A Network with an Edge

- *Rana Hanocka, Amir Hertz, Noa Fish, Raja Giryes, Shachar Fleishman, Daniel Cohen-Or*  
Article: [[pdf](#)]  
Auxiliary Video: [[mp4](#)] [090](#)

ACM  
SIGGRAPH  
2019  
Animation &  
Skinning

NeuroSkinning: Automatic Skin Binding for  
Production Characters with Deep Graph Networks

- *Lijuan Liu, Youyi Zheng, Di Tang, Yi Yuan, Changjie Fan, Kun Zhou*

Article: [[pdf](#)]

Auxiliary Material: [[zip](#)]

Auxiliary Video: [[mp4](#)] [114](#)

## Tarefa D

### Tema Livre

texto (pdf) ~2 pgs

slides (pdf) ~2

1 caso / aplicação

2 RN

(restrições versus generalização)

- Com base nos exemplos mostrados em aula, identifique um tipo de problema que pareça interessante para ser tratado com redes neurais.
- Analise a generalidade da proposta, e explique qual o cenário que está considerando para a sua implantação. E quais restrições está assumindo que sejam necessárias.
- Diga o que seria considerado como informação de E/S para a rede neural .
- Diga então como poderia ser seu treinamento. Qual seria a atuação do professor num processo de aprendizagem supervisionada. Considere a possibilidade de fazer ajustes nos dados para tornar mais fácil os treinamentos, conforme visto em alguns dos exemplos em aula.
- Exponha duas razões que considere críticas (difíceis) para o sucesso desta solução.
- Exponha duas razões que pareçam ser boas justificativas para usar redes neurais neste caso.

## Tarefa E

### Veículos Autônomos

texto (pdf) ~2 pgs

slides (pdf) ~2

1 caso / aplicação

2 RN

(restrições versus generalização)

- Proponha uma arquitetura de controle para veículos autônomos composta por um ou mais módulos de controle, como visto nos exemplos de aula (HLC e LLC)
- Analise se a proposta feita se encaixa melhor em condições particulares de trânsito (ex: estrada) ou quão genérica consegue ser.
- Diga o que seria considerado como informação de E/S para cada módulo
- Considere a implantação de tais módulos com redes neurais e diga então como poderia ser seu treinamento (que informações seriam usadas)
- Exponha duas razões que considere críticas (difíceis) para o sucesso desta solução
- Discorra sobre quão factível parece ser o uso de Deep Learning para tratar desta questão, ou seja quão difícil seria fazer as previsões necessárias para condução autônoma do veículo (incertezas, ...)

# Deep Learning – Ferramentas



Ambientes de Programação



Modelagem do Problema

ferramentas visuais (tipo LabView)



# Deep Learning Arquiteturas

---

## CPU

- arquitetura generalista / multipropósito
- C / C++ / Java / Python

## GPU

- arquitetura semidedicada / fluxo de dados (streaming)
- rendering (CG) / deep learning
- CUDA / ...

# Case

## SMART TRACK – BMW Project



***Smart Driver Assistance***



**Traffic condition forecast**



**ANN**

Training data sets (history)

