

# Tracking de Sub Partículas Atômicas Baseada em Modelos Deep Learning

Steve Ataucuri Cruz  
Jefferson Fialho

Advanced Institute for Artificial Intelligence  
São Paulo - Brasil

9 de março de 2020


- Melhoras no treino e configuração a partir de JSON
- Errores corrigidos e bugs.
- Agregada funcionalidades de Visualizações com Polares.
- Agregada suporte para redes: Convolucionais (CNN) e Multi Layer (MLP).
- Agregada suporte notebooks para rodar em Google Colab(Externamente).

- **Base de Dados:** Partículas *15192*.
- **Divisão dados:** 80%, 20%
- **Três experimentos com. Previsão Univariada.**
  - Experimento LSTM.
  - Experimento CNN.
  - Experimento MLP.

## Experimento I: Previsão Univariada - Coord Cartesianas

- **Previsão:**  $P_{h+1} = F(s_h)$  ,  $h = 4$
- **Características:** Posições do Hit.
- **LSTM paralel:** 2 camadas paralelas 400, densa, dropout, densa, dropout, camada saída: 3, função: ReLU, **otimizador:** adam, rmsprop, **loss:** mean squared error.
- **LSTM stack:** 2 camadas ocultas 400 neurônios, camada saída: 3 neurônio, função: ReLU, **otimizador:** Adam, rmsprop, **loss:** mean squared error.


## Experimento I: Previsão Univariada - Coord Cartesianas



## Experimento I: Previsão Univariada - Coord Cartesianas

- **Previsão:**  $P_{h+1} = F(s_h)$  ,  $h = 4$
- **Características:** Posições do Hit.
- **CNN:** 1 camada Conv1D (filtro: 64, kernel: 2), Maxpooling, Flatten, densa(20), saída densa: 3, função: ReLU, **otimizador:** rmsprop, **loss:** mean squared error.

## Experimento I: Previsão Univariada - Coord Cartesianas



## Experimento I: Previsão Univariada

Modelo	MAE	RMSE	RMSE-vector	R <sup>2</sup>
Modelos Deep - Cartesiano				
LSTM paralelo	0.072	0.135	<b>[0.19, 0.11, 0.09]</b>	0.981
LSTM	0.056	0.103	<b>[0.12, 0.09, 0.10]</b>	0.989
CNN	0.066	0.144	<b>[0.15, 0.18, 0.07]</b>	0.978
Modelos Deep - Polares				
LSTM paralelo	0.078	0.14	<b>[0.19, 0.09, 0.12]</b>	0.98
LSTM	0.08	0.148	<b>[0.13, 0.20, 0.10]</b>	0.977



- Previsão Multi-step Multivariada
- **Previsão:**  $t = 1, h = 4$   
$$P_{h+t} = F([s_h, s_{h-1}, s_{h-2}, s_{h-3}, s_{h-4}])$$
- Testar com dados de Track complicados.
- Implementar Modelos híbridos LSTM-CNN.
- Utilizar a métrica de Kaggle.

# Preparação dos dados

- Dada uma sequência
- Para treino (entrada anterior) :

H11 H12 H13 H14 H15  
H21 H22 H23 H24 H25

H11 H12 H13 H14 H15  
H21 H22 H23 H24 H25

# Preparação dos dados

- Dada uma sequência
- Para treino (entrada nova) :

H1 H2 H3 H4 H5 H6 H7 H8 H9 H10

H1 H2 H3 H4 H5

H2 H3 H4 H5 H6

H3 H4 H5 H6 H7

H4 H5 H6 H7 H8

H5 H6 H7 H8 H9

H6 H7 H8 H9 H10

A1 A2 A3 A4 A5 A6 A7 A8 A9 A10

## Experimento I: Previsão Multi step

Modelo	MAE	RMSE	RMSE-vector	R <sup>2</sup>
Modelos Deep - Cartesiano(sem Normalização)				
LSTM	9.47	13.051	<b>[10.16, 16.56, 11.50]</b>	0.99

Tabela: Resultados parciais.

# Preparação dos dados




Figura: Resultados parciais. Entrada nova.

# Preparação dos dados





Figura: Resultados parciais. Entrada nova.

# Trabalhos Futuros - 24-28-Fev

- Concertar problemas na previsão
- Aplicar calculo de distancias



- Corregido o problema da previsão das rotas.
- Valores perigosos **NAN** no dataset do TEST.



- Previsão Multi-step Multivariada
- **Previsão:**  $t = 1, h = 4$   
 $P_{h+t} = F([s_h, s_{h-1}, s_{h-2}, s_{h-3}, s_{h-4}])$
- Previsão com deslocamento.
- **Características:** Posições do Hit.
- **LSTM stack:** 1 camada 800 neurônios, 1 Dropout, 1 camada 800 neurônios, 1 Dropout, 1 densa 10 neurônios, camada saída: 3 neurônio, função: ReLU, **otimizador:** adam, rmsprop, **loss:** mean squared error.

## Experimento : Previsão Multi step

Modelo	MAE	RMSE	RMSE-Vector	R <sup>2</sup>
Coord - (X,Y,Z)				
LSTM+Normalização	0.062	0.087	[0.06, 0.11, 0.09]	0.992
LSTM-Normalização	7.758	11.087	[10.59, 10.84, 11.79]	0.999
Coord - (Rho,Eta,Phi)				
LSTM+Normalização	<b>0.052</b>	<b>0.074</b>	<b>[0.05, 0.08, 0.09]</b>	0.994
LSTM-Normalização	<b>1.75</b>	<b>3.204</b>	<b>[5.53, 0.15, 0.48]</b>	1

Tabela: Desempenho dos Modelos.

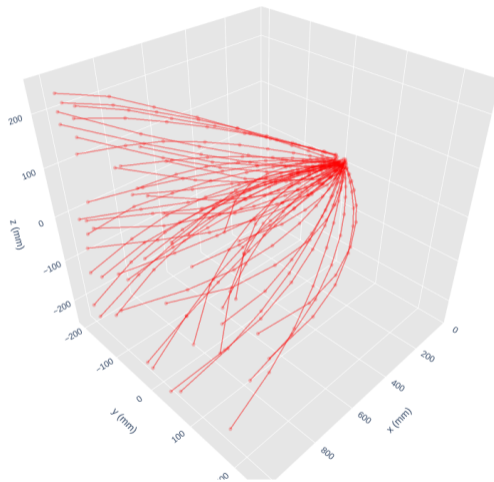


Figura: Dados originais - 50 Tracks




Figura: Dados Preditos - Coord. Cartesianos (30 Tracks)




Figura: Dados Preditos - Coord. Polares (30 Tracks)

- Aplicar calculo de Distancias com KNN ou outra técnica.
- Trocar pelo predito.