>>> Um seminário sobre aprendizagem

>>> Seminário de Coisas Legais

Name: Lucas Giraldi Almeida Coimbra

Date: 29 de setembro de 2023

Grafos

>>> Grafos

Grafos:

>>> Grafos

Grafos:

* vértices

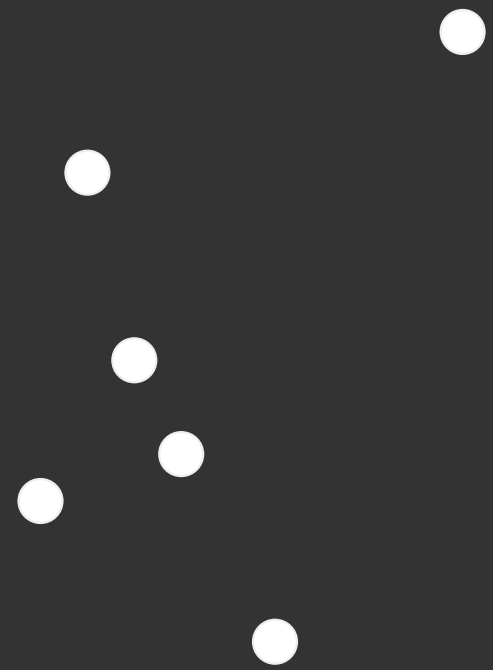

>>> Grafos

Grafos:

* vértices e arestas;

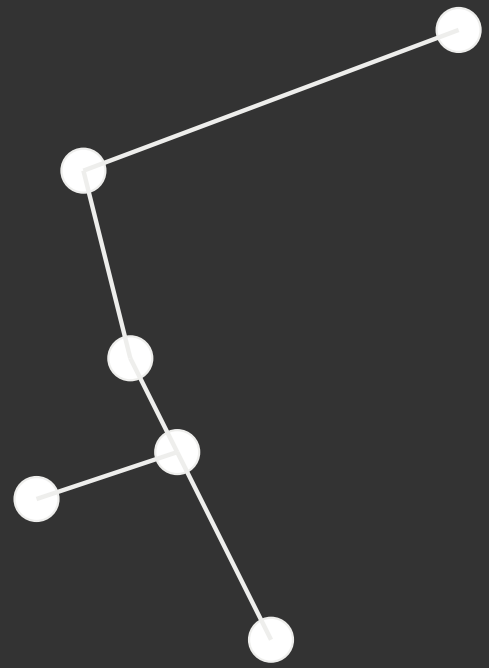

>>> Grafos

Grafos:

* vértices e arestas;

Podem representar:

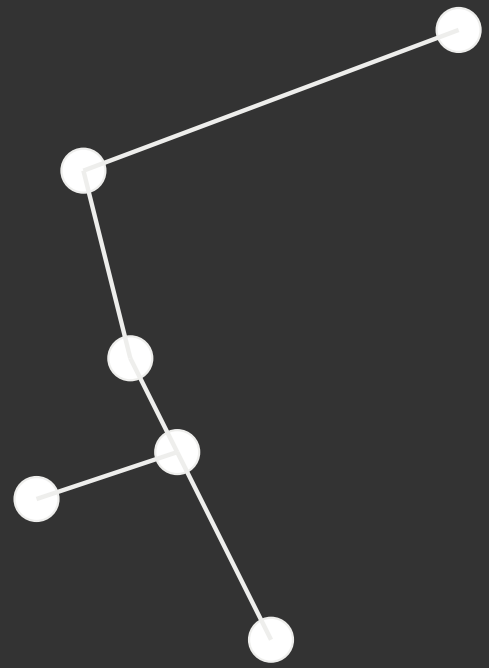

>>> Grafos

Grafos:

* vértices e arestas;

Podem representar:

* Substâncias químicas;

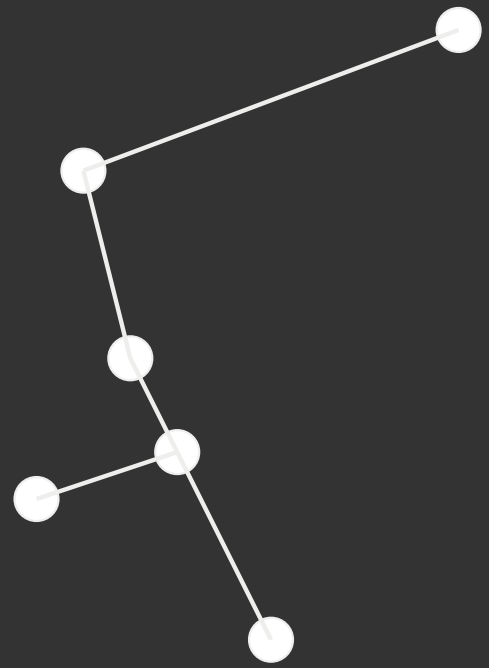

>>> Grafos

Grafos:

* vértices e arestas;

Podem representar:

* Substâncias químicas;
* Redes sociais;

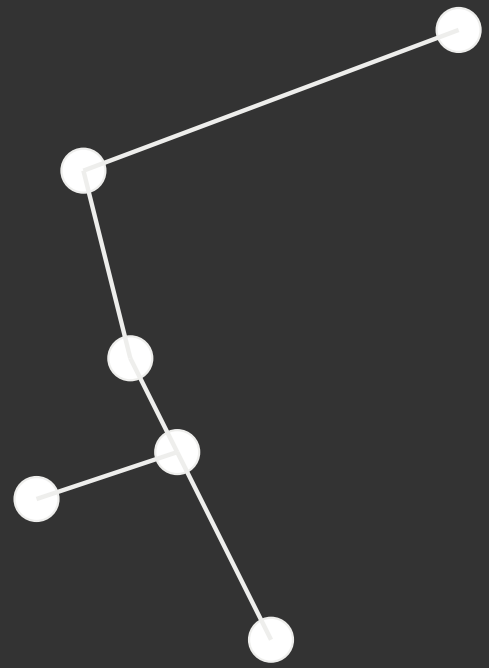

>>> Grafos

Grafos:

* vértices e arestas;

Podem representar:

* Substâncias químicas;
* Redes sociais;
* Cidades interligadas;

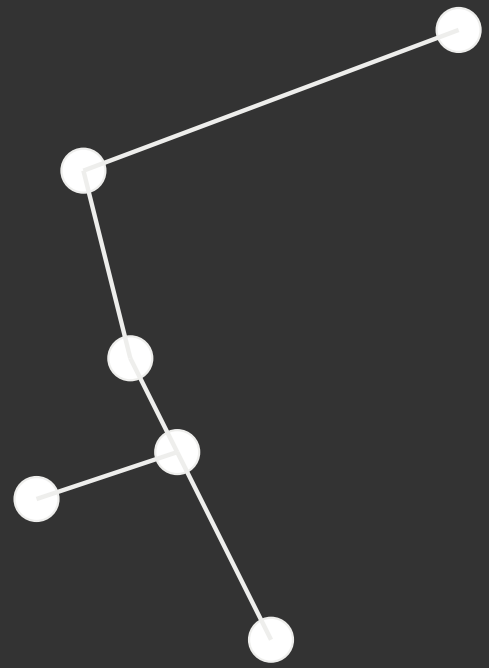

>>> Grafos

Grafos:

* vértices e arestas;

Podem representar:

* Substâncias químicas;
* Redes sociais;
* Cidades interligadas;
* Artigos que referenciam um ao outro;

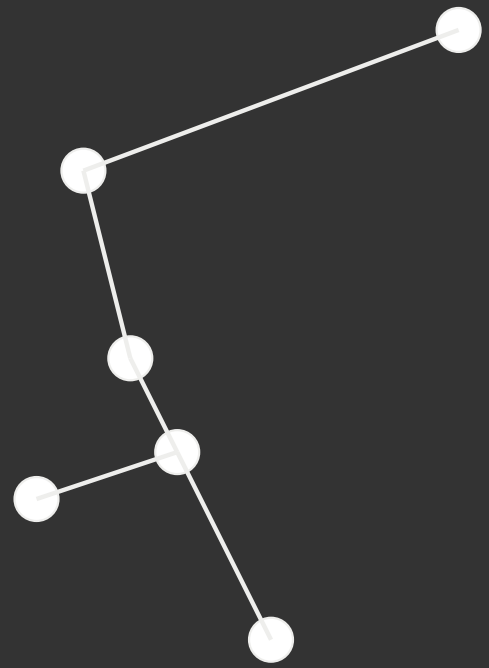

Redes Neurais

>>> Neurônios

>>> Neurônios

Neurônios:

>>> Neurônios

Neurônios:

* Função: recebe coisas e devolve coisas;

>>> Neurônios

Neurônios:

* Função: recebe coisas e devolve coisas;
* Recebe: sinal elétrico (número) de outros neurônios;

>>> Neurônios

Neurônios:

* Função: recebe coisas e devolve coisas;
* Recebe: sinal elétrico (número) de outros neurônios;
* Devolve: um sinal elétrico (número).

>>> Neurônios

Neurônios:

* Função: recebe coisas e devolve coisas;
* Recebe: sinal elétrico (número) de outros neurônios;
* Devolve: um sinal elétrico (número).

IMPORTANTE

>>> Neurônios

Neurônios:

* Função: recebe coisas e devolve coisas;
* Recebe: sinal elétrico (número) de outros neurônios;
* Devolve: um sinal elétrico (número).

IMPORTANTE

Algumas ligações são mais importantes do que outras.