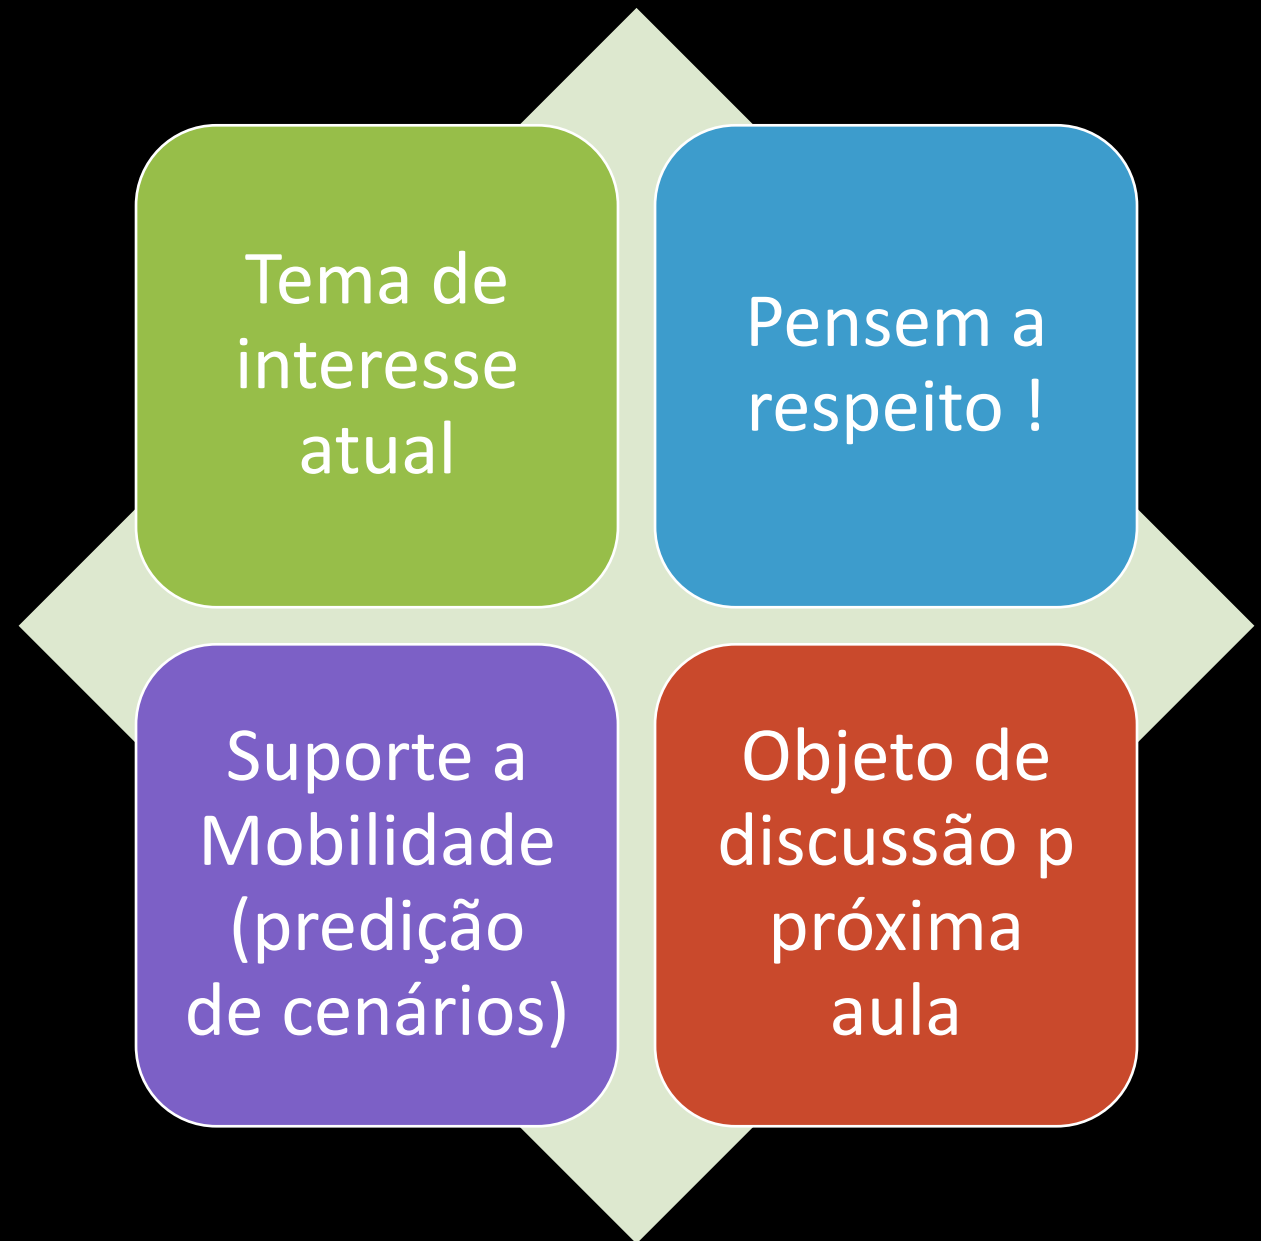
rain & traffic conditions

Searching for event correlations

Deployment (real time)

traffic forecast

# Deep Learning – Direção Autônoma





# Exercício

texto (pdf)

~3 pgs

slides (pdf)

~3

modelo

restrições

generalidades

## Cenário:

- Mobilidade Urbana
  - Escolha um problema
    - Multi-modal
    - Bikes & Scooters
    - Rotas Ônibus
    - Aplicativos ....
  - Identifique parâmetros importantes
  - Identifique uma métrica para quantificar a questão
    - Considere que tenha como obter as medidas para sua função de fitness
- Apresente uma proposta para representar estes parâmetros de modo conveniente para treinar uma rede neural
  - Analise quão flexível parecer ser a proposta para poder ser estendida a outros casos da mesma natureza
    - Ex: Outras regiões da cidade
  - Discorra sobre quão factível parece ser o uso de Deep Learning para tratar desta questão
    - Consigo fazer as previsões que gostaria de fazer?

