

I Workshop de
Ciência de Dados
do Poder Judiciário
Estatística aplicada ao Direito

Realização:



Poder
Judiciário



CONSELHO
NACIONAL
DE JUSTIÇA

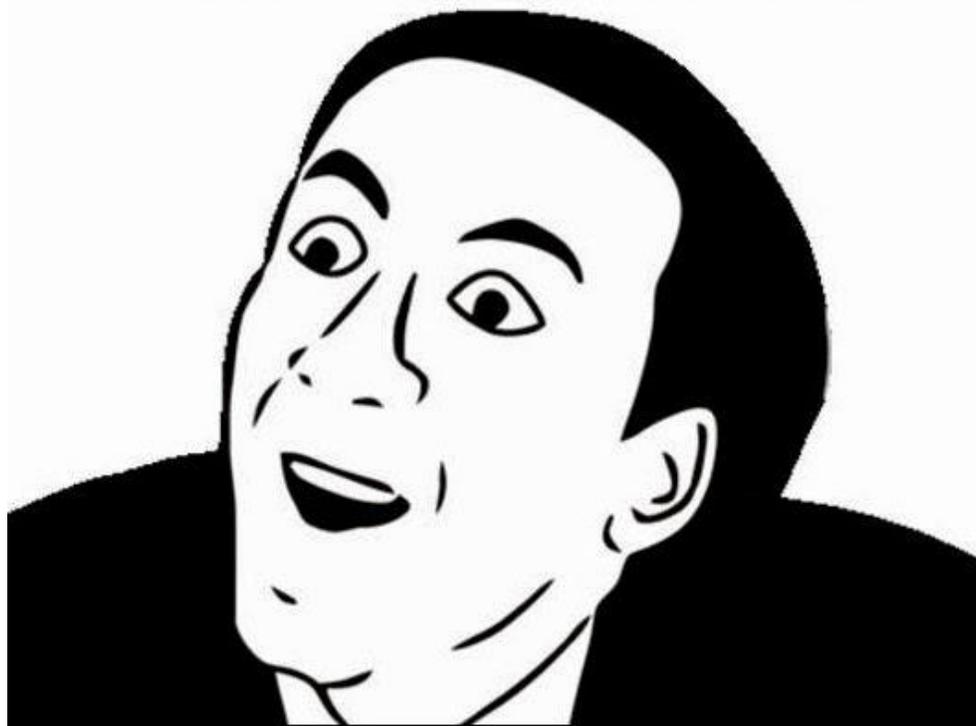
Previsão através de *deep learning* e redes neurais LSTM: uma combinação insuperável

Daniel Takata Gomes (ENCE/IBGE)

- O que é *deep learning*?

- O que é *deep learning*?
- Aprendizagem profunda!

NÃO ME DIGA



#10yearchallenge

#10yearchallenge



 neymarjr • Seguindo

neymarjr A cara de menino se foi, mas o olhar e o foco de quem quer vencer sempre estará comigo. #10yearschallenge

zelove9 🙏🙏

gabipozzi 🙏🙏

xandys2 🙏🙏🙏🙏🙏

joanasanz Y los granos también hahahaha

lucaslma Caralho 🙏

🤍 💬 📤

#10yearchallenge

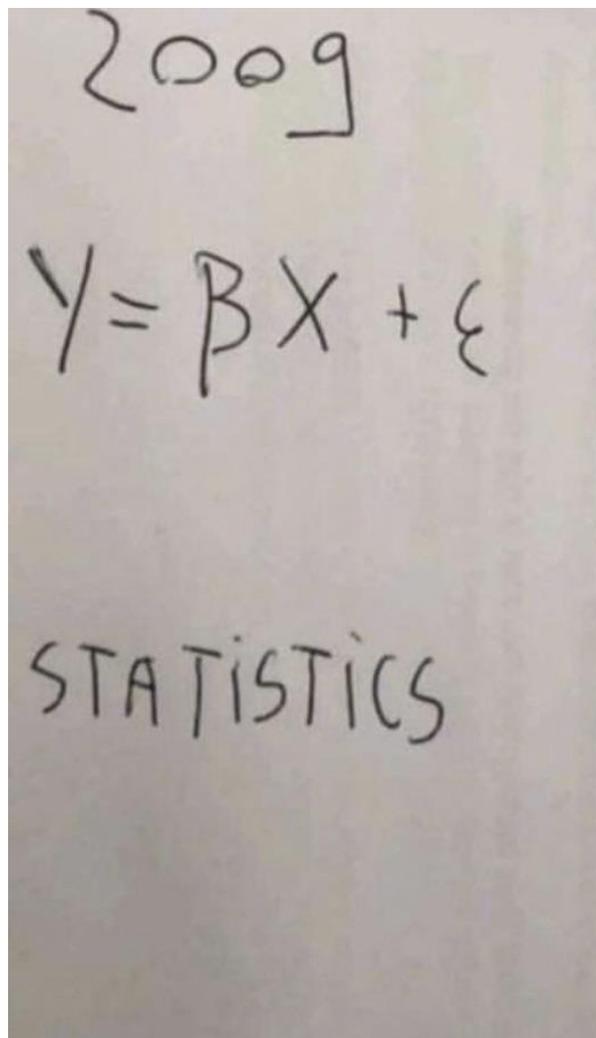
2009



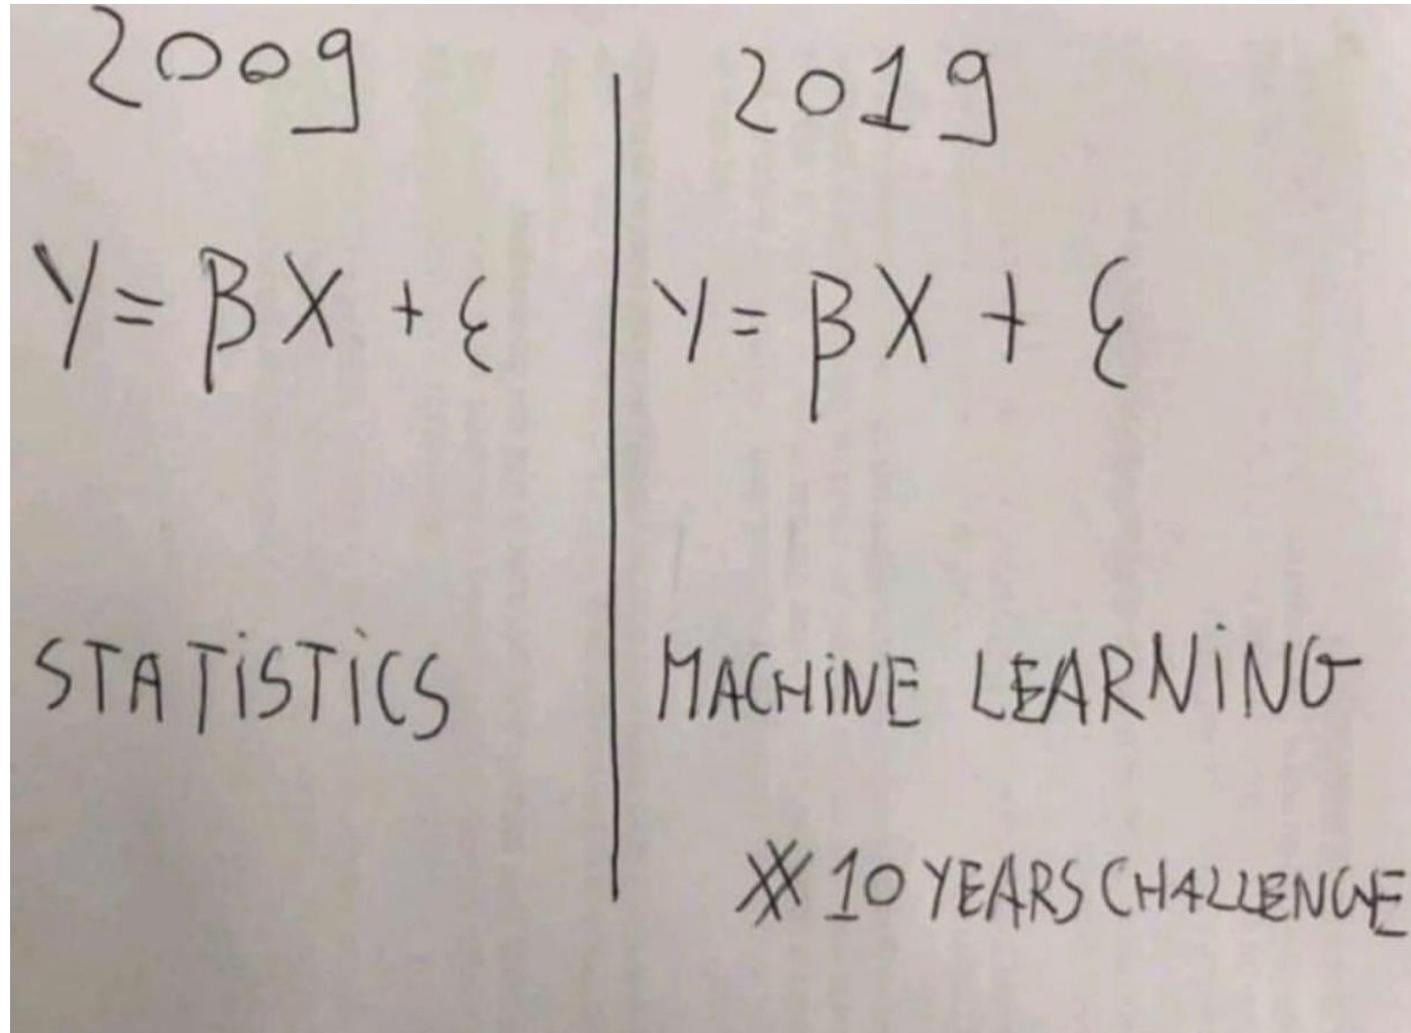
2019



#10yearchallenge



#10yearchallenge



- *Machine learning*: algoritmos e metodologias que permitem que programas de computador melhorem seu desempenho a medida que obtém mais dados.

- *Machine learning*: algoritmos e metodologias que permitem que programas de computador melhorem seu desempenho a medida que obtém mais dados.
- Técnicas: modelos de regressão, modelos lineares generalizados, análise de agrupamentos, análise discriminante, árvores de decisões, **redes neurais**.



Yoshua Bengio



Geoffrey E Hinton



Yann LeCun



FATHERS OF THE DEEP LEARNING REVOLUTION RECEIVE ACM A.M. TURING AWARD

Bengio, Hinton, and LeCun Ushered in Major Breakthroughs in Artificial Intelligence

ACM named [Yoshua Bengio](#), [Geoffrey Hinton](#), and [Yann LeCun](#) recipients of the 2018 ACM A.M. Turing Award for conceptual and engineering breakthroughs that have made deep neural networks a critical component of computing. Bengio is Professor at the University of Montreal and Scientific Director at Mila, Quebec's Artificial Intelligence Institute; Hinton is VP and Engineering Fellow of Google, Chief Scientific Adviser of The Vector Institute, and University Professor Emeritus at the University of Toronto; and LeCun is Professor at New York University and VP and Chief AI Scientist at Facebook.

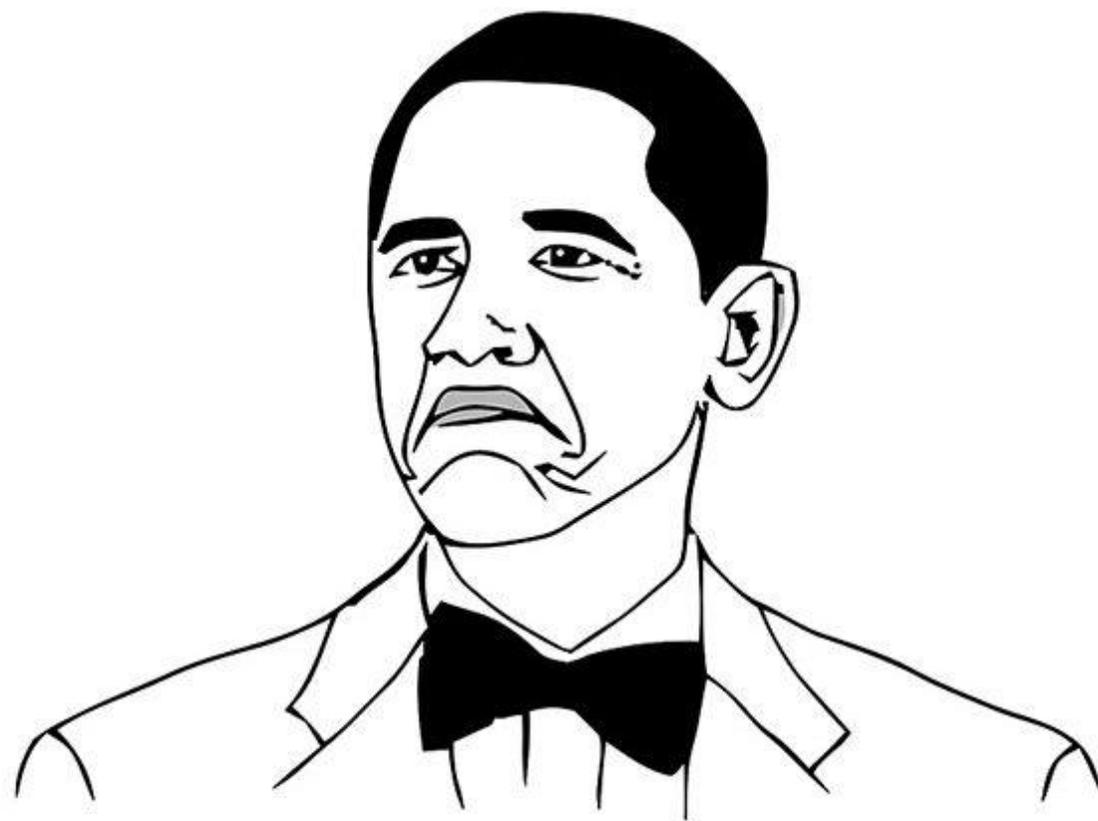
Working independently and together, Hinton, LeCun and Bengio developed conceptual foundations for the field, identified surprising phenomena through experiments, and contributed engineering advances that demonstrated the practical advantages of deep neural networks. In recent years, deep learning methods have been responsible for astonishing breakthroughs in computer vision, speech recognition, natural language processing, and robotics—among other applications.