>>> Ligações

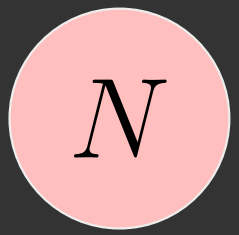

>>> Ligações

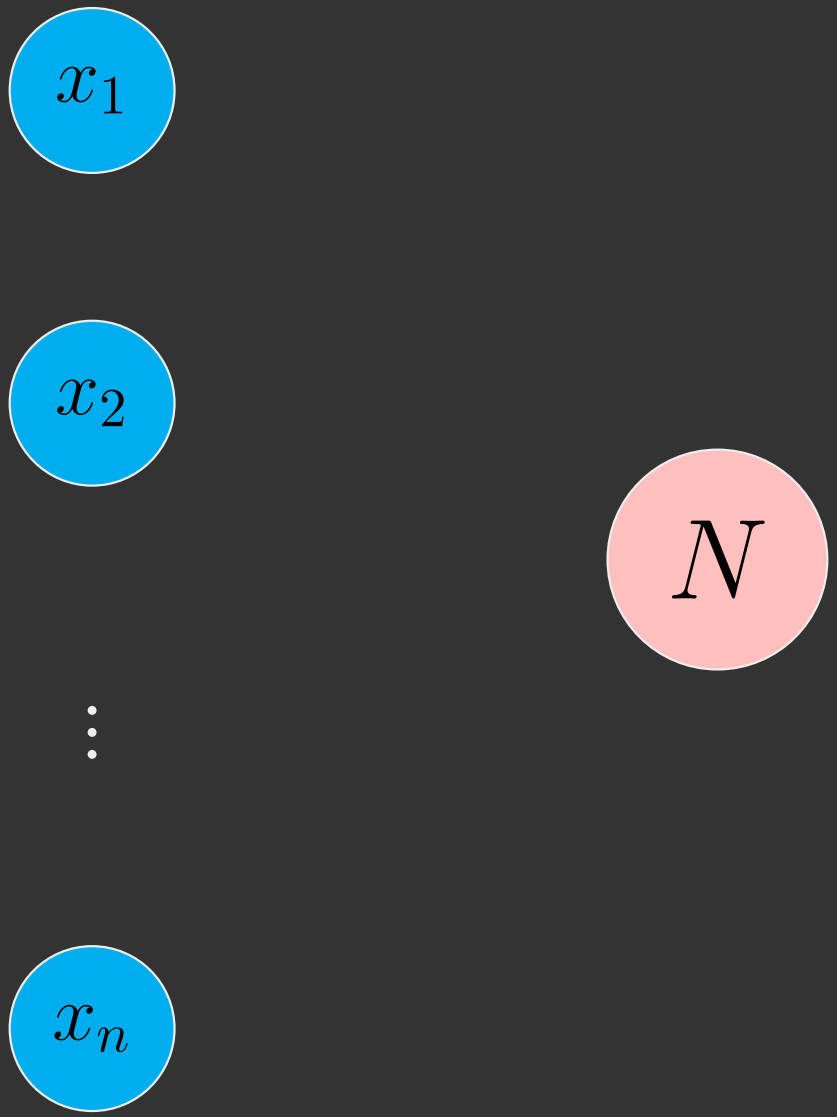

>>> Ligações

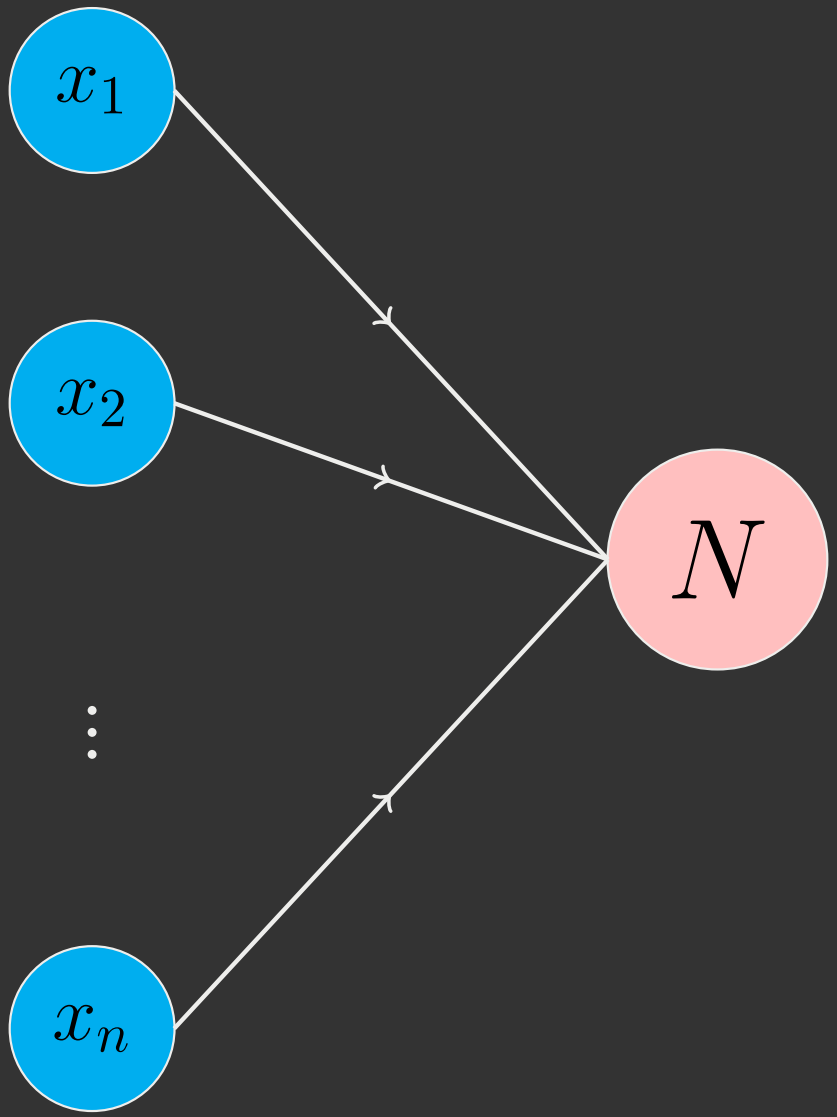

>>> Ligações

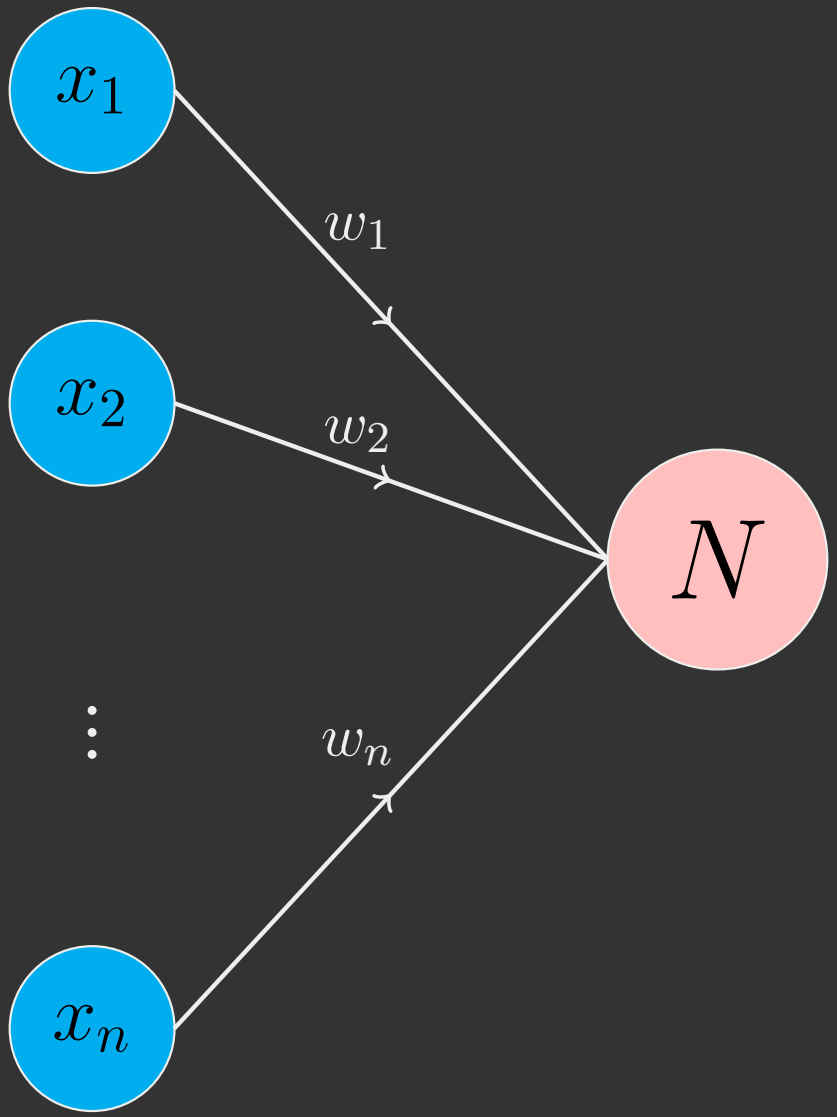

>>> Ligações

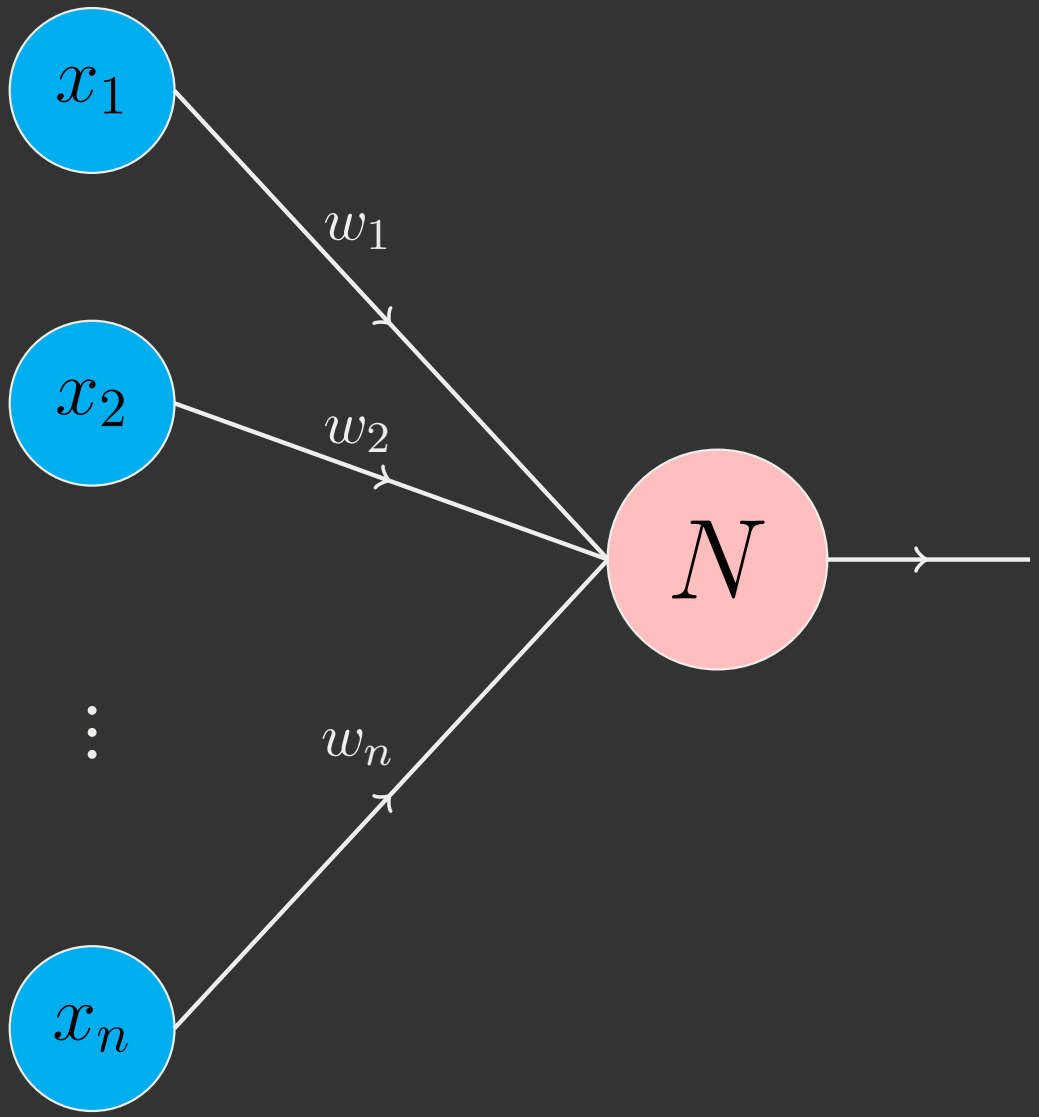

>>> Ligações

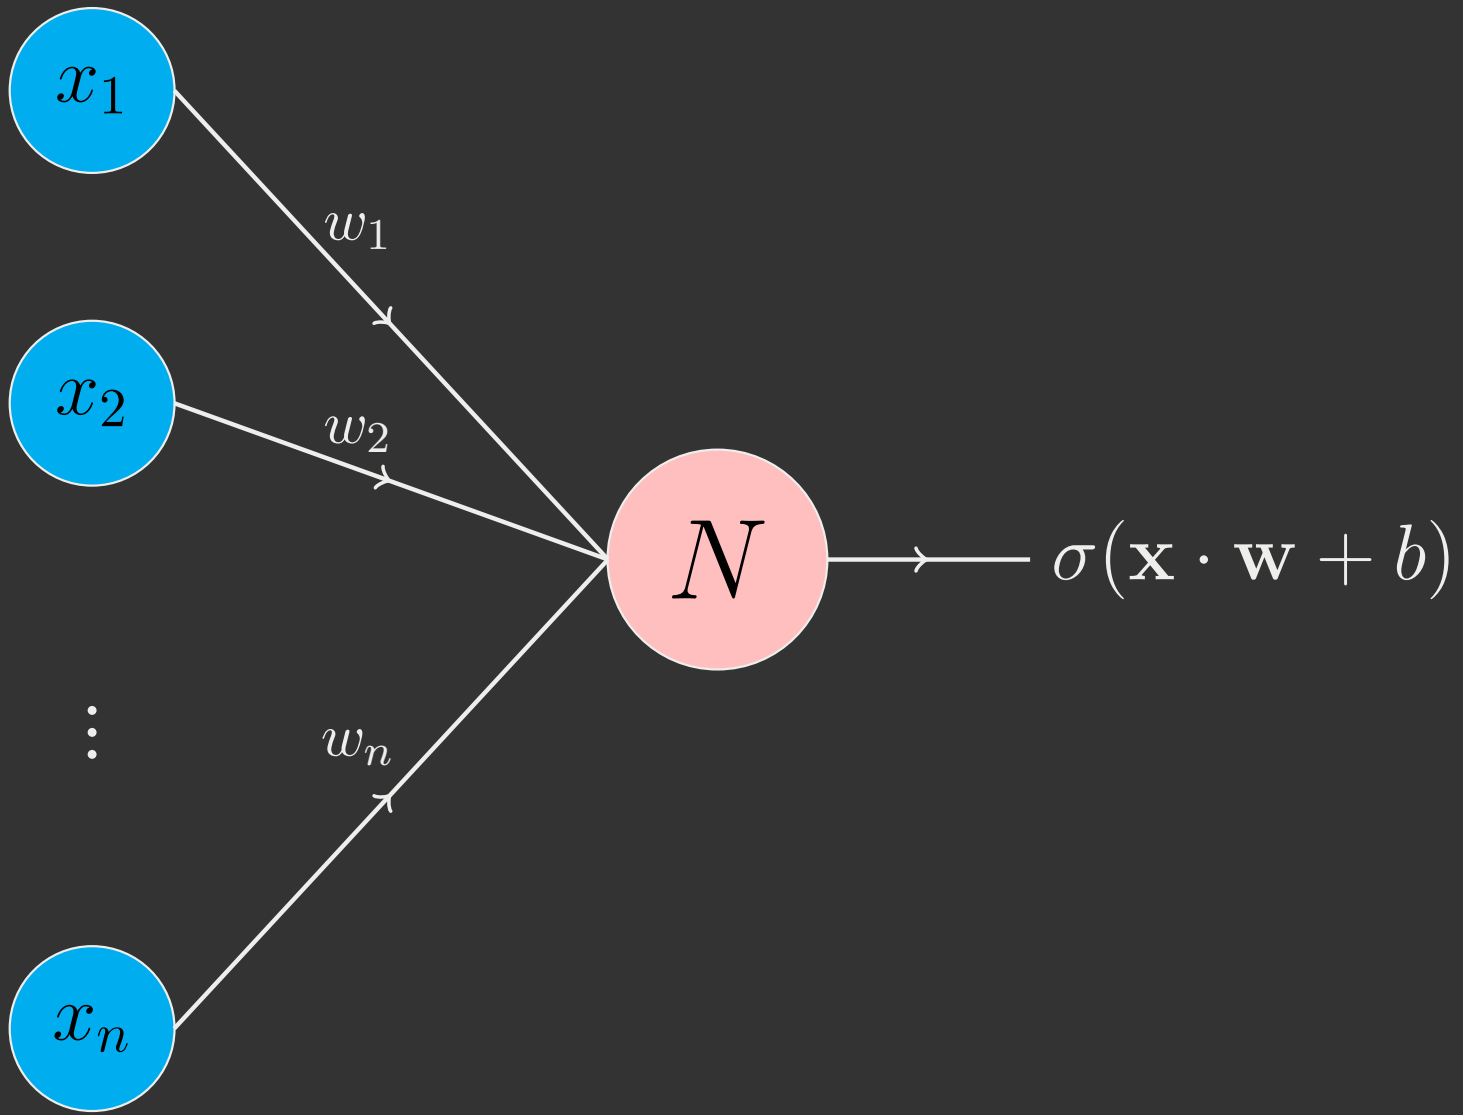

$$\sigma(\mathbf{x} \cdot \mathbf{w} + b)$$

>>> Explicando

$$\sigma\left(\mathbf{x} \cdot \mathbf{w} + b\right)$$

* $\mathbf{x} = (x_1, x_2, \ldots, x_n)$ - sinais;

$$\sigma(\mathbf{x} \cdot \mathbf{w} + b)$$

* $\mathbf{x} = (x_1, x_2, \ldots, x_n)$ - sinais;
* $\mathbf{w} = (w_1, w_2, \ldots, w_n)$ - pesos;