# SMART TRACK Presentation (slides)


# GP-GPU Presentation (slides)



ELSEVIER


Journal of Computational Physics

Volume 380, 1 March 2019, Pages 442-463



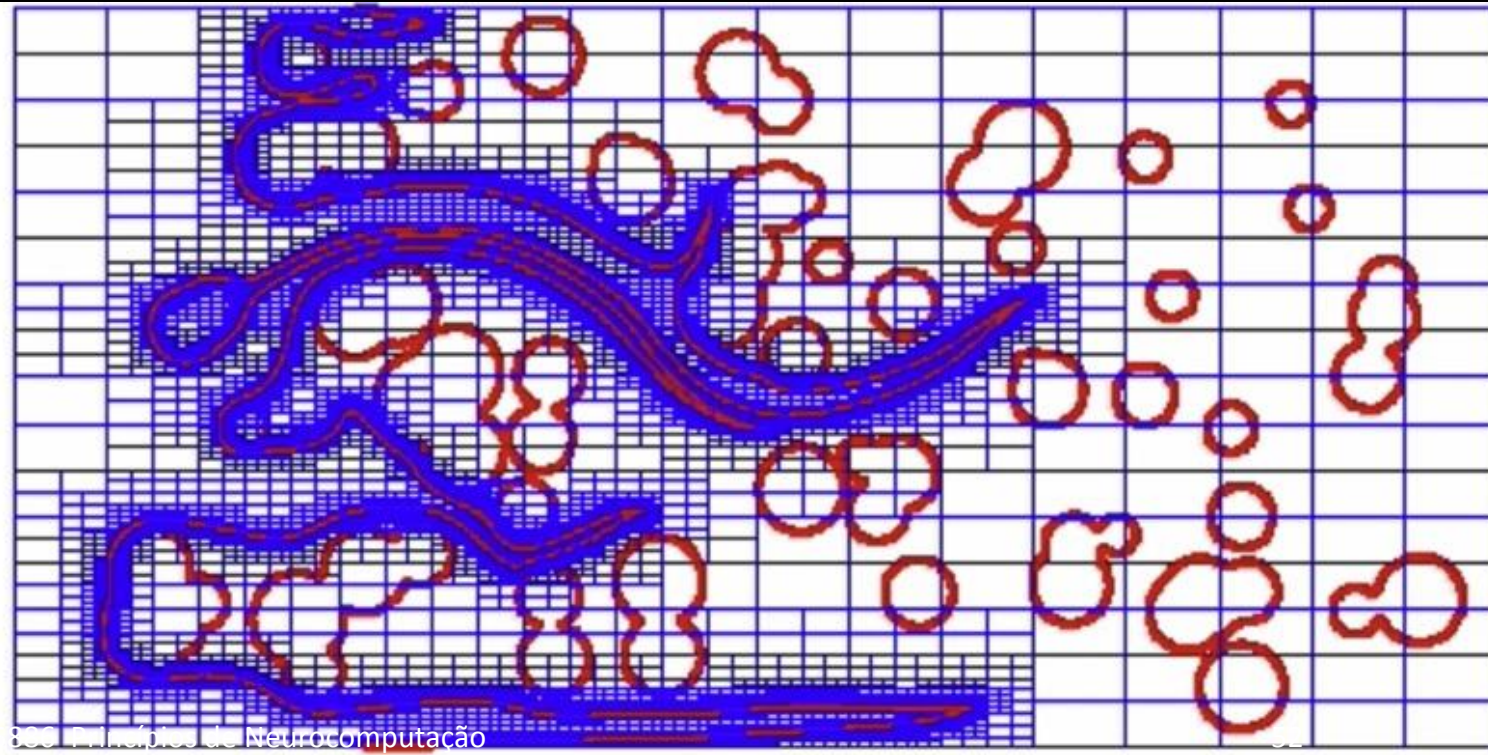
## Sharp interface approaches and deep learning techniques for multiphase flows

Author links open overlay panel [Frederic Gibou<sup>ab</sup>](#) [David Hyde<sup>c</sup>](#) [Ron Fedkiw<sup>c</sup>](#)  
<https://doi.org/10.1016/j.jcp.2018.05.031> [Get rights and content](#)



2019

Marcio Lobo Netto



800 - Princípios de Neurocomputação