While the use of artificial neural networks as a tool to help computers recognize patterns and simulate human intelligence had been introduced in the 1980s, by the early 2000s, LeCun, Hinton and Bengio were among a small group who remained committed to this approach. Though their efforts to rekindle the AI community's interest in neural networks were initially met with skepticism, their ideas recently resulted in major technological advances, and their methodology is now the dominant paradigm in the field.

Resultados da última CIF (competição internacional de previsões de séries temporais, organizada dentro do IEEE World Congress on Computational Intelligence):

Resultados da última CIF (competição internacional de previsões de séries temporais, organizada dentro do IEEE World Congress on Computational Intelligence):

Pos.	Modelo	SMAPE
1	LSTM-Deseasonalized	0.105 ± 0.107
2	LSTMs and ETS	0.108 ± 0.116
3	ETS	0.119 ± 0.142
4	MLP	0.121 ± 0.135
5	REST	0.124 ± 0.133
6	FRBE	0.129 ± 0.162
7	HEM	0.130 ± 0.147
8	Avg	0.131 ± 0.133
9	BaggedETS	0.131 ± 0.176
10	LSTM	0.133 ± 0.155



NOT BAD

Mas afinal de contas, o que é uma rede neural?

Mas afinal de contas, o que é uma rede neural?

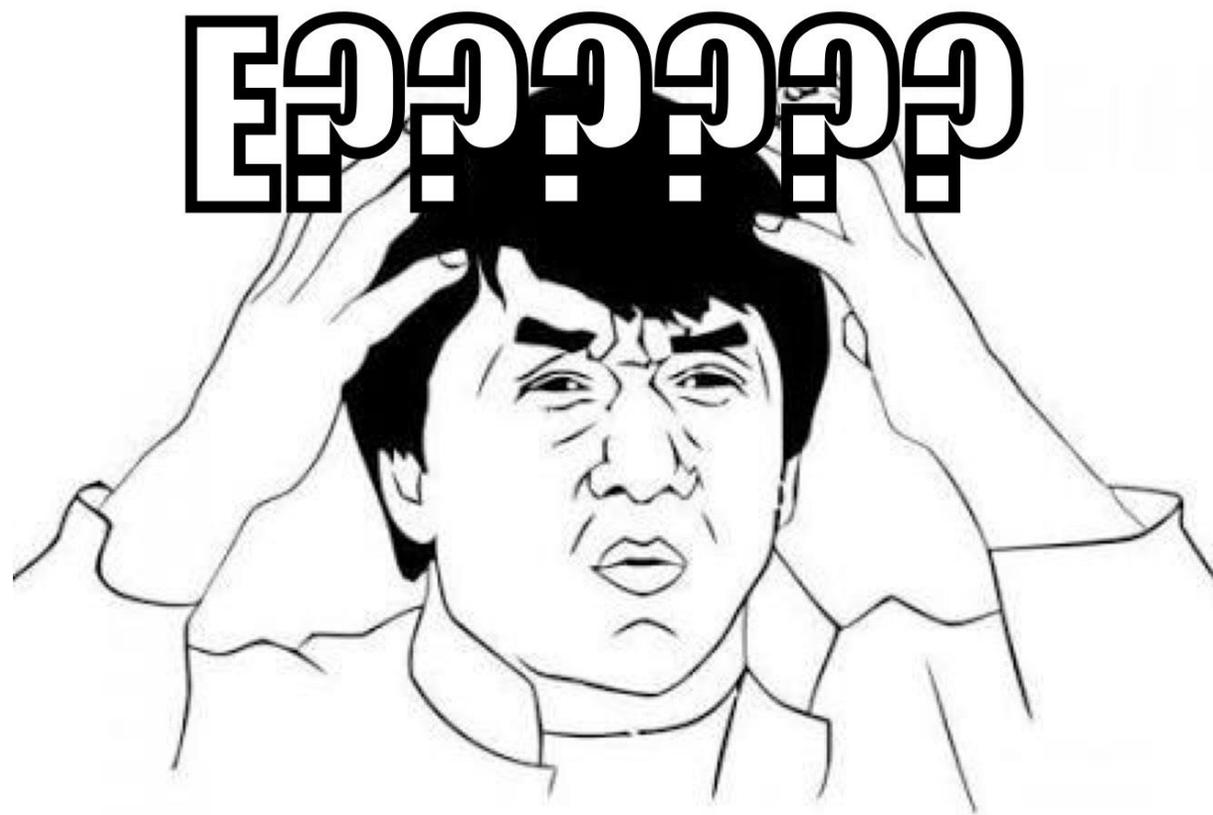
- Muitos dizem que são modelos que se assemelham a forma como neurônios trabalham em nossos cérebros.

Mas afinal de contas, o que é uma rede neural?

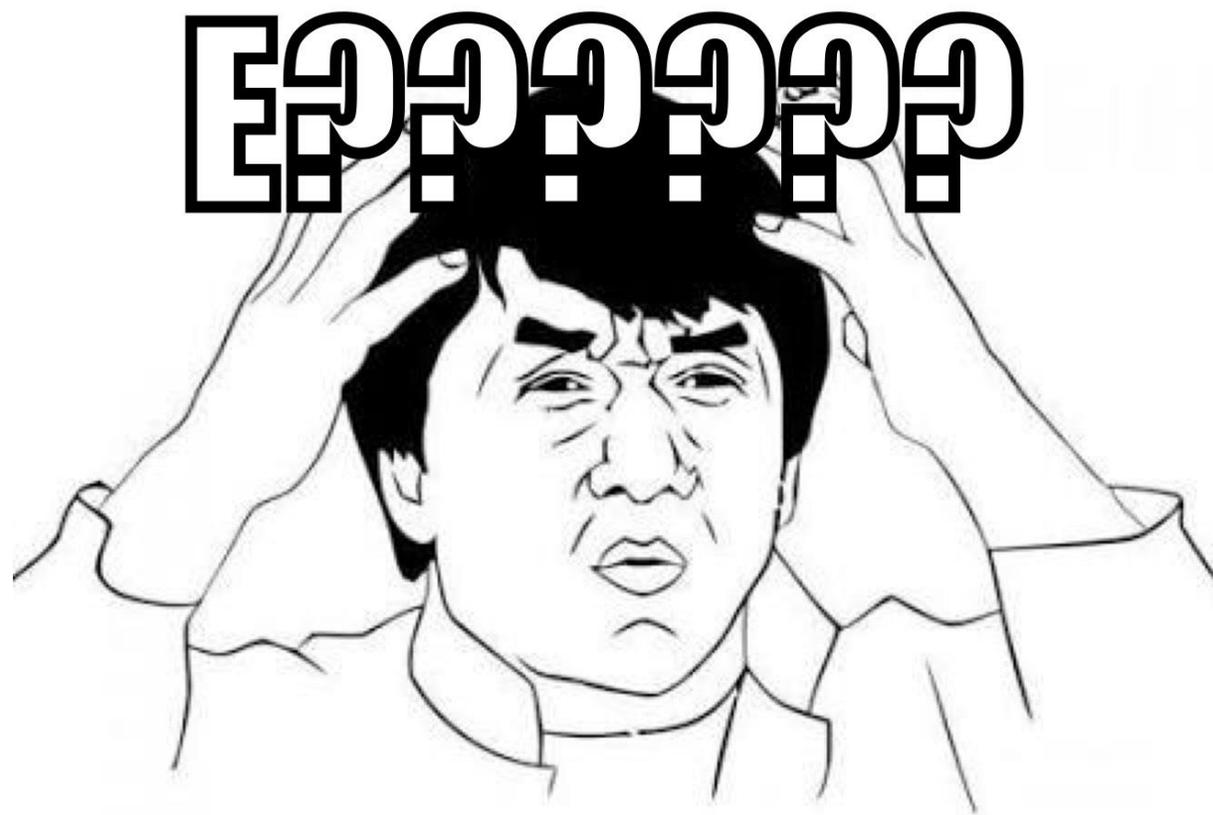
- Muitos dizem que são modelos que se assemelham a forma como neurônios trabalham em nossos cérebros.
- Que elas consistem de um sistema de nós que interconecta diversas ramificações.

Mas afinal de contas, o que é uma rede neural?

- Muitos dizem que são modelos que se assemelham a forma como neurônios trabalham em nossos cérebros.
- Que elas consistem de um sistema de nós que interconecta diversas ramificações.
- E que, tipicamente, as redes neurais aprendem a partir da atualização e ampliação desses laços e interconexões.



Teorema de Kolmogorov-Nielsen: Dada uma função $f : [0; 1]^n \rightarrow \mathbb{R}^m$, $f(x) = y$, existe sempre para f uma implementação exata com uma rede neural de três camadas com n entradas, sendo a primeira camada intermediária composta por $n(2n + 1)$ neurônios, a segunda camada intermediária com $2n + 1$ neurônios e a camada de saída com m neurônios representando as m componentes do vetor y .



Modelo de regressão linear.

Modelo de regressão linear.

- Suponha que desejemos ter uma ideia peso de uma criança, baseada na altura dela.



Modelo de regressão linear.

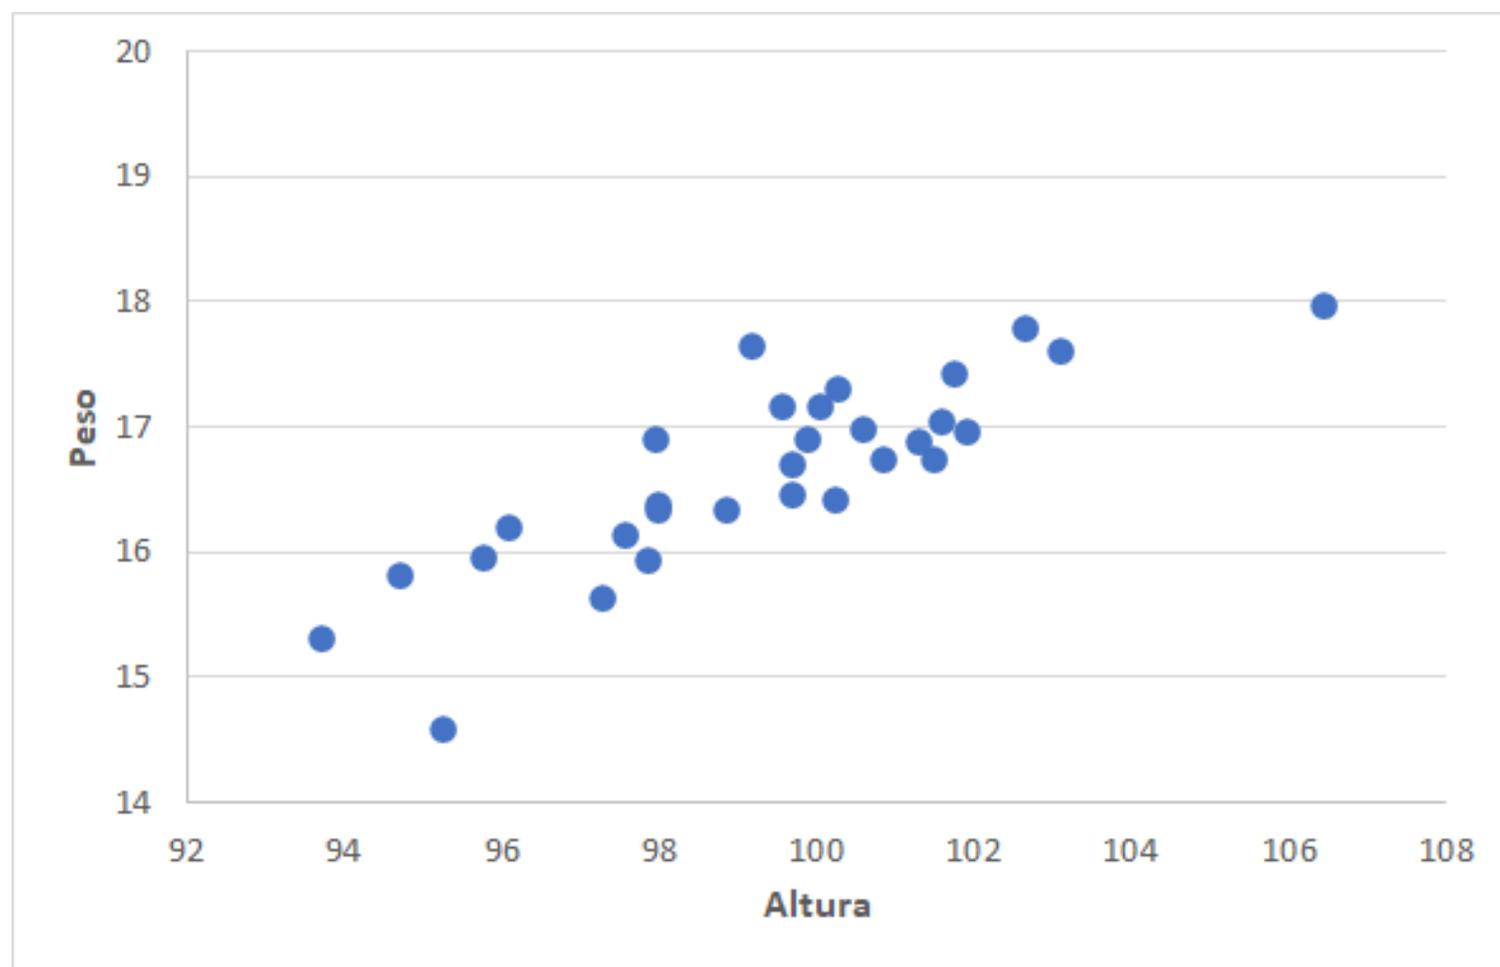
- Suponha que desejemos ter uma ideia peso de uma criança, baseada na altura dela.
- É possível construir um modelo relacionando as duas quantidades.