$$\sigma(\mathbf{x} \cdot \mathbf{w} + b)$$

* $\mathbf{x} = (x_1, x_2, \ldots, x_n)$ - sinais;
* $\mathbf{w} = (w_1, w_2, \ldots, w_n)$ - pesos;
* $b \in \mathbb{R}$ - *bias*;

$$\sigma(\mathbf{x} \cdot \mathbf{w} + b)$$

* $\mathbf{x} = (x_1, x_2, \ldots, x_n)$ - sinais;
* $\mathbf{w} = (w_1, w_2, \ldots, w_n)$ - pesos;
* $b \in \mathbb{R}$ - *bias*;
* $\sigma \colon \mathbb{R} \to \mathbb{R}$ - função de ativação.

>>> Neurônio (de novo)

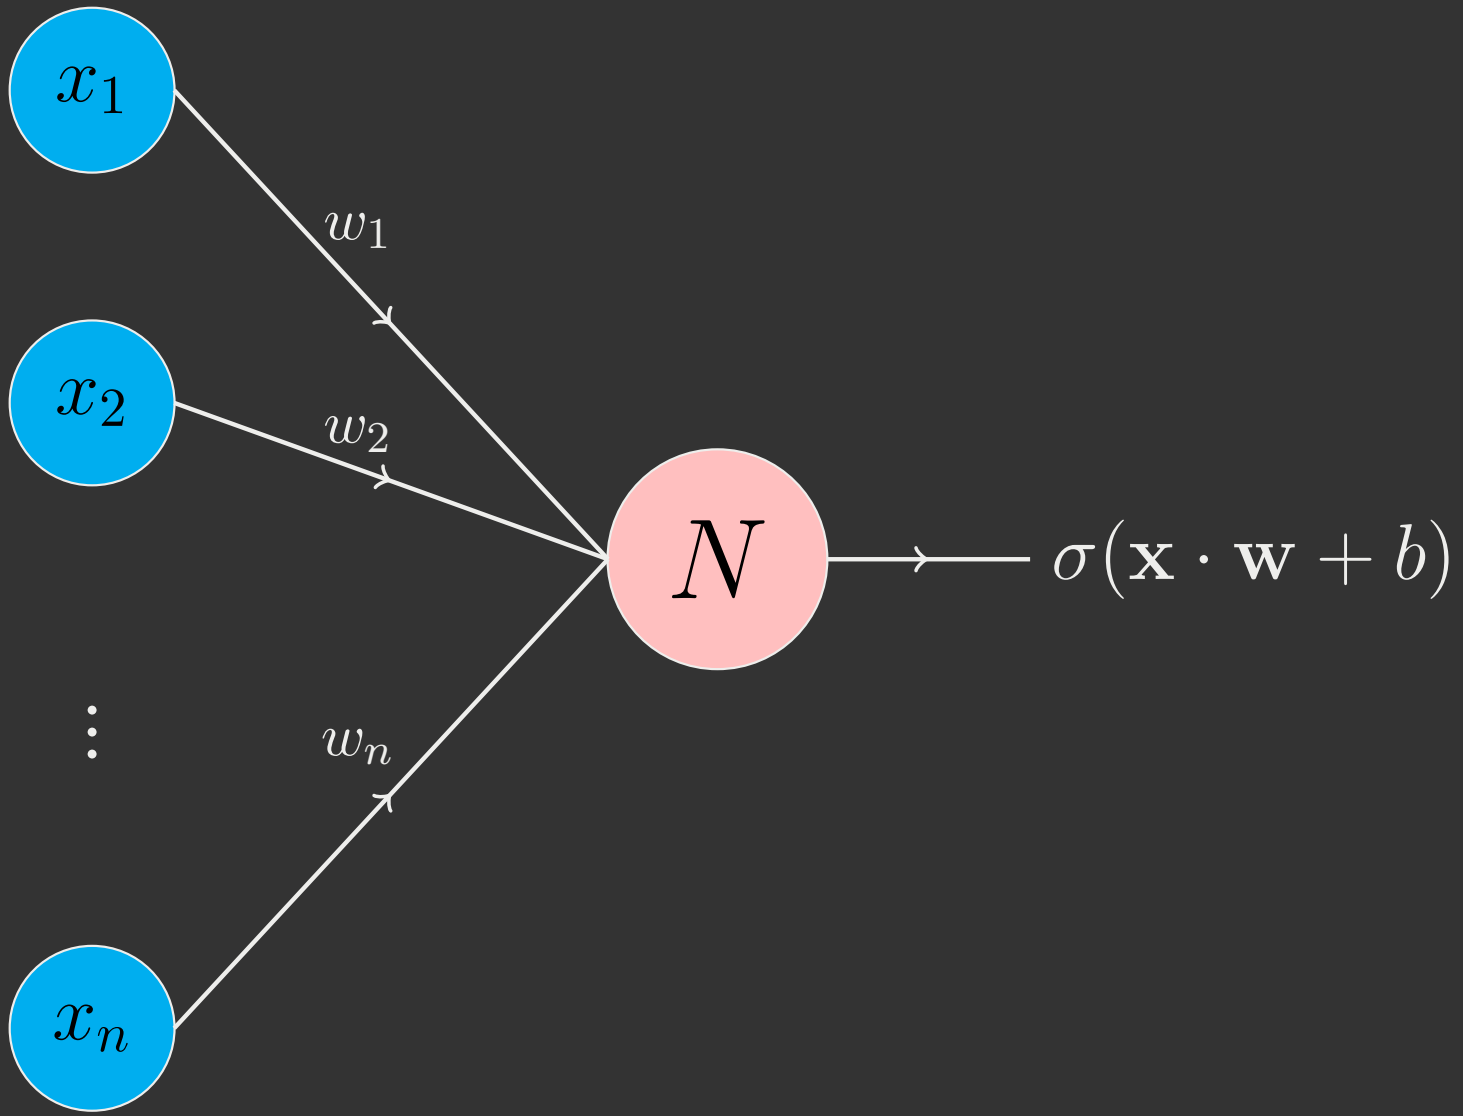

>>> Função de ativação

$$\sigma(x) = \frac{1}{1+e^{-x}}$$

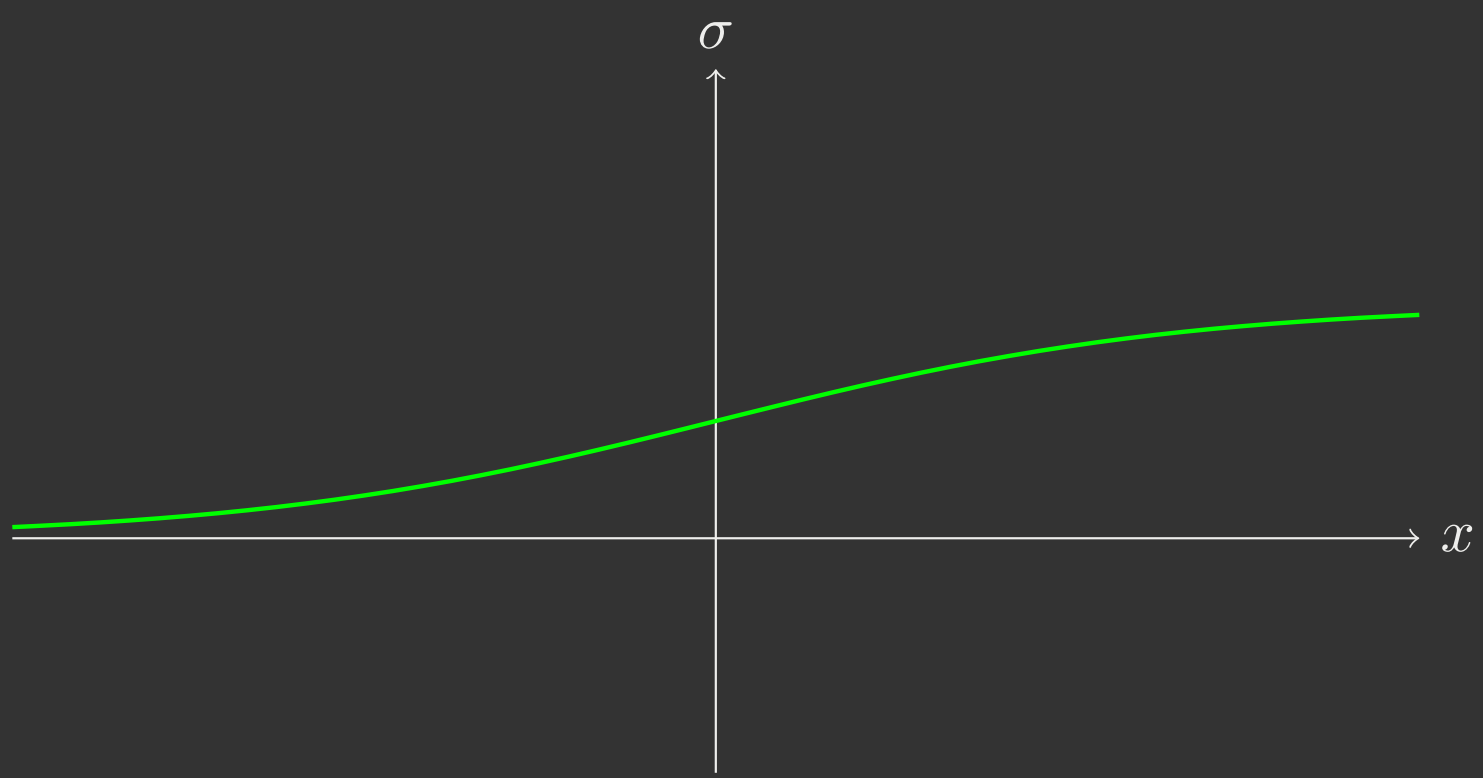

>>> Aprendendo

Por que aprender?