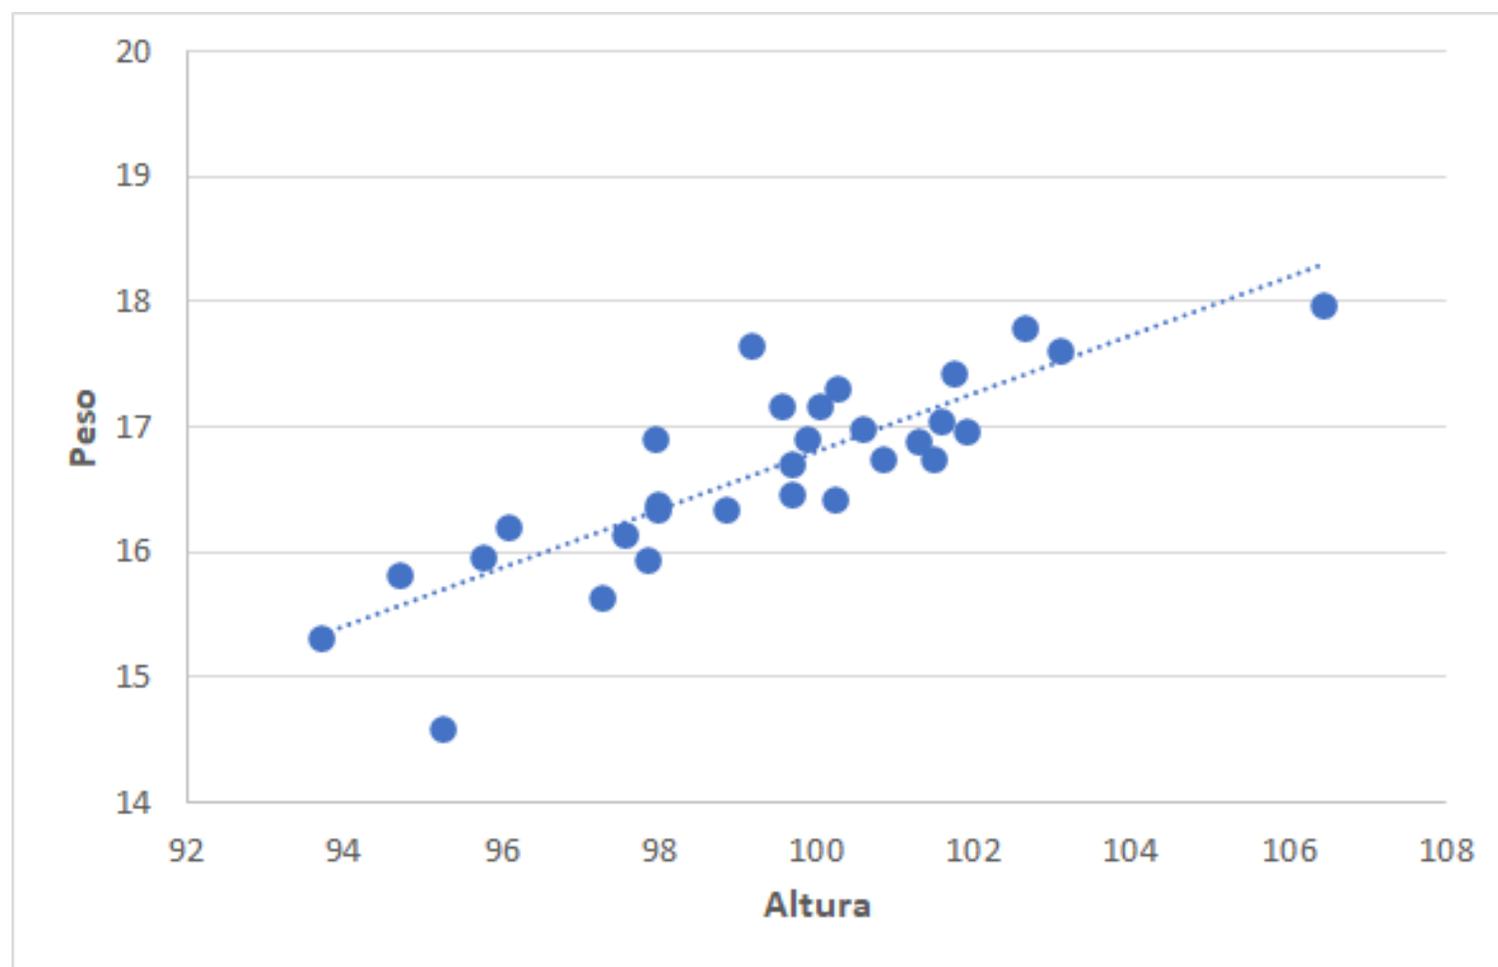


Modelo de regressão linear.

- Suponha que desejemos ter uma ideia peso de uma criança, baseada na altura dela.
- É possível construir um modelo relacionando as duas quantidades.
- Suponha que dados coletados de 30 crianças com idades entre três e quatro anos apresentem a seguinte relação gráfica:

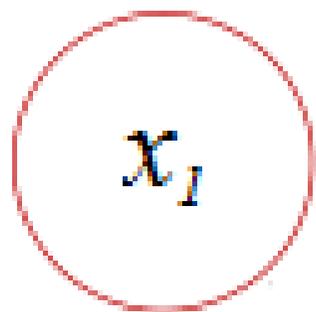


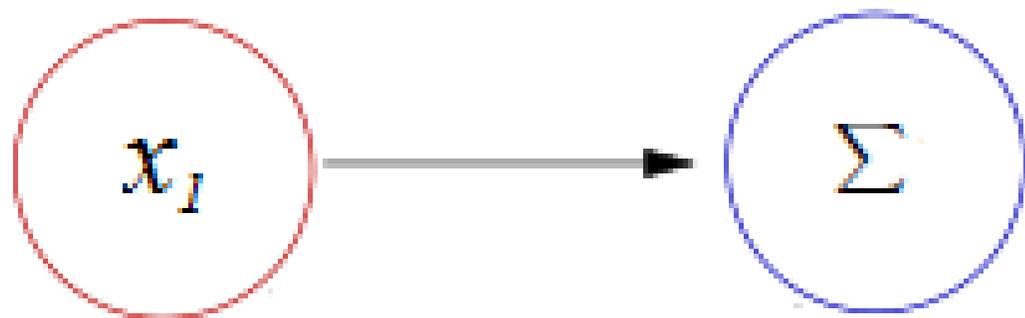


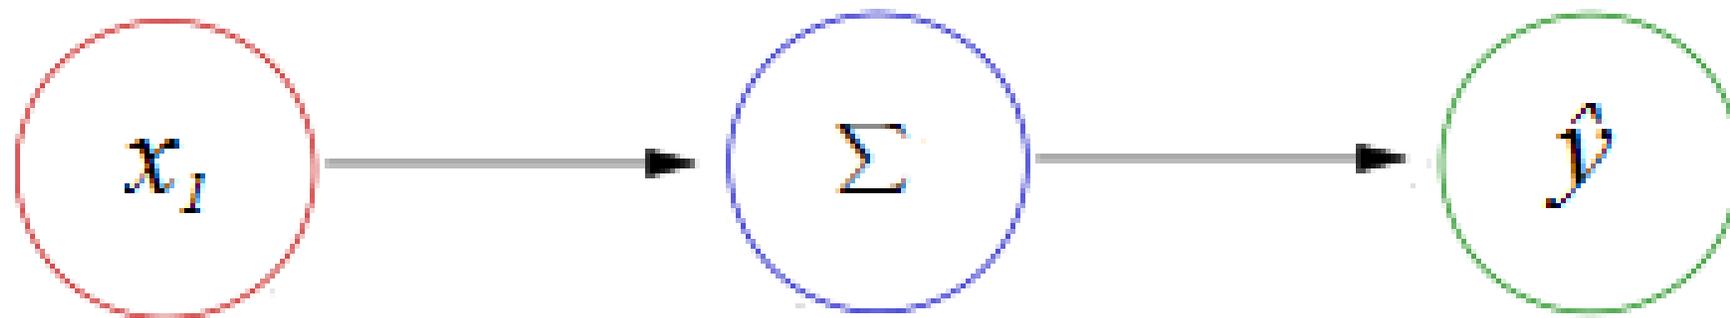


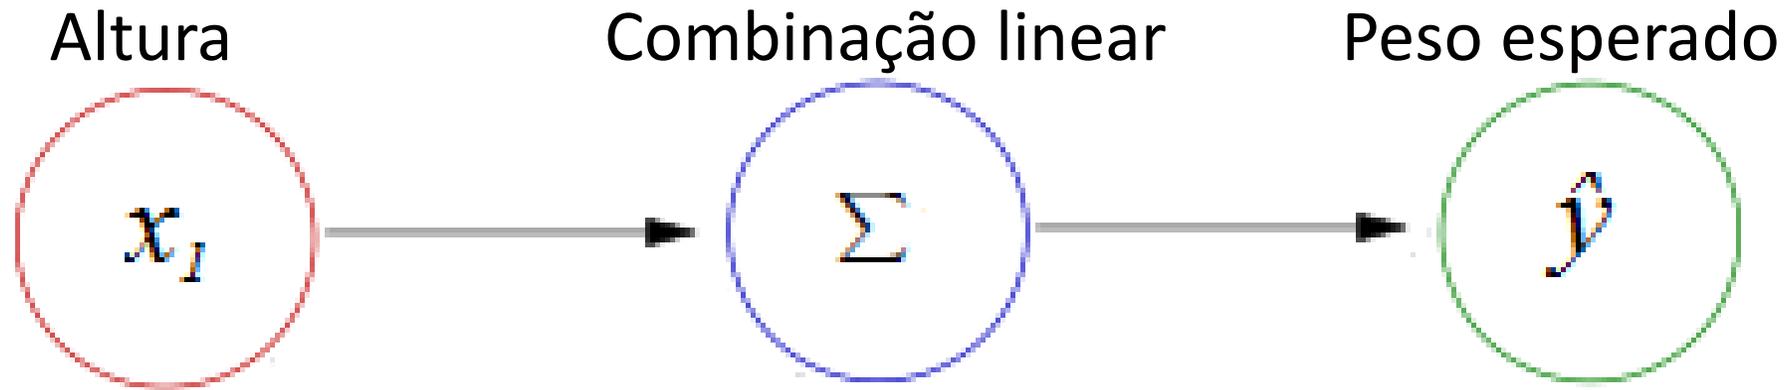
- Modelo de regressão linear: $\text{Peso} = -13,7 + 0,3 \times \text{Altura}$

- Modelo de regressão linear: $\text{Peso} = -13,7 + 0,3 \times \text{Altura}$
- Portanto, espera-se que uma criança de 101 cm tenha um peso de:
$$-13,7 + 0,3 \times 101 = 16,60 \text{ kg}$$









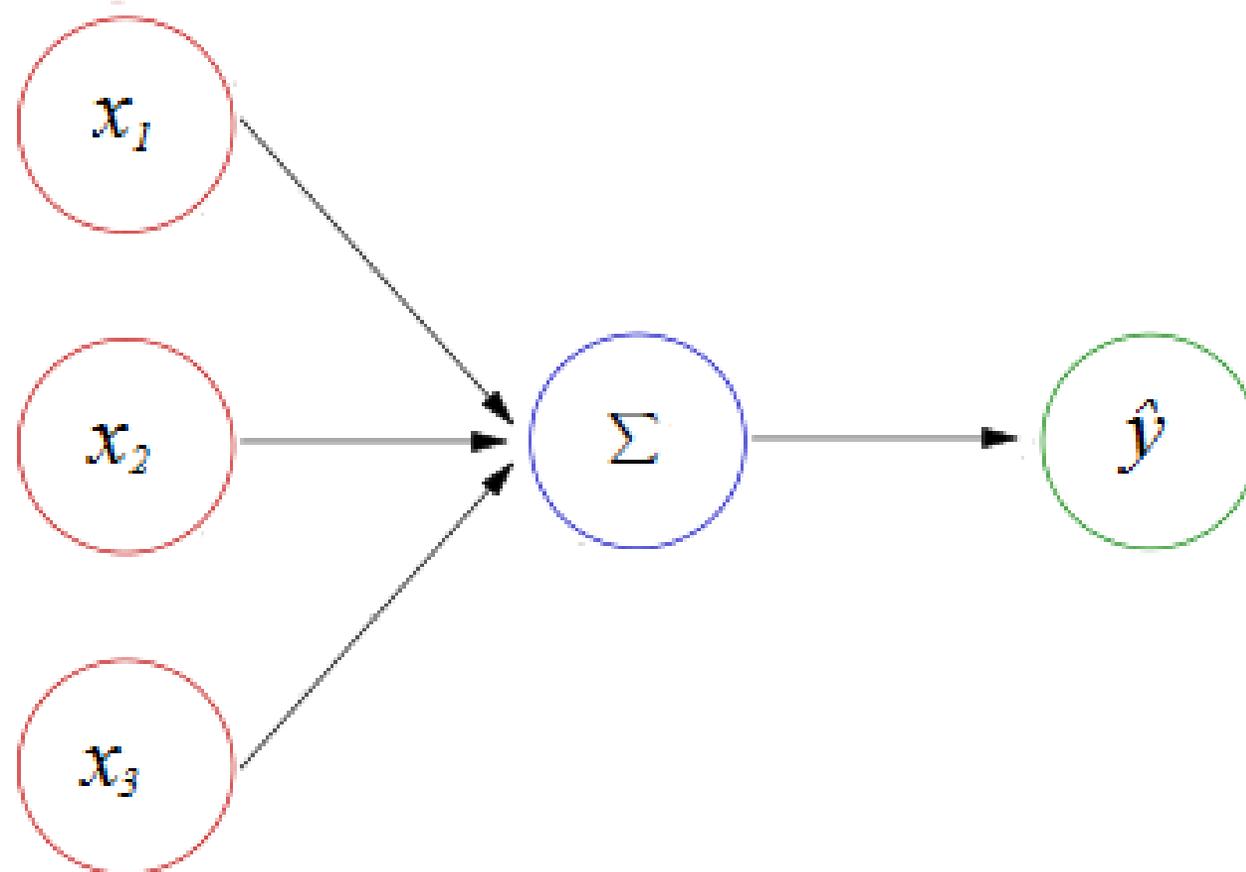
$$\hat{y} = -13,7 + 0,3x_1$$

Peso esperado = $-13,7 + 0,3 \times$ Altura

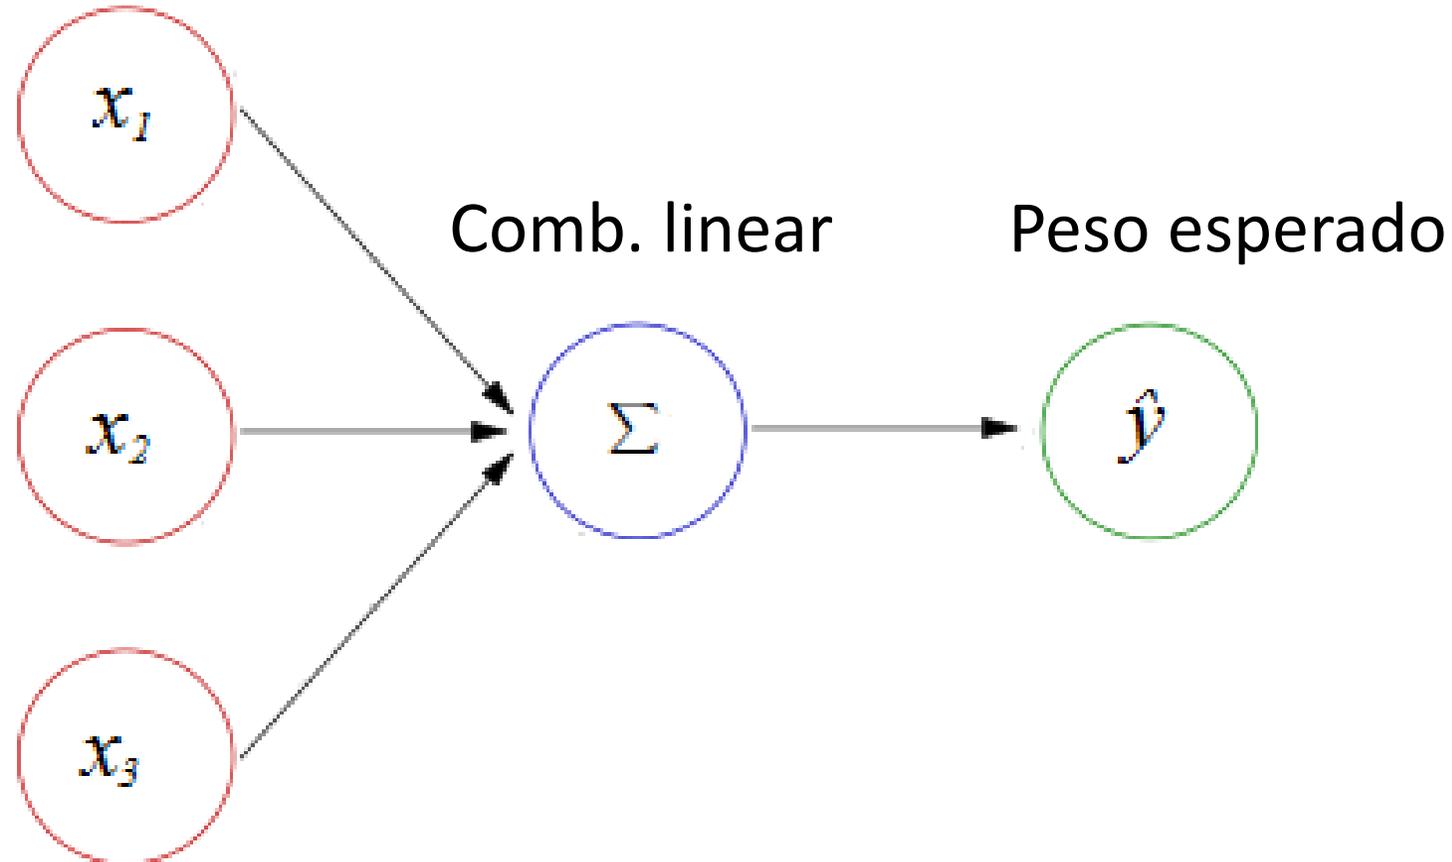
- No entanto, outras quantidades, além da altura, podem ser importantes para se ter uma ideia mais precisa do peso da criança

- No entanto, outras quantidades, além da altura, podem ser importantes para se ter uma ideia mais precisa do peso da criança
- Por exemplo: quantidade de calorias ingeridas por dia; tempo diário de exercícios físicos; etc.

- No entanto, outras quantidades, além da altura, podem ser importantes para se ter uma ideia mais precisa do peso da criança
- Por exemplo: quantidade de calorias ingeridas por dia; tempo diário de exercícios físicos; etc.
- Para isso, utiliza-se o modelo de regressão linear múltiplo, em que mais variáveis podem ser utilizadas para serem relacionadas a outra variável de interesse.



Altura, calorias,
exercícios etc



- Agora, suponha que deseja-se ter uma ideia da chance de ocorrência de determinado evento, com base em variáveis auxiliares.

- Agora, suponha que deseja-se ter uma ideia da chance de ocorrência de determinado evento, com base em variáveis auxiliares.
- Danziger, Levav e Avnaim-Pesso (2011) conduziram um estudo científico utilizando dados de centenas de prisioneiros israelenses.



- Foram avaliados os pedidos de liberdade condicional. E detectou-se que, ao longo das sessões, no início delas, o percentual de pedidos concedidos era de 65%, e ia caindo até quase zero.



- Foram avaliados os pedidos de liberdade condicional. E detectou-se que, ao longo das sessões, no início delas, o percentual de pedidos concedidos era de 65%, e ia caindo até quase zero.
- Após um recesso (intervalo para lanche, almoço), o percentual voltava a 65%.



- Foram avaliados os pedidos de liberdade condicional. E detectou-se que, ao longo das sessões, no início delas, o percentual de pedidos concedidos era de 65%, e ia caindo até quase zero.
- Após um recesso (intervalo para lanche, almoço), o percentual voltava a 65%.
- Ou seja, a fadiga de decisão é um fator determinante.



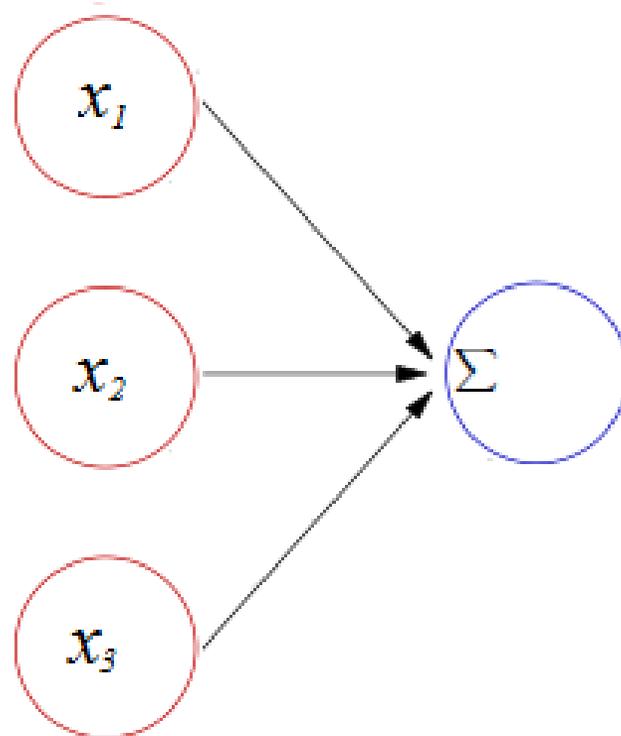
- Nesse contexto, pode-se pensar em utilizar um modelo de regressão linear para avaliar as chances dos pedidos de liberdade condicional serem aceitos ou não, baseadas em variáveis como: gravidade do crime, comportamento dos detentos, tempo decorrido da sessão etc.

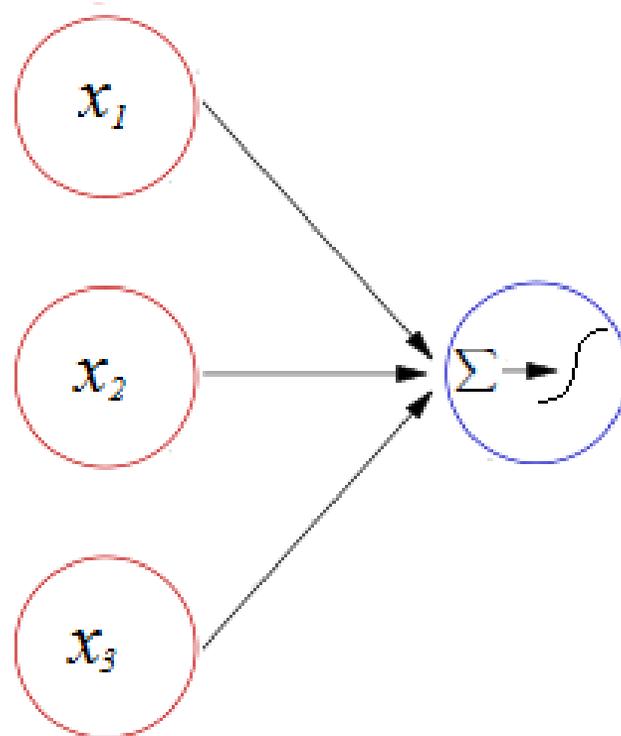
- Nesse contexto, pode-se pensar em utilizar um modelo de regressão linear para avaliar as chances dos pedidos de liberdade condicional serem aceitos ou não, baseadas em variáveis como: gravidade do crime, comportamento dos detentos, tempo decorrido da sessão etc.
- Como agora estamos avaliando chances (probabilidade de aceitação dos pedidos), é preciso fazer um ajuste no modelo de regressão.