Por que aprender?

* Dado x, queremos que o neurônio transmita um valor t;

Por que aprender?

* Dado $\mathbf{x}$, queremos que o neurônio transmita um valor t;
* Com os pesos $\mathbf{w}$ e o *bias* b, o neurônio está transmitindo um valor y.

>>> Aprendendo

Por que aprender?

* Dado $\mathbf{x}$, queremos que o neurônio transmita um valor t;
* Com os pesos $\mathbf{w}$ e o *bias* b, o neurônio está transmitindo um valor y.

O que é aprender?

>>> Aprendendo

Por que aprender?

* Dado $\mathbf{x}$, queremos que o neurônio transmita um valor t;
* Com os pesos $\mathbf{w}$ e o *bias* b, o neurônio está transmitindo um valor y.

O que é aprender?

* Calcular erro: $E(y) = |y - t|$;

>>> Aprendendo

Por que aprender?

* Dado $\mathbf{x}$, queremos que o neurônio transmita um valor t;
* Com os pesos $\mathbf{w}$ e o *bias* b, o neurônio está transmitindo um valor y.

O que é aprender?

* Calcular erro: $E(y) = |y - t|$;
* Mudar $\mathbf{w}$ e b para diminuir $E(y)$.

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;
* Cada pessoa é representada por um vetor x que contém dados numéricos da ficha médica, como pressão, temperatura e peso;

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;
* Cada pessoa é representada por um vetor $\mathbf{x}$ que contém dados numéricos da ficha médica, como pressão, temperatura e peso;
* Urgência: número entre 0 e 1.

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;
* Cada pessoa é representada por um vetor $\mathbf{x}$ que contém dados numéricos da ficha médica, como pressão, temperatura e peso;
* Urgência: número entre 0 e 1. Se for 0, não é urgente, se for 1, precisa de atendimento rápido;

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;
* Cada pessoa é representada por um vetor $\mathbf{x}$ que contém dados numéricos da ficha médica, como pressão, temperatura e peso;
* Urgência: número entre 0 e 1. Se for 0, não é urgente, se for 1, precisa de atendimento rápido;
* Sabemos: os dados da pessoa $\mathbf{x}$ e qual a urgência dela;

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;
* Cada pessoa é representada por um vetor $\mathbf{x}$ que contém dados numéricos da ficha médica, como pressão, temperatura e peso;
* Urgência: número entre 0 e 1. Se for 0, não é urgente, se for 1, precisa de atendimento rápido;
* Sabemos: os dados da pessoa $\mathbf{x}$ e qual a urgência dela;
* Treinamos o neurônio para que, ao receber $\mathbf{x}$, retorne a sua urgência;

>>> Aprendi, e agora?

* Situação: queremos ordenar pessoas para atendimento em um pronto-socorro;
* Cada pessoa é representada por um vetor $\mathbf{x}$ que contém dados numéricos da ficha médica, como pressão, temperatura e peso;
* Urgência: número entre 0 e 1. Se for 0, não é urgente, se for 1, precisa de atendimento rápido;
* Sabemos: os dados da pessoa $\mathbf{x}$ e qual a urgência dela;
* Treinamos o neurônio para que, ao receber $\mathbf{x}$, retorne a sua urgência;
* Esperamos que, ao receber uma pessoa $\mathbf{x}'$, o neurônio retorne como seu sinal, mais ou menos corretamente, a urgência de $\mathbf{x}'$.

>>> Só um?

Neurônios são poderosos sozinhos.

>>> Só um?

Neurônios são poderosos sozinhos.
E se pegarmos vários?

>>> Rede Neural

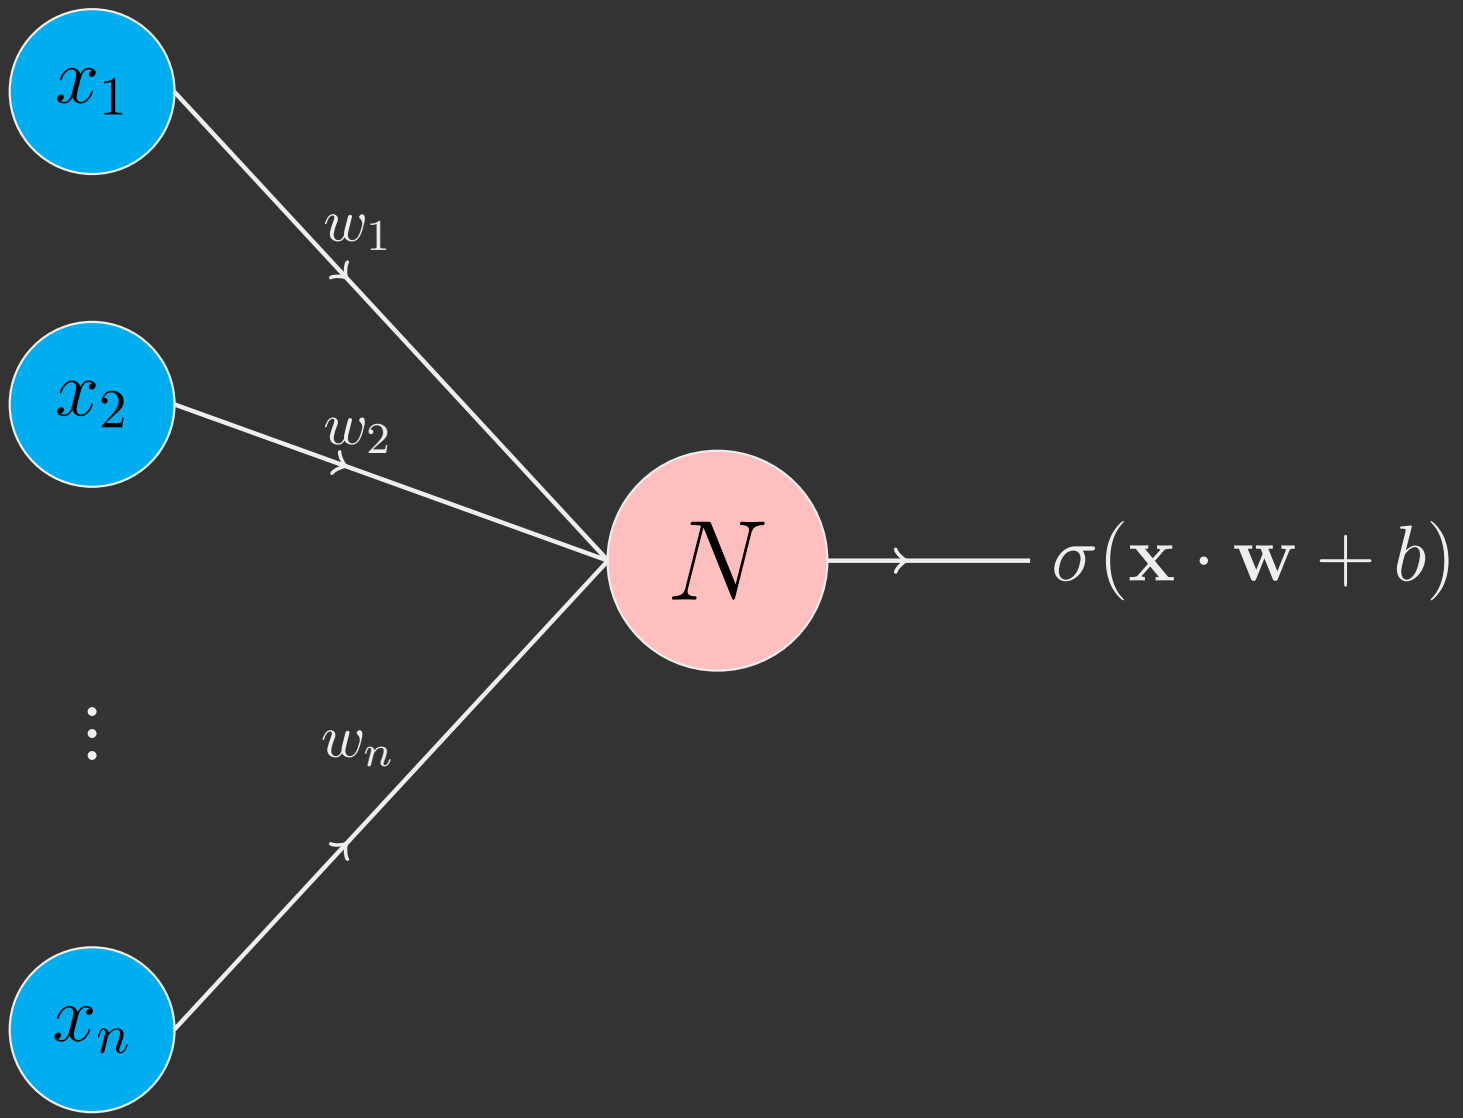

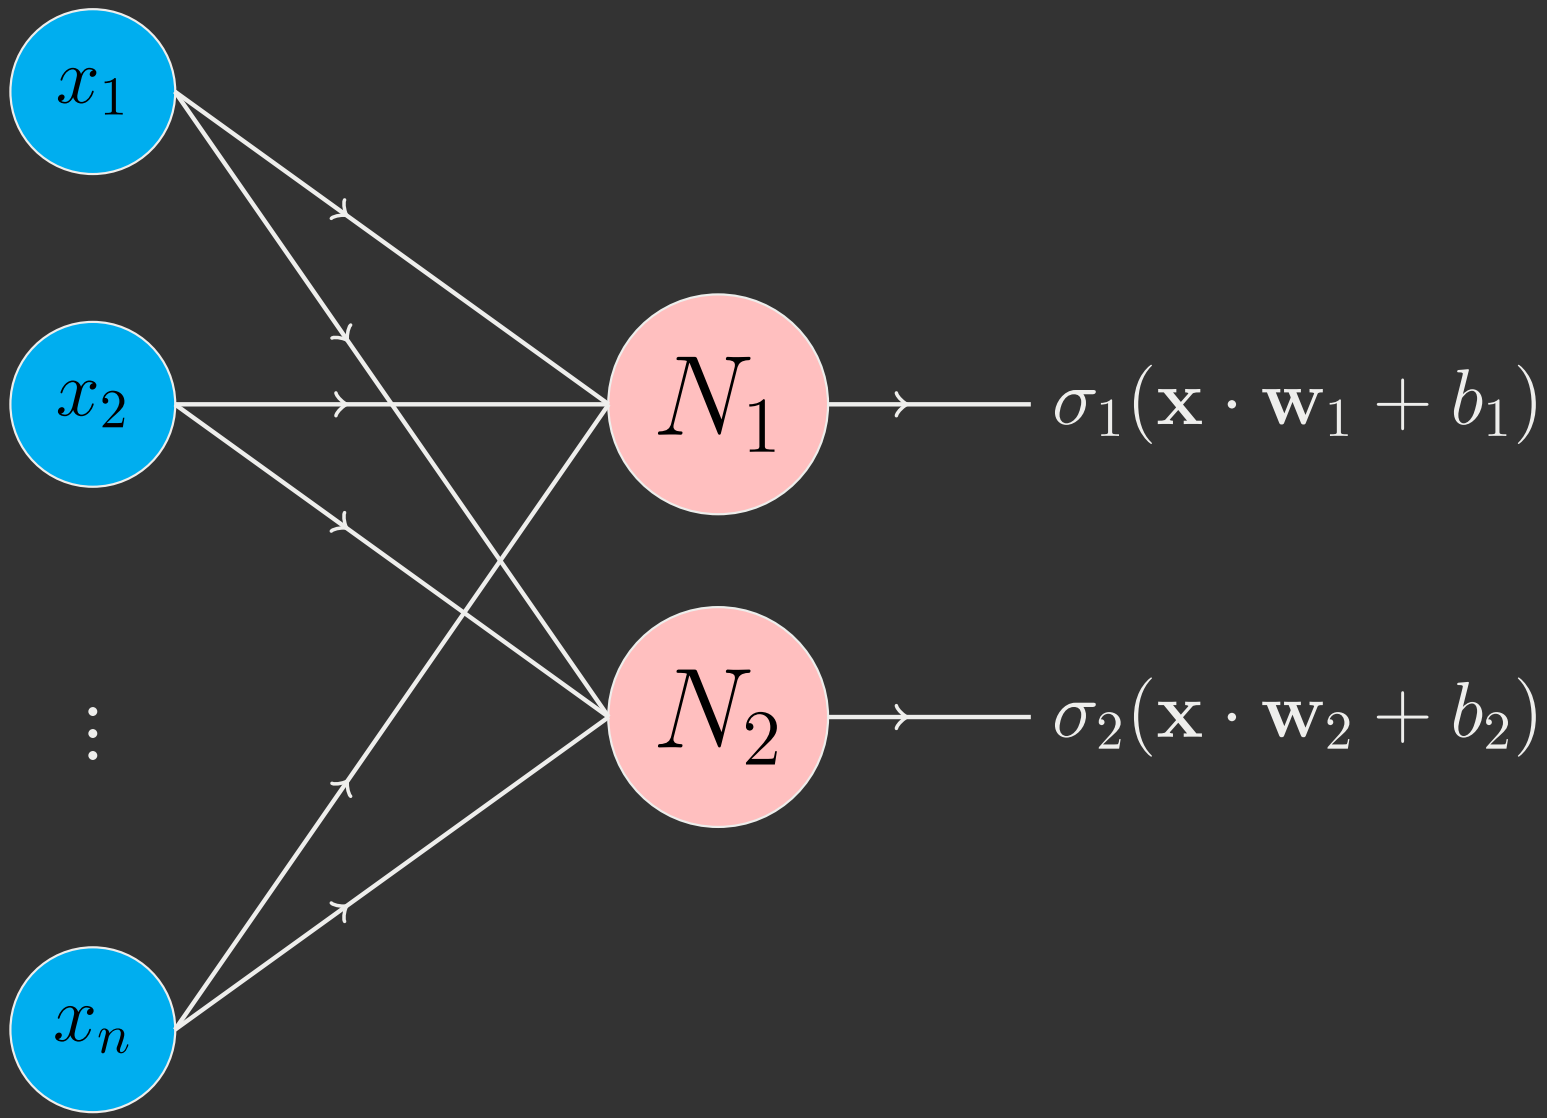
x_1
x_2
$\vdots$
x_n
N_1
N_2
$\sigma_1(\mathbf{x} \cdot \mathbf{w}_1 + b_1)$
$\sigma_2(\mathbf{x} \cdot \mathbf{w}_2 + b_2)$

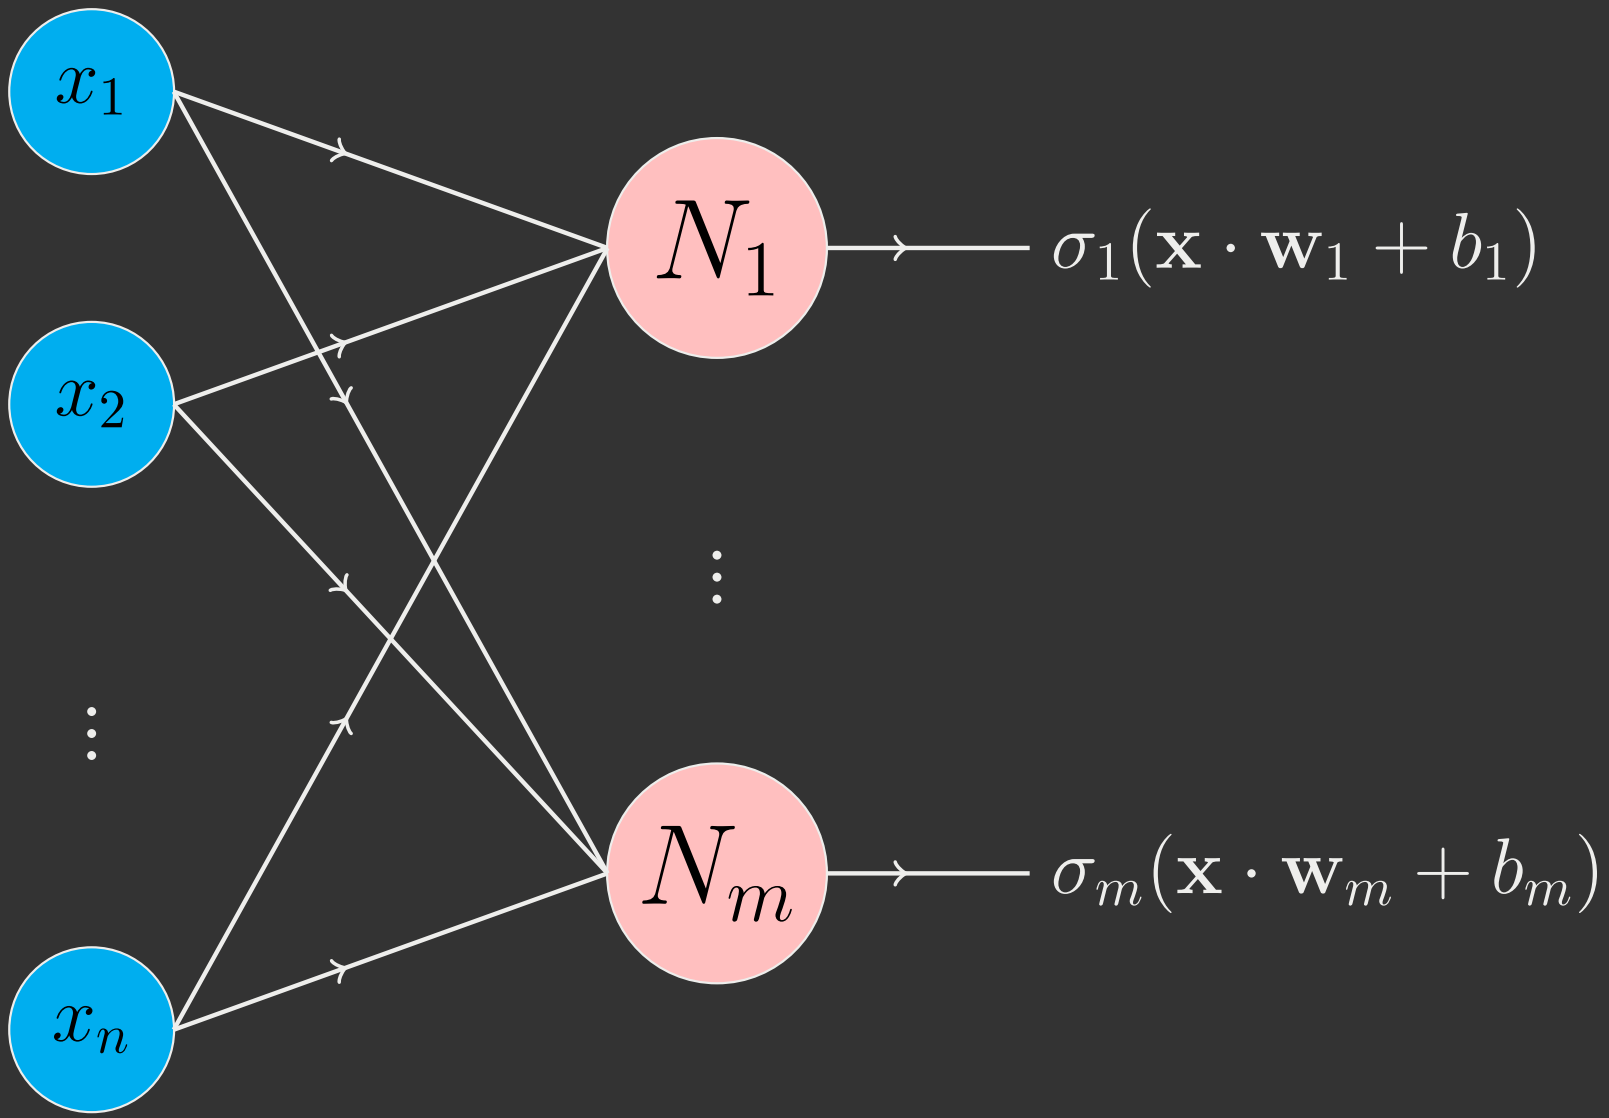
x_1
x_2
x_n
N_1
N_m
$\sigma_1(\mathbf{x} \cdot \mathbf{w}_1 + b_1)$
$\sigma_m(\mathbf{x} \cdot \mathbf{w}_m + b_m)$