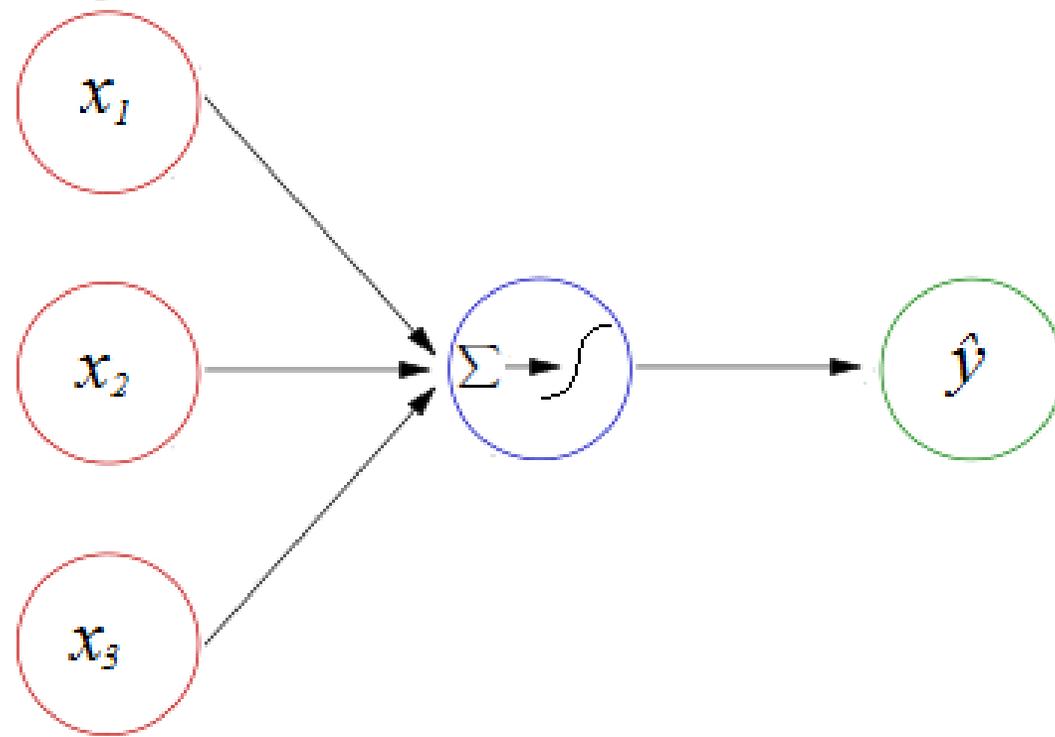
x_1

x_2

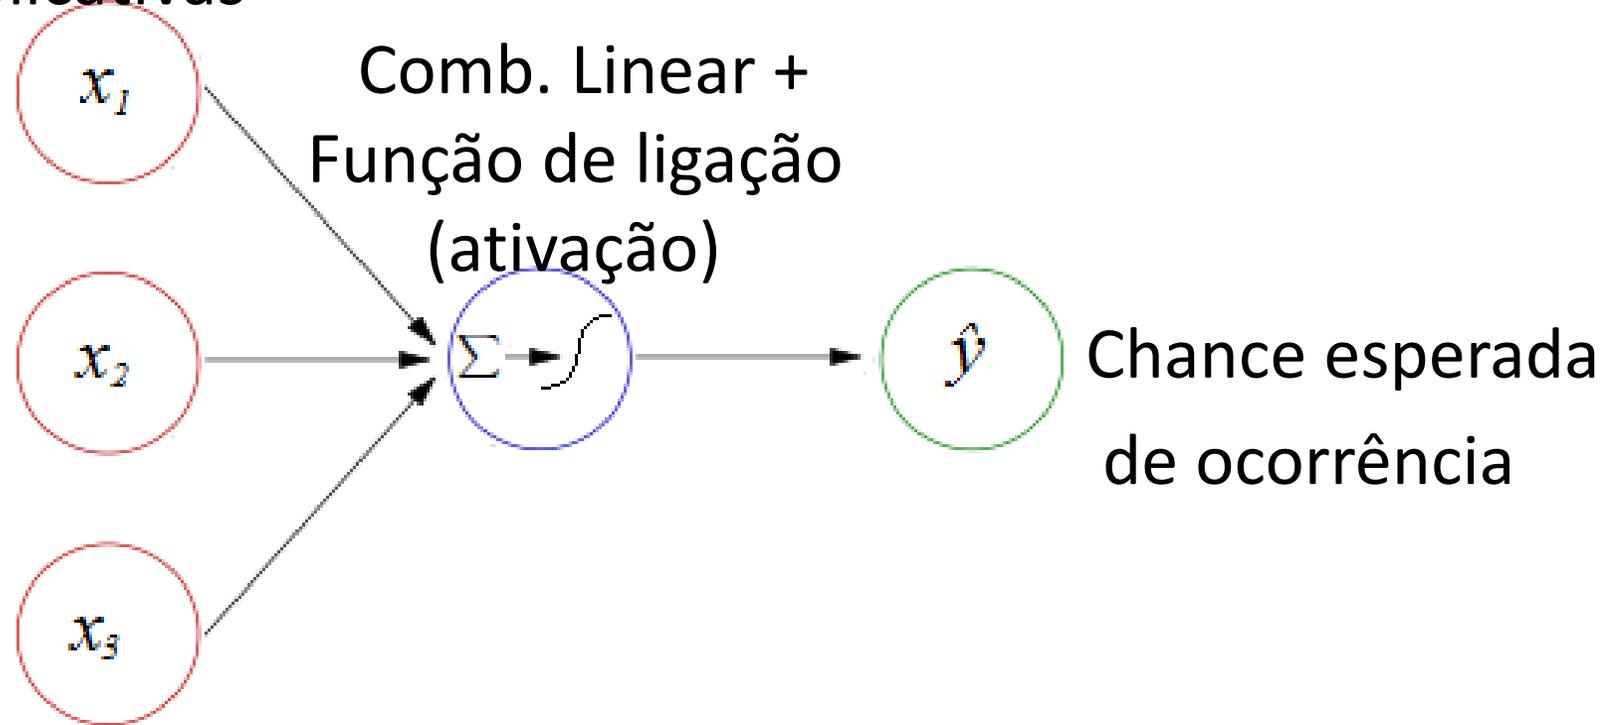
x_3







Variáveis
explicativas



Esse modelo é chamado de modelo linear generalizado.

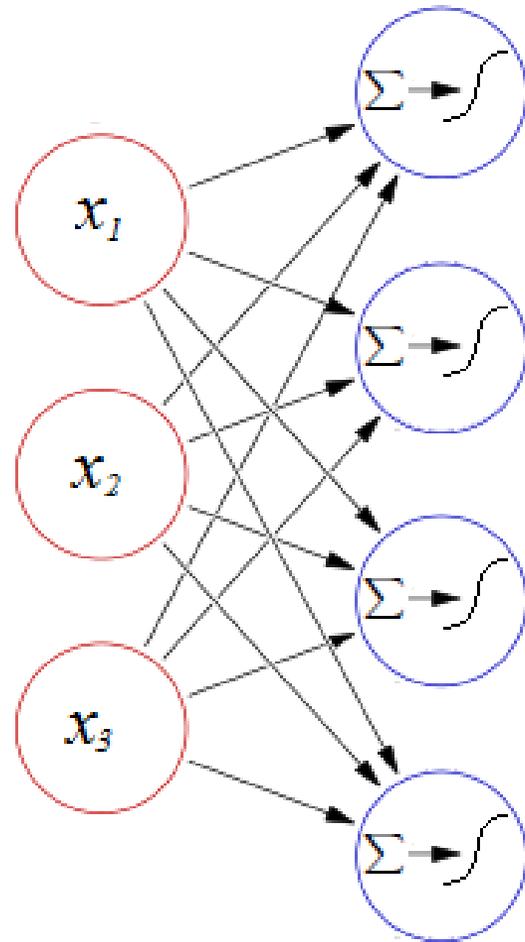
- Modelo linear generalizado: modelo de regressão “turbinado”.

- Modelo linear generalizado: modelo de regressão “turbinado”.
- Modelo de redes neurais: modelo linear generalizado “turbinado”!

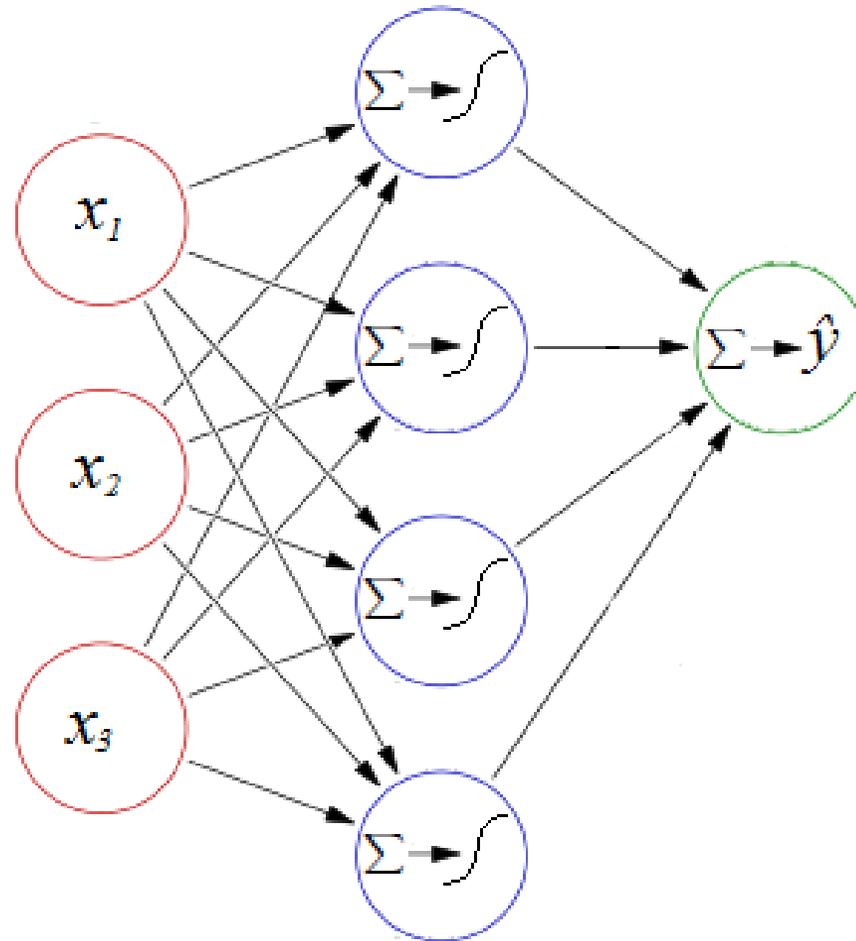
x_1

x_2

x_3

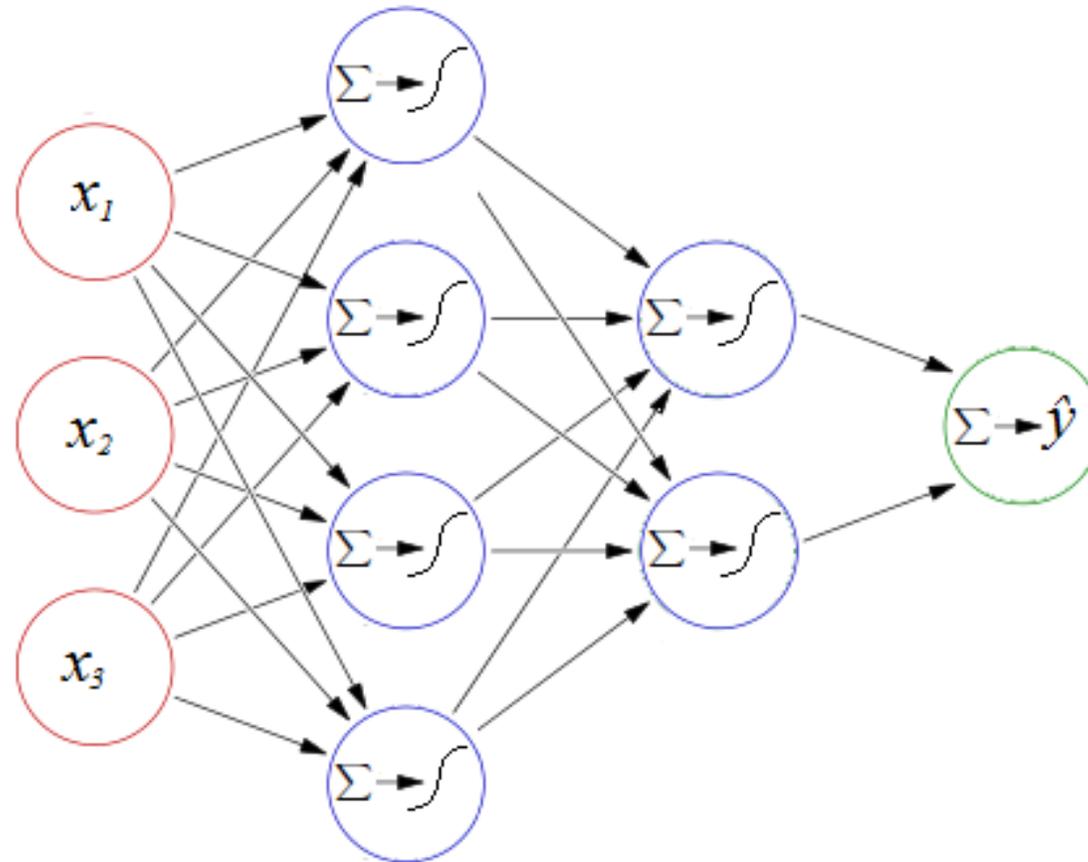


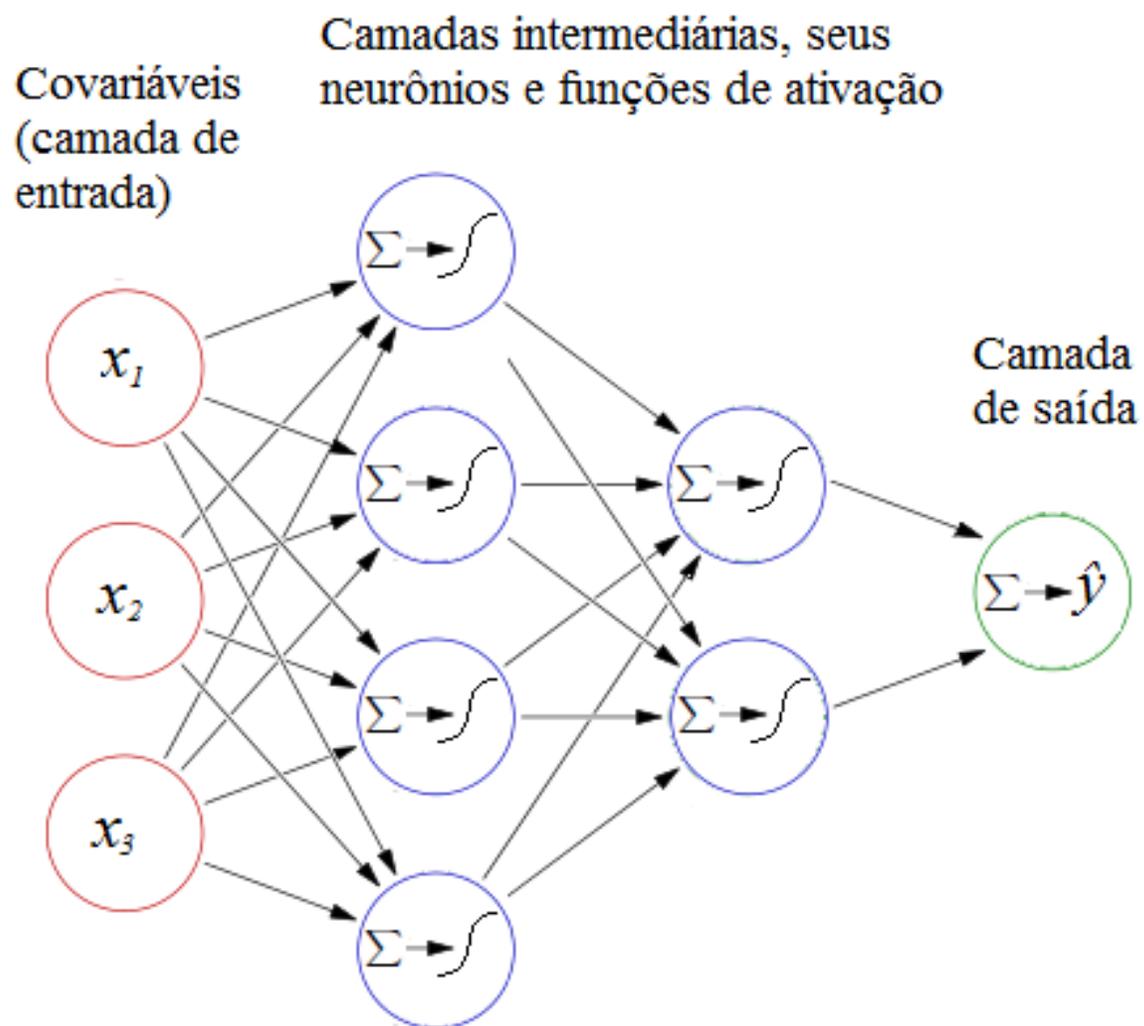
Rede neural:



- As estruturas de uma rede neural, bem como suas funções de ativação, são escolhidas apropriadamente de acordo com o objetivo desejado.

Rede neural profunda (*deep neural network*):





- Redes neurais com muitas camadas intermediárias: *deep neural networks*, ou redes neurais profundas.

- Redes neurais com muitas camadas intermediárias: *deep neural networks*, ou redes neurais profundas.
- Não se sabe exatamente o porque, mas redes neurais profundas são mais rápidas, eficientes e precisas que redes neurais convencionais, e, por isso, têm sido amplamente utilizadas.

[About](#) [Store](#)

[Gmail](#) [Images](#) 

[Sign in](#)

Google

Google Search

I'm Feeling Lucky

facebook®



Instagram



- Tais redes são utilizadas para classificação, previsão, visão computacional, reconhecimento de imagens, de fala, processamento de linguagem natural etc.

- Tais redes são utilizadas para classificação, previsão, visão computacional, reconhecimento de imagens, de fala, processamento de linguagem natural etc.
- Conseguem lidar com conjuntos de dados muito volumosos e complexos, compostos de números, textos, imagens, áudios, vídeos etc.

- Tais redes são utilizadas para classificação, previsão, visão computacional, reconhecimento de imagens, de fala, processamento de linguagem natural etc.
- Conseguem lidar com conjuntos de dados muito volumosos e complexos, compostos de números, textos, imagens, áudios, vídeos etc.
- Os modelos são altamente complexos devido ao grande número de parâmetros.

- Problema: os algoritmos para estimação de parâmetros de redes neurais usuais não conseguem “recordar” a informação por longos períodos de tempo. Logo, não conseguem ser adequados para dependências de longo prazo.

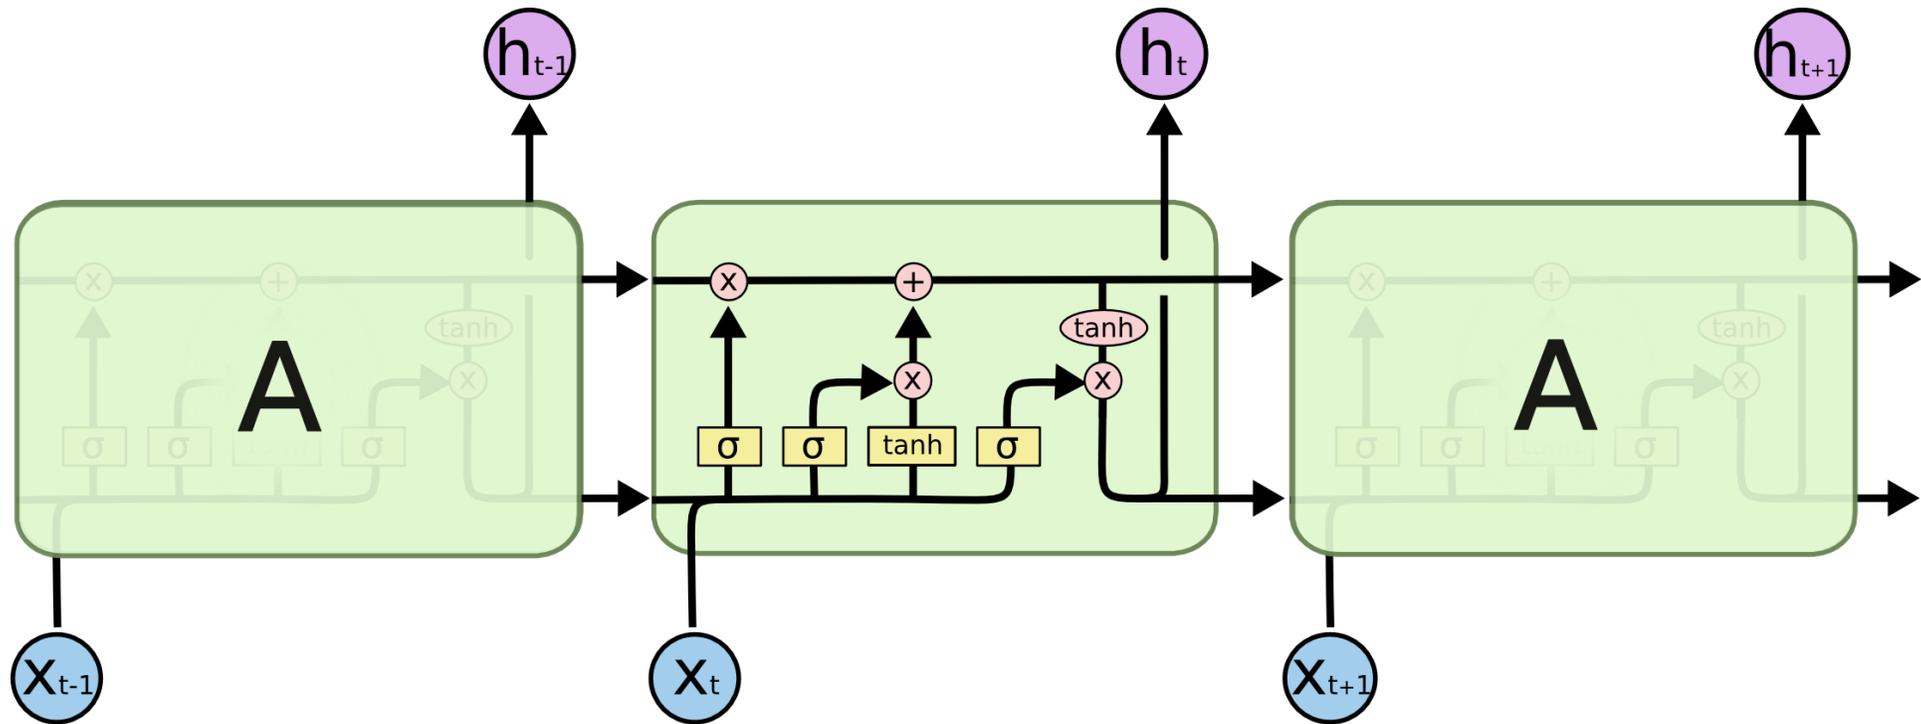
- Problema: os algoritmos para estimação de parâmetros de redes neurais usuais não conseguem “recordar” a informação por longos períodos de tempo. Logo, não conseguem ser adequados para dependências de longo prazo.
- Solução: redes profundas LSTM (*Long Short Term Memory* - Redes de Memória de Longo Prazo).

- São projetadas para evitar o problema de dependência de longo prazo. Afinal, recordar a informação por longos períodos de tempo é praticamente o seu comportamento padrão, algo bem previsível e fácil de aprender.

- São projetadas para evitar o problema de dependência de longo prazo. Afinal, recordar a informação por longos períodos de tempo é praticamente o seu comportamento padrão, algo bem previsível e fácil de aprender.
- Para isso, são estruturadas como se fossem várias redes neurais dentro de uma só.

- São projetadas para evitar o problema de dependência de longo prazo. Afinal, recordar a informação por longos períodos de tempo é praticamente o seu comportamento padrão, algo bem previsível e fácil de aprender.
- Para isso, são estruturadas como se fossem várias redes neurais dentro de uma só.
- Para entender sua estrutura, é uma desgraça!

- São projetadas para evitar o problema de dependência de longo prazo. Afinal, recordar a informação por longos períodos de tempo é praticamente o seu comportamento padrão, algo bem previsível e fácil de aprender.
- Para isso, são estruturadas como se fossem várias redes neurais dentro de uma só.
- Para entender sua estrutura, é uma desgraça!
- Mas funciona que é uma beleza!



Previsão de uma série temporal univariada: aplicação a dados de esportes

**BBC
NEWS**

More or Less

[More or Less Home](#) [Episodes](#) [Podcast](#) [More](#)



Peaty v Bolt: Which is the greatest world record?

Using statistics to compare world records in athletics and swimming

Professor Takata calculated the likelihood of Peaty's world record being broken by a swimmer as 0.291%.