>>> Rede Neural

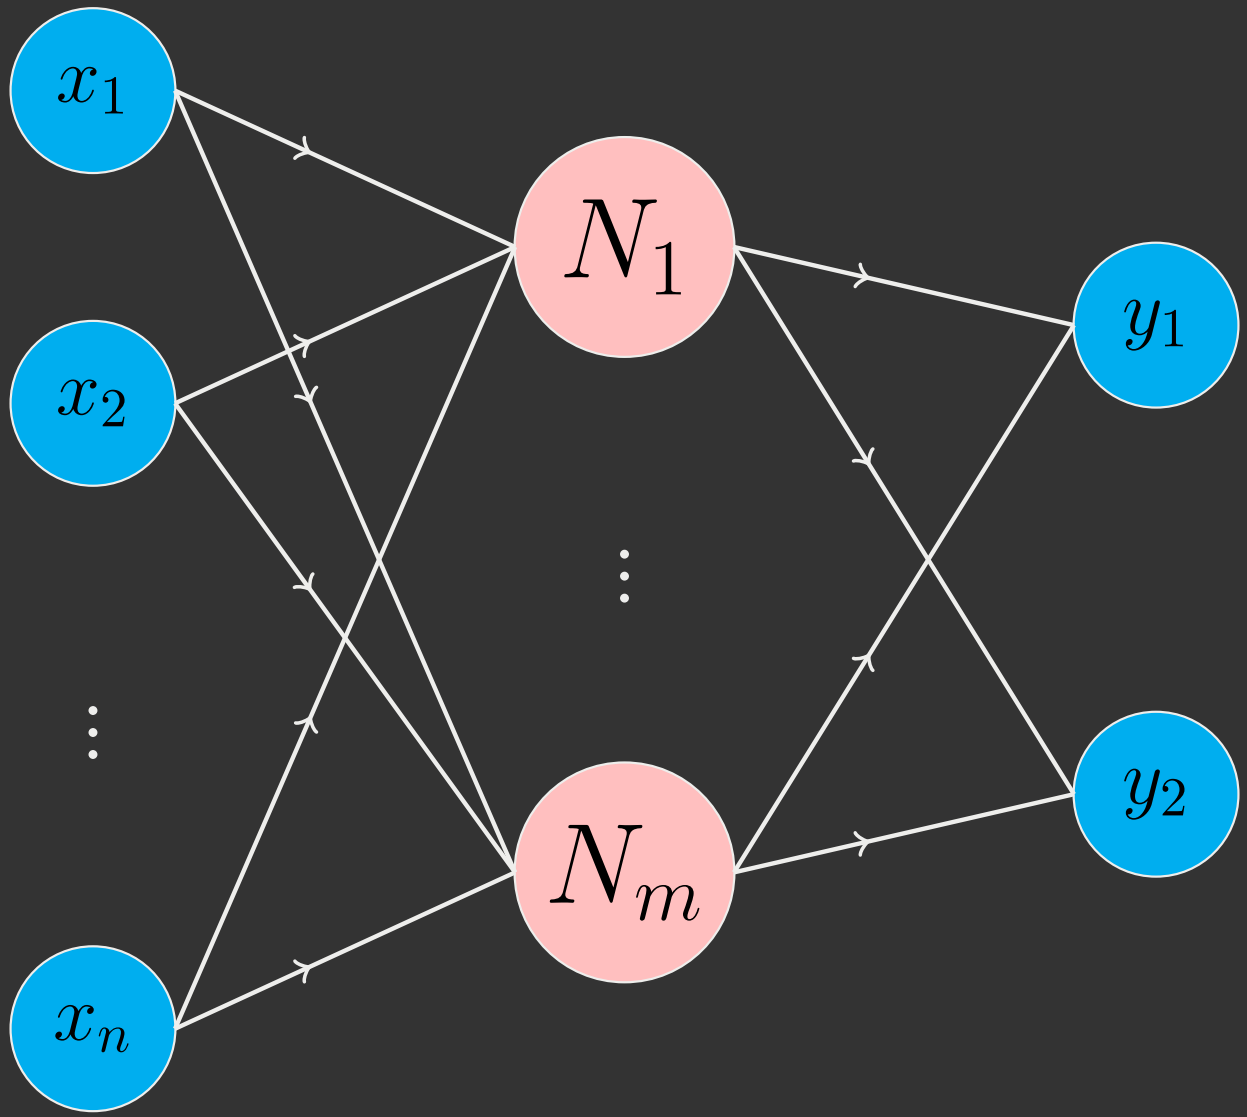

>>> Aprendendo (de novo)

A ideia é a mesma, mas agora temos $\mathbf{y} = (y_1, y_2)$, $\mathbf{t} = (t_1, t_2)$ e o erro

$$E(\mathbf{y}) = ||\mathbf{y} - \mathbf{t}||.$$

>>> Aprendendo (de novo)

A ideia é a mesma, mas agora temos $\mathbf{y} = (y_1, y_2)$, $\mathbf{t} = (t_1, t_2)$ e o erro

$$E(\mathbf{y}) = ||\mathbf{y} - \mathbf{t}||.$$

PROBLEMA

Ligações de uma camada interferem no valor de neurônios de outras camadas: treinamento é mais difícil.

Convolução

>>> Vizinhos e Grau

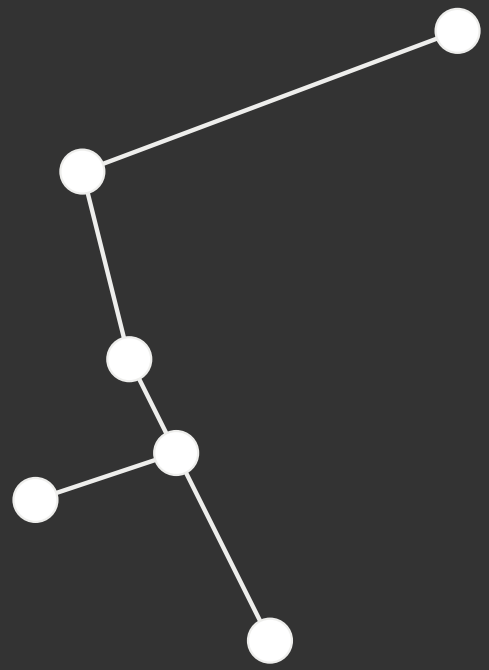

>>> Vizinhos e Grau

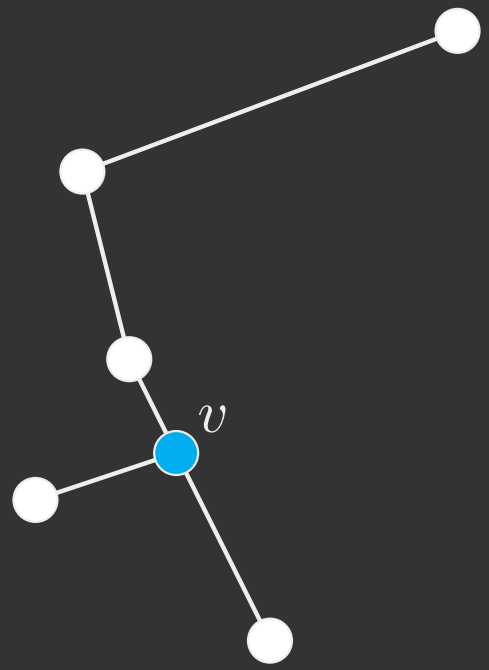

>>> Vizinhos e Grau

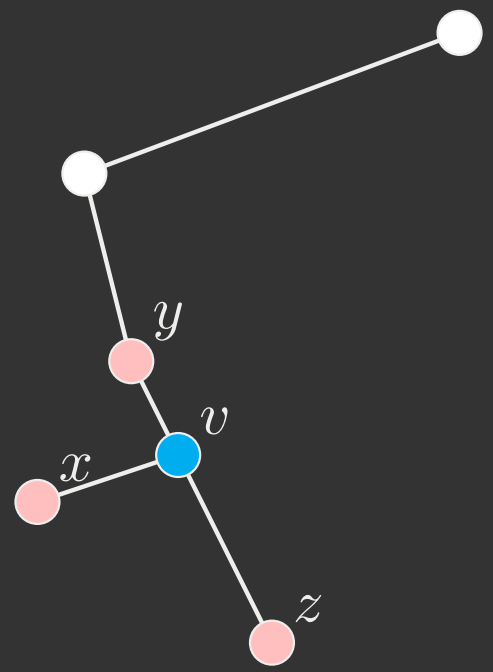

>>> Vizinhos e Grau

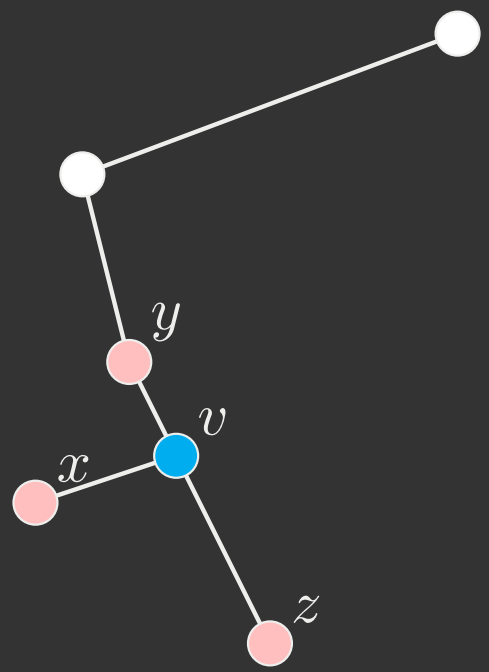

Vizinhança: pontos rosas.

>>> Vizinhos e Grau

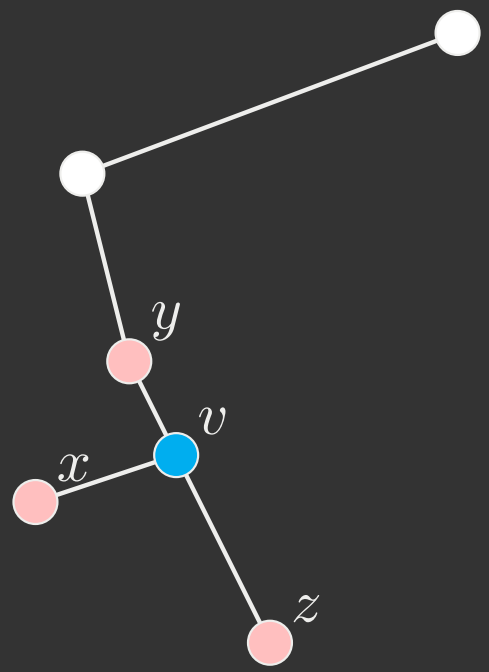

Vizinhança: pontos rosas. Nesse caso, $\mathcal{N}(v) = \{x, y, z\}$.

>>> Vizinhos e Grau

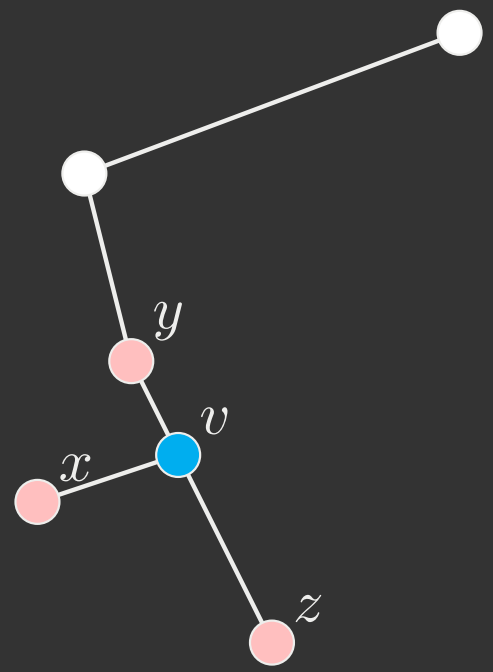

Vizinhança: pontos rosas. Nesse caso, $\mathcal{N}(v) = \{x, y, z\}$.

Grau: número de vizinhos.

>>> Vizinhos e Grau

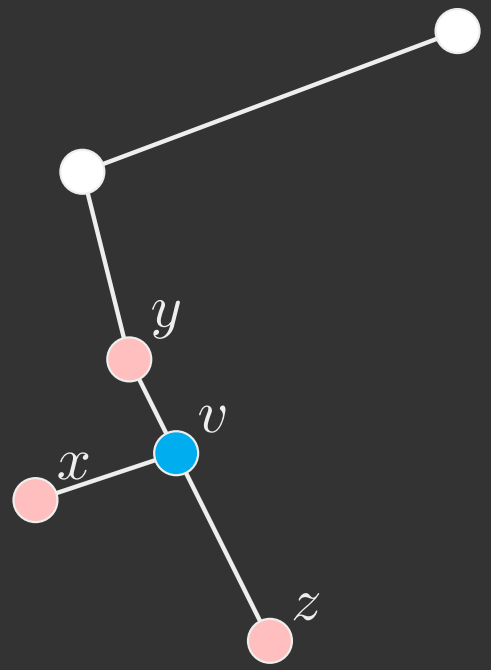

Vizinhança: pontos rosas. Nesse caso, $\mathcal{N}(v) = \{x, y, z\}$.
Grau: número de vizinhos. Nesse caso, $\deg(v) = 3$.

PROBLEMA

O número $\deg(v)$ só contém informação sobre o vértice v.

PROBLEMA

O número $\deg(v)$ só contém informação sobre o vértice v.

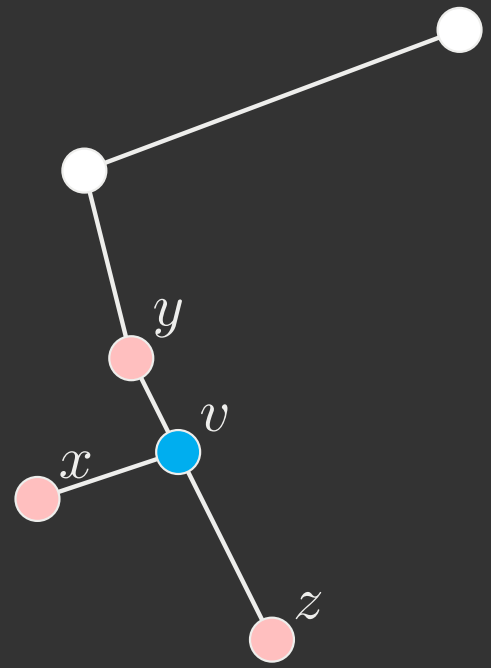

PROBLEMA

O número $\deg(v)$ só contém informação sobre o vértice v.

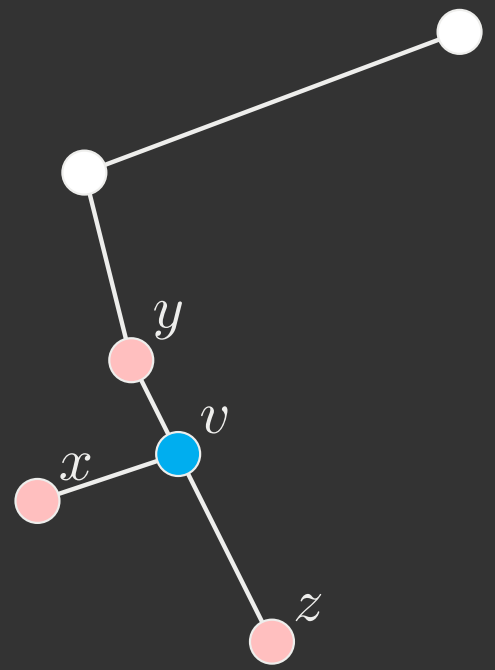

$$\deg_2(v) = \frac{\deg(v) + \deg(x) + \deg(y) + \deg(z)}{4}$$

PROBLEMA

O número $\deg(v)$ só contém informação sobre o vértice v.

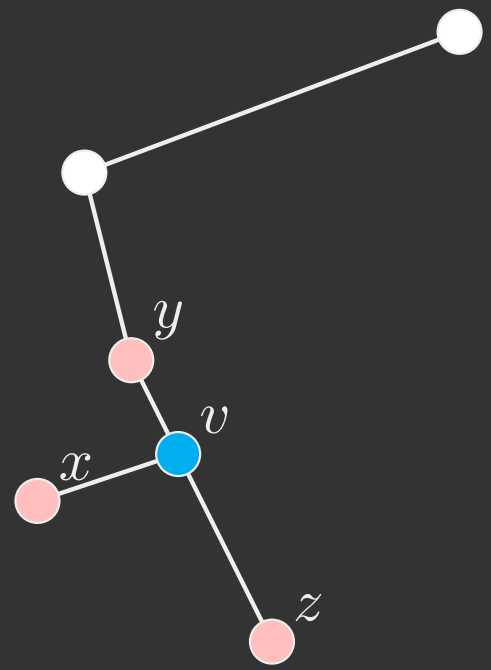

$$\deg_2(v) = \frac{\deg(v) + \deg(x) + \deg(y) + \deg(z)}{4}$$

O número $\deg_2(v)$ contém informação sobre v e seus vizinhos.

GNNs - Graph Neural Networks

Redes Neurais em Grafos

>>> GNNs - Primeiro passo

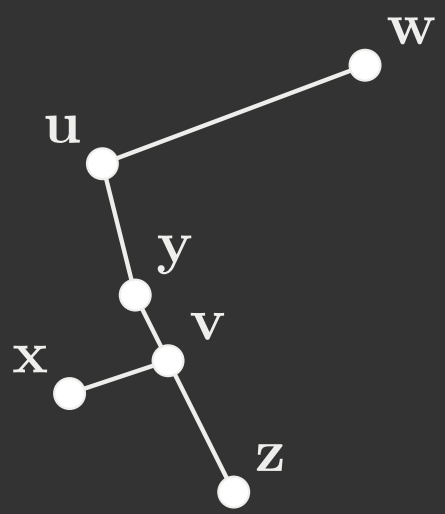

>>> GNNs - Primeiro passo

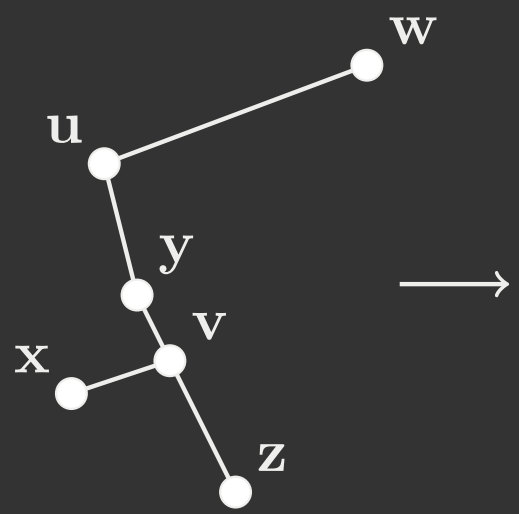

>>> GNNs - Primeiro passo

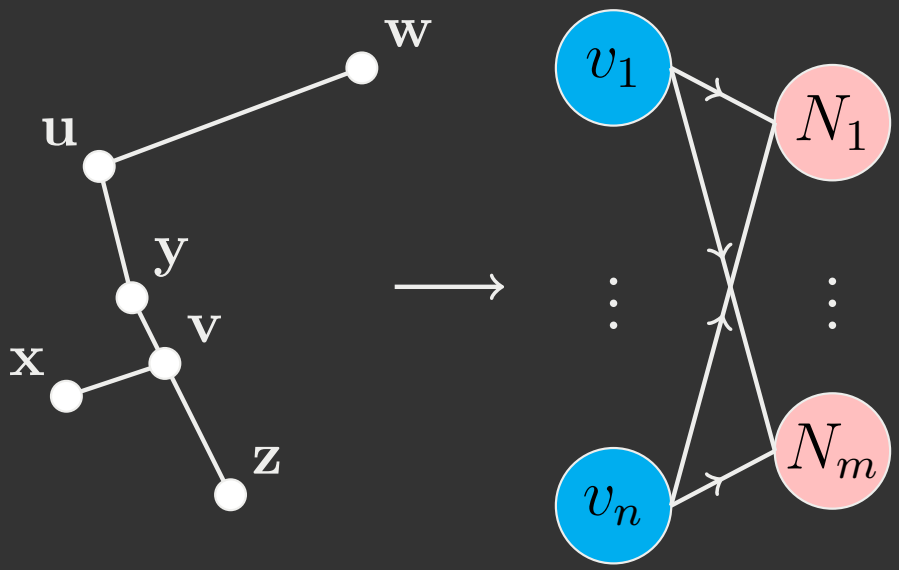

>>> GNNs - Primeiro passo

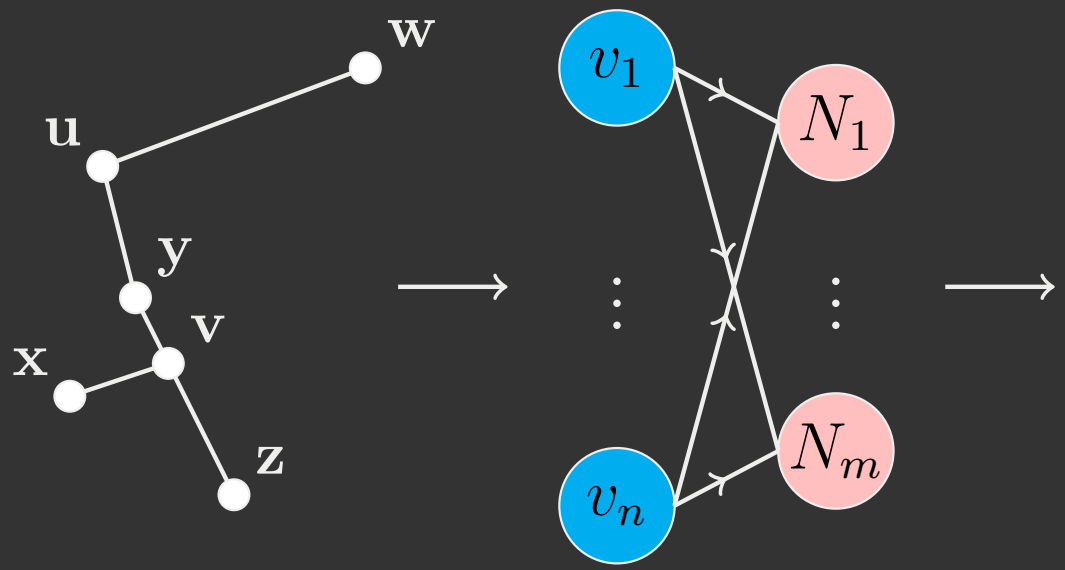

>>> GNNs - Primeiro passo

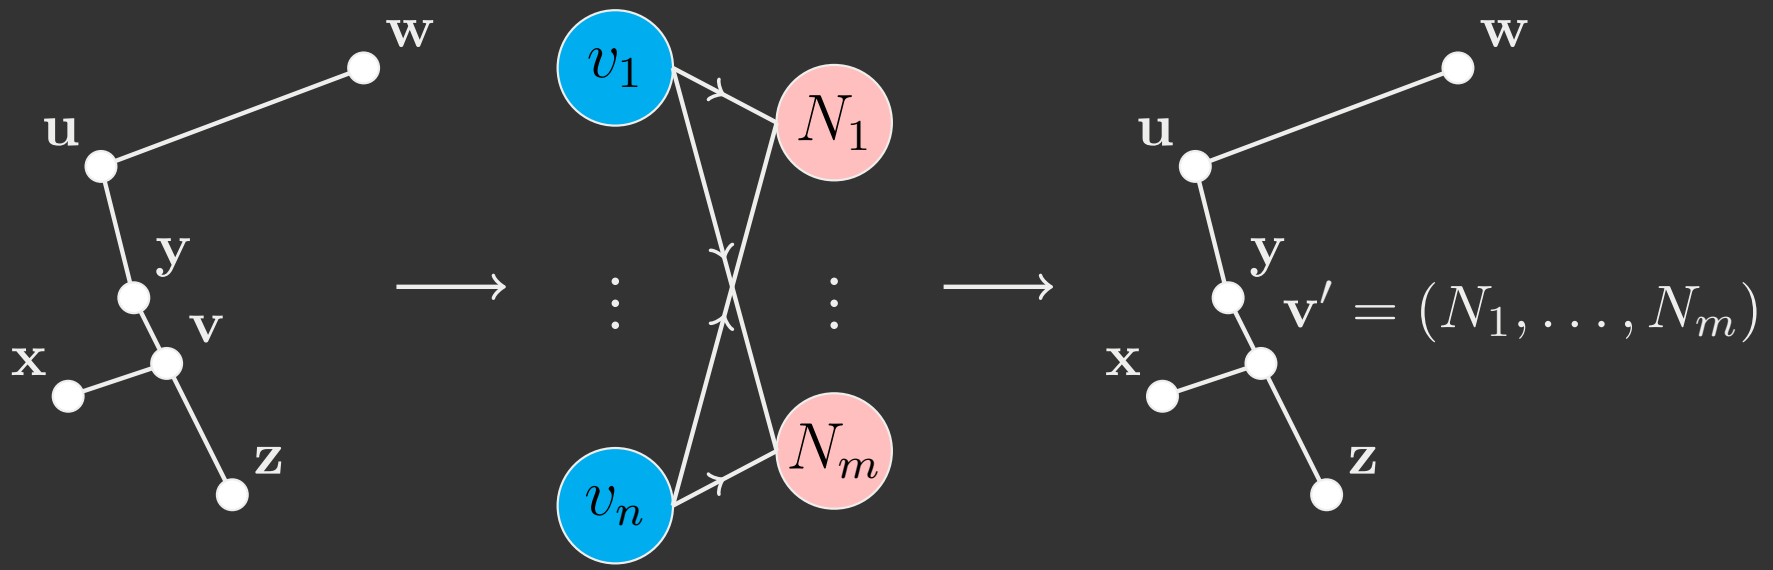

>>> GNNs - Segundo passo

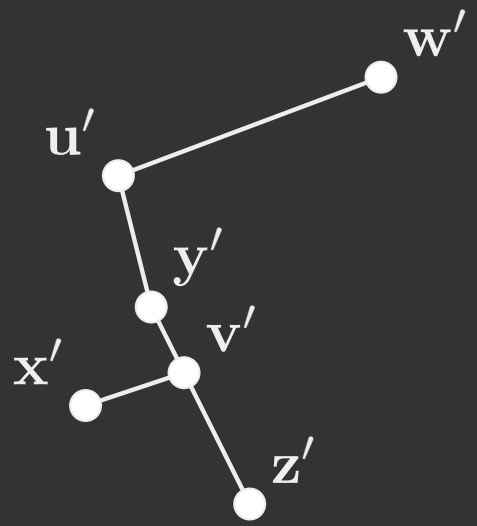

>>> GNNs - Segundo passo

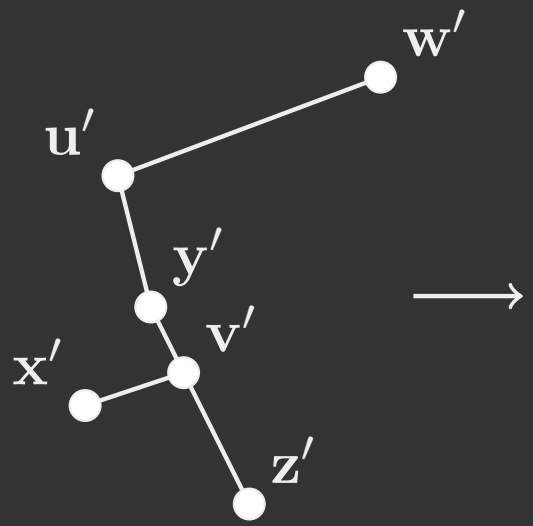

>>> GNNs - Segundo passo

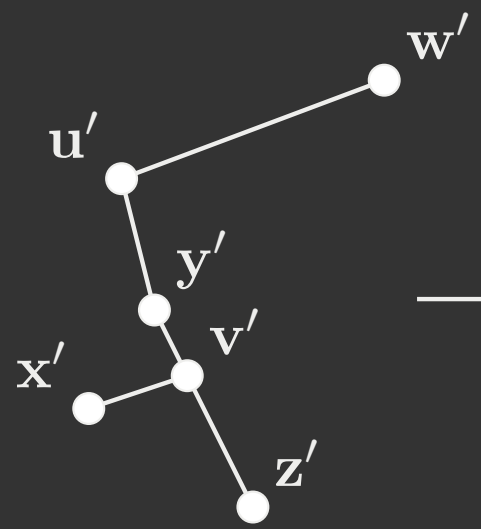

$$\longrightarrow \quad \mathbf{u}_1 = \frac{\mathbf{u}'+\mathbf{w}'+\mathbf{y}'}{3}$$

$$\vdots$$

$$\mathbf{z}_1 = \frac{\mathbf{z}'+\mathbf{v}'}{2}$$

>>> GNNs - Segundo passo

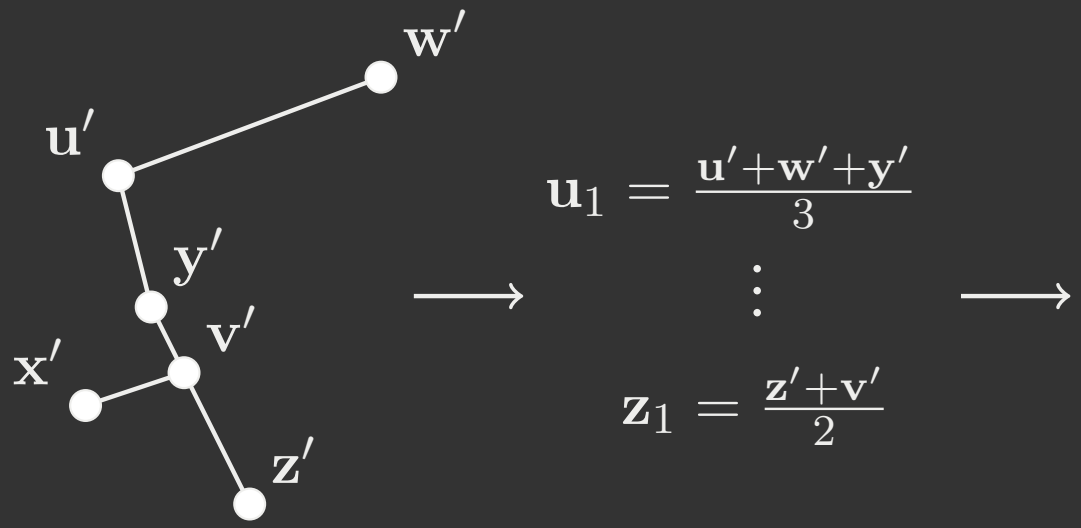

>>> GNNs - Segundo passo

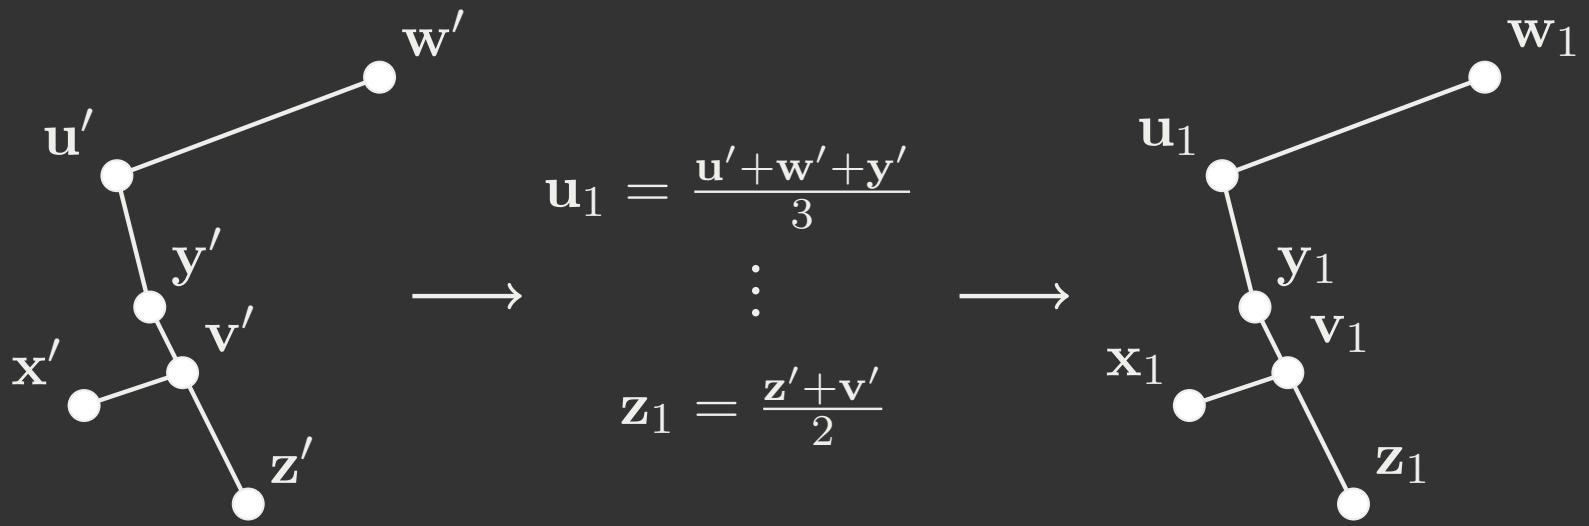

>>> Conclusão

Repetindo o processo k vezes, obtemos

>>> Conclusão

Repetindo o processo k vezes, obtemos

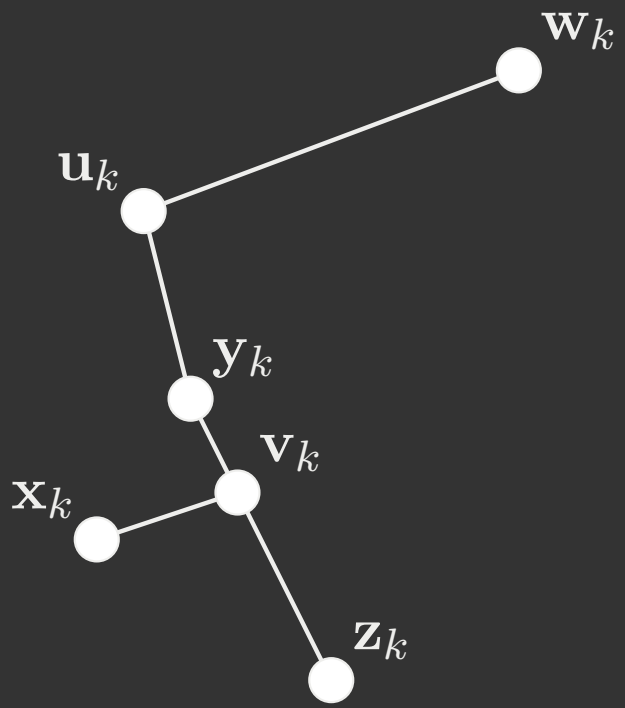

>>> Conclusão

Repetindo o processo k vezes, obtemos

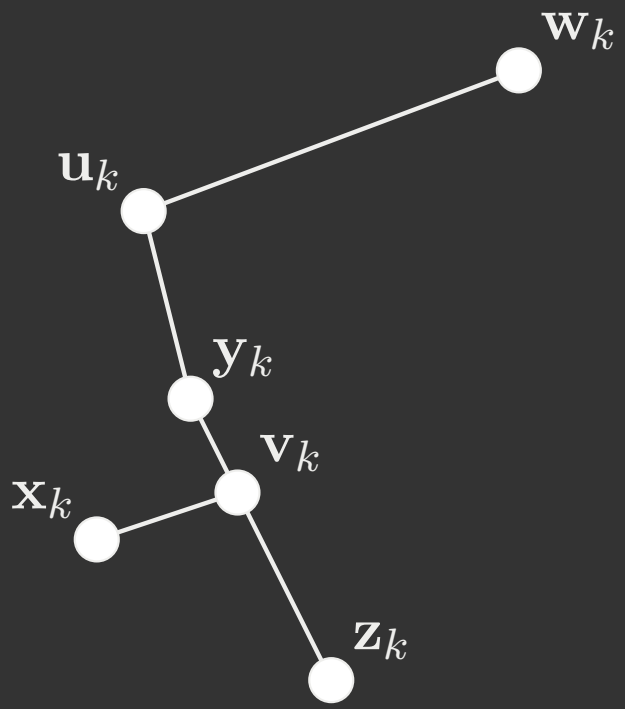

* Todas as listas tem o mesmo tamanho;

>>> Conclusão

Repetindo o processo k vezes, obtemos

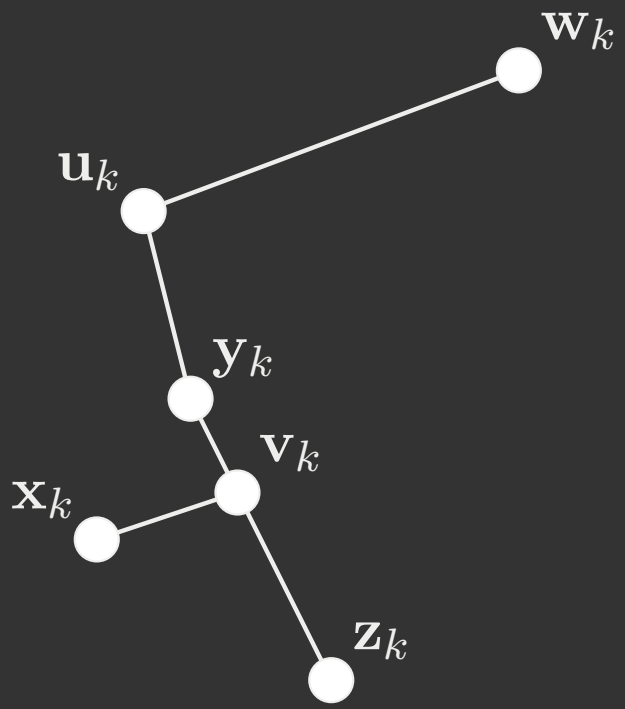

* Todas as listas tem o mesmo tamanho;
* São listas de números;

>>> Conclusão

Repetindo o processo k vezes, obtemos