[Show more](#)

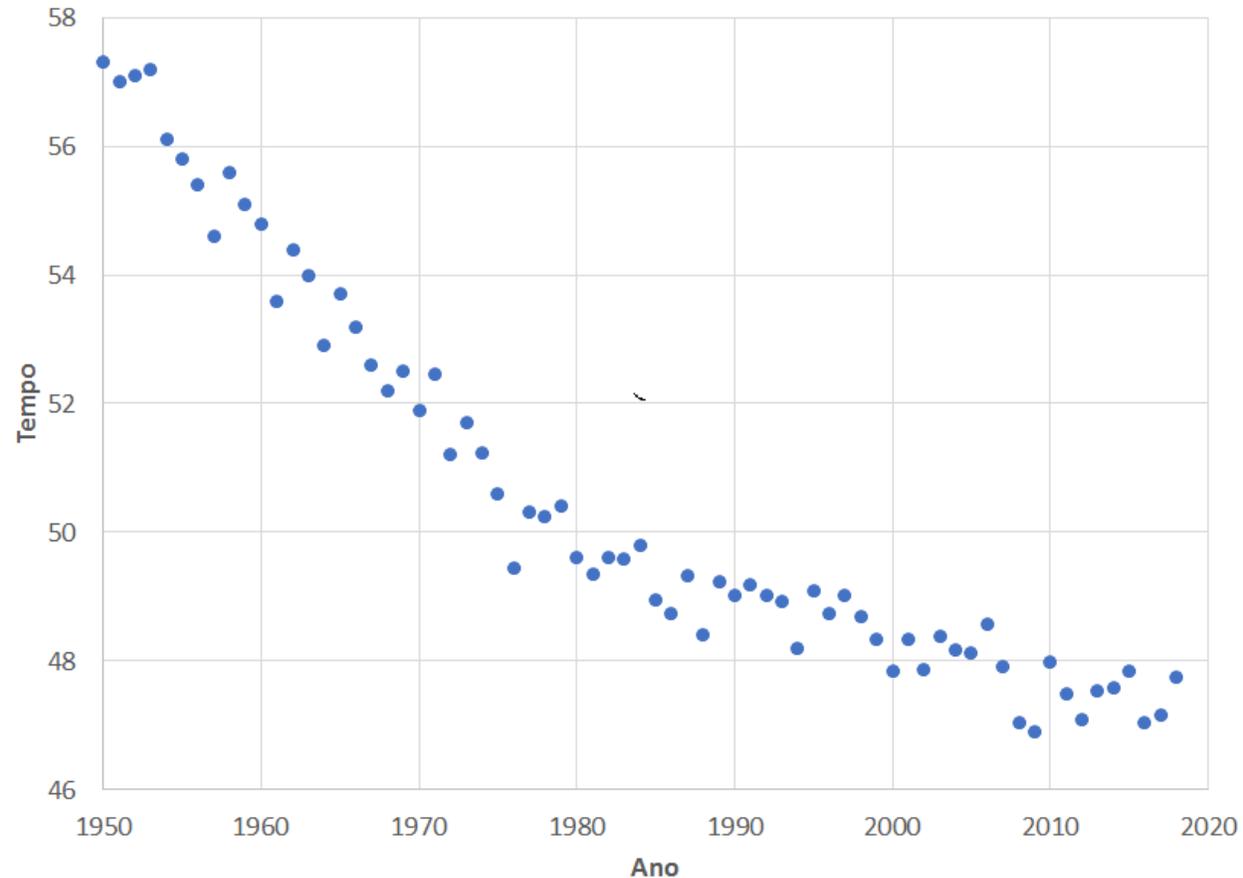
[Download](#)



Evolução dos tempos dos atletas líderes do ranking mundial da prova de 100 metros livre masculino, na natação:

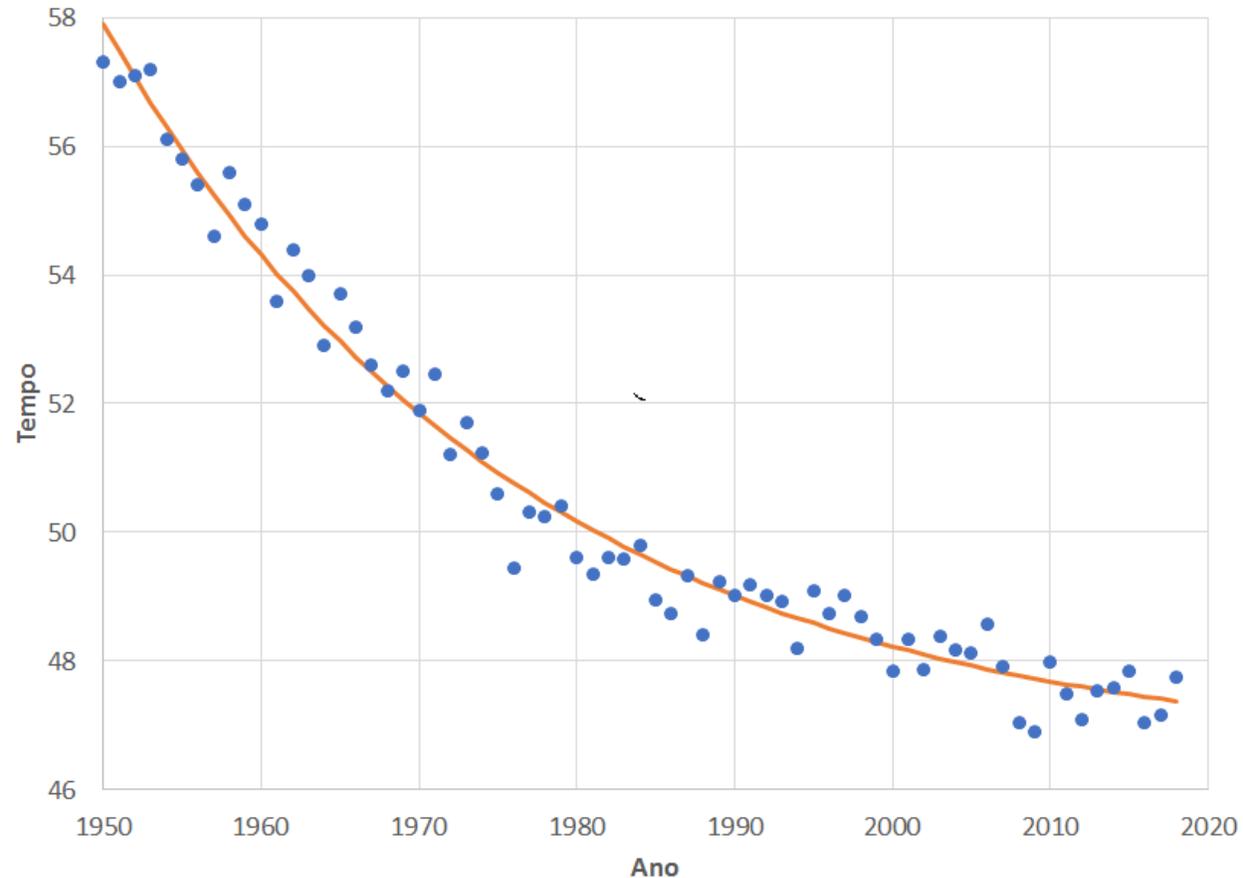


Evolução dos tempos dos atletas líderes do ranking mundial da prova de 100 metros livre masculino, na natação:





Evolução dos tempos dos atletas líderes do ranking mundial da prova de 100 metros livre masculino, na natação:



- Ajuste de uma rede LSTM simples, com 50 unidades, utilizando a biblioteca Keras no Python.

- Ajuste de uma rede LSTM simples, com 50 unidades, utilizando a biblioteca Keras no Python.
- Keras é uma biblioteca de redes neurais, capaz de rodar em cima das bibliotecas de tensores TensorFlow, CNTK ou Theano.

- Ajuste de uma rede LSTM simples, com 50 unidades, utilizando a biblioteca Keras no Python.
- Keras é uma biblioteca de redes neurais, capaz de rodar em cima das bibliotecas de tensores TensorFlow, CNTK ou Theano.
- Provê uma estrutura que permite compilar redes neurais combinando camadas de diferentes dimensões e funções de ativação, tornando o ciclo de desenvolvimento de novos modelos de aprendizado de máquina muito mais rápido.

```
from keras.models import Sequential
from keras.layers import LSTM
from keras.layers import Dense

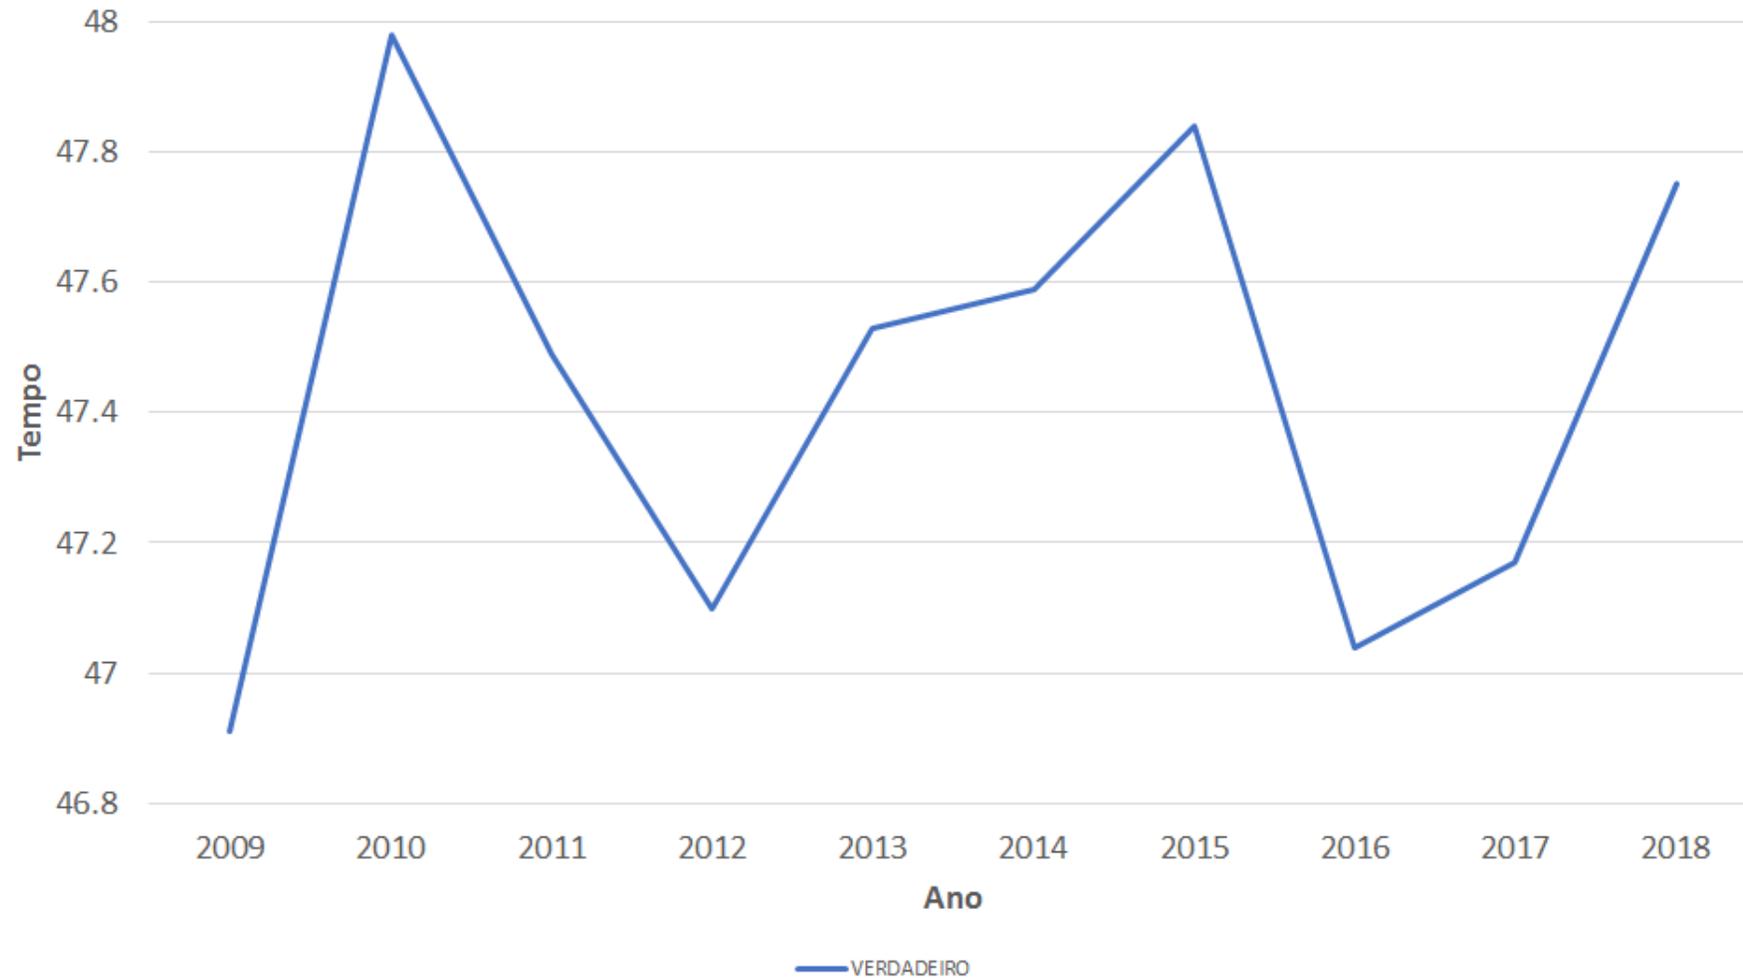
# definindo o modelo
model = Sequential()
model.add(LSTM(50, activation='relu', input_shape=(n_steps,
n_features)))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')

# ajustando o modelo
model.fit(X, y, epochs=200, verbose=0)

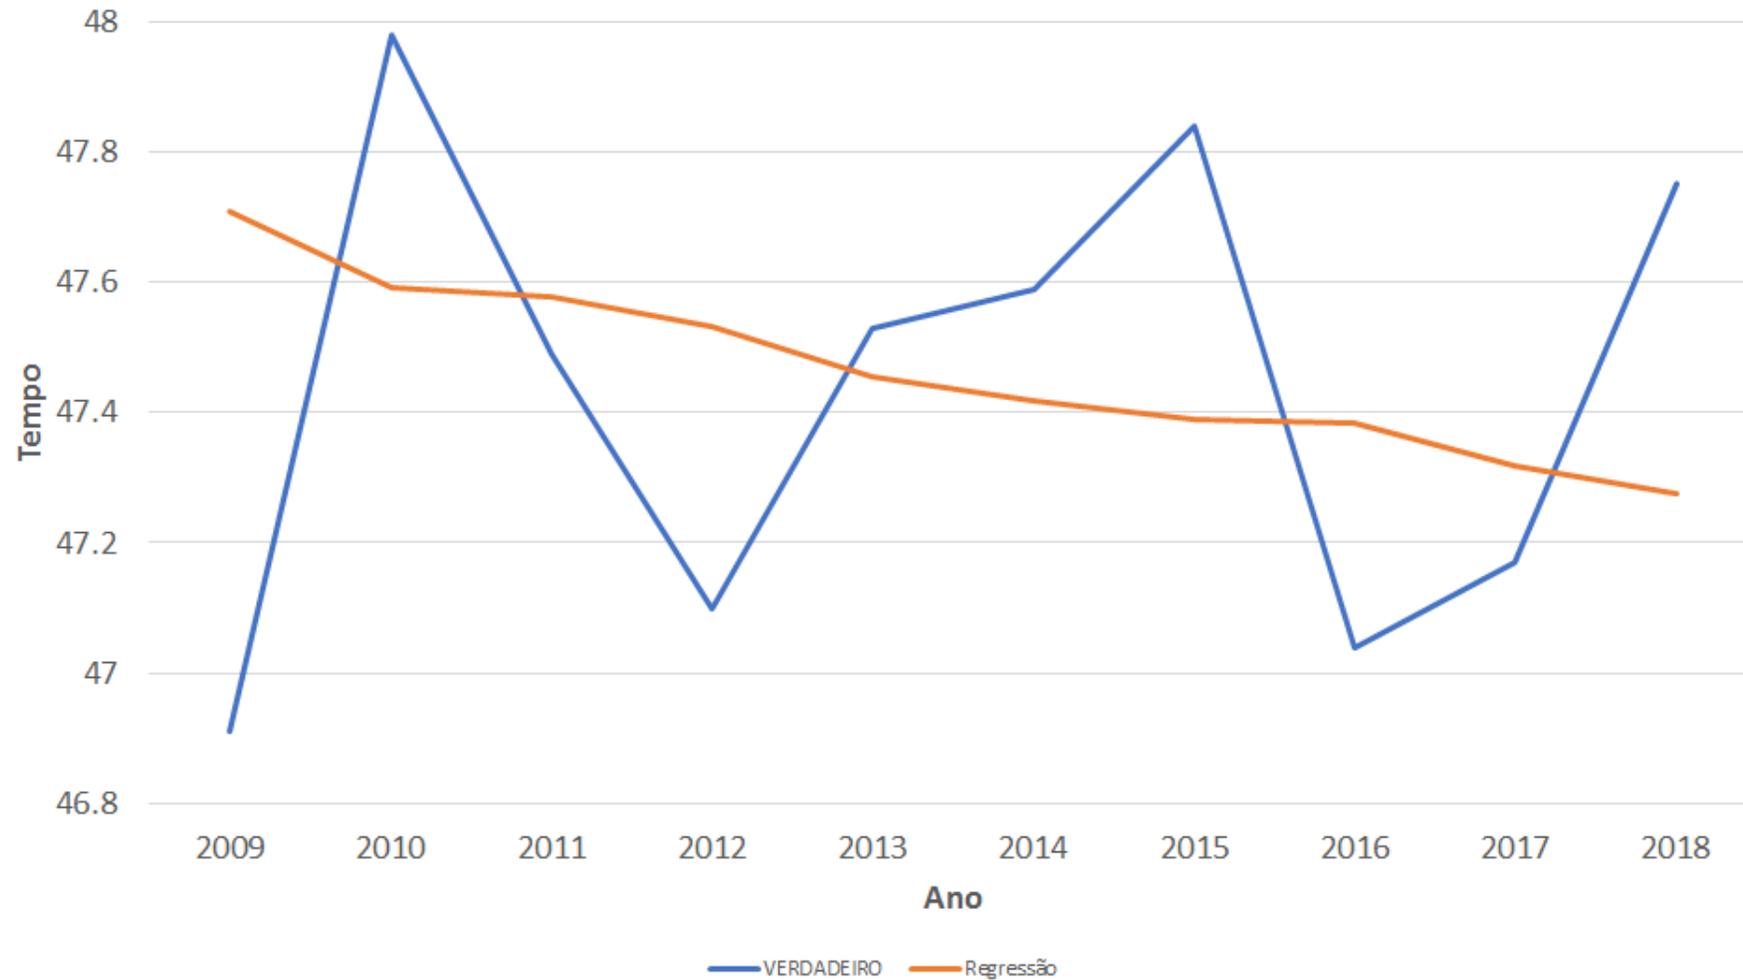
# previsão
yhat = model.predict(x_input, verbose=0)
```

Previsão para o período 2009-2018:

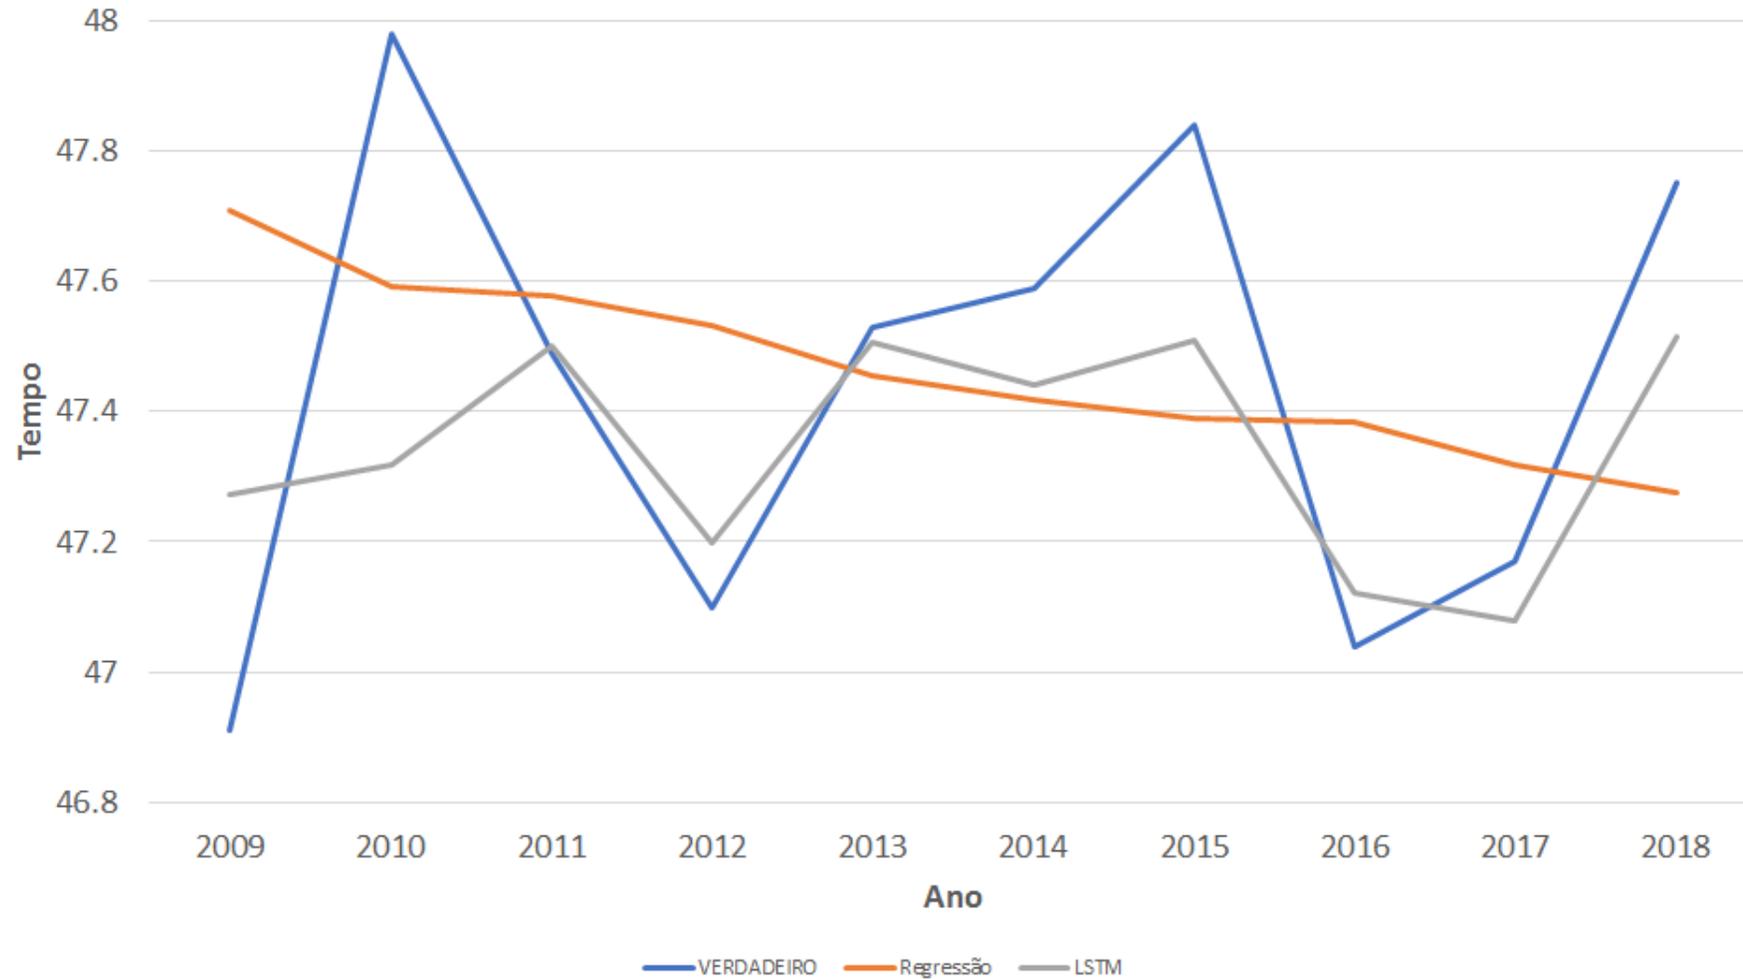
Previsão para o período 2009-2018:



Previsão para o período 2009-2018:



Previsão para o período 2009-2018:



Previsão para o período 2009-2018: comparações entre os modelos

Modelo	MSE	MAE	MAPE
Regressão	0,1589	0,3374	0,0072
Rede LSTM	0,0781	0,2041	0,0043

Considerações finais:

Considerações finais:

- As rede neurais profundas (LSTM) têm impulsionado substanciais progressos em áreas como visão computacional, reconhecimento de imagens, de fala, processamento de linguagem natural etc.

Considerações finais:

- As rede neurais profundas (LSTM) têm impulsionado substanciais progressos em áreas como visão computacional, reconhecimento de imagens, de fala, processamento de linguagem natural etc.
- São “caixas-pretas”, no sentido que a forma funcional do modelo e seus parâmetros não podem ser interpretados, mas possuem uma grande capacidade de aprendizagem e, principalmente, não “esquecer” informações passadas relevantes, em relação aos modelos tradicionais.

“Ao melhorar de forma drástica a habilidade de computadores entenderem o mundo, as rede neurais profundas estão mudando não apenas o campo da computação, mas basicamente todos os campos da ciência e do desenvolvimento humano.”

Jeff Dean, diretor da divisão de IA da Google.

Referências:

- *Colah's Blog* (<https://colah.github.io/>)
- *Machine Learning Mastery* (<https://machinelearningmastery.com>)
- Livro: *Deep Learning* (Ian Goodfellow, Yoshua Bengio, Aaron Courville)
- Livro: *Deep Learning for Time Series Forecasting* (Jason Brownlee)
- Livro: *Deep Learning with R* (François Chollet, J. J. Allaire)
- Danziger, S., Levav, J., & Avnaim-Pesso, L. (2011). Extraneous factors in judicial decisions. *Proceedings of the National Academy of Sciences*, 108(17), 6889-6892.



O Σportístico

A estatística e a ciência de dados no esporte

<http://www.esportistico.com.br>

<http://www.youtube.com/danieltakata>



     **Daniel Takata
Esportístico**

 **daniel.gomes@ibge.gov.br
daniel@esportistico.com.br**

Obrigado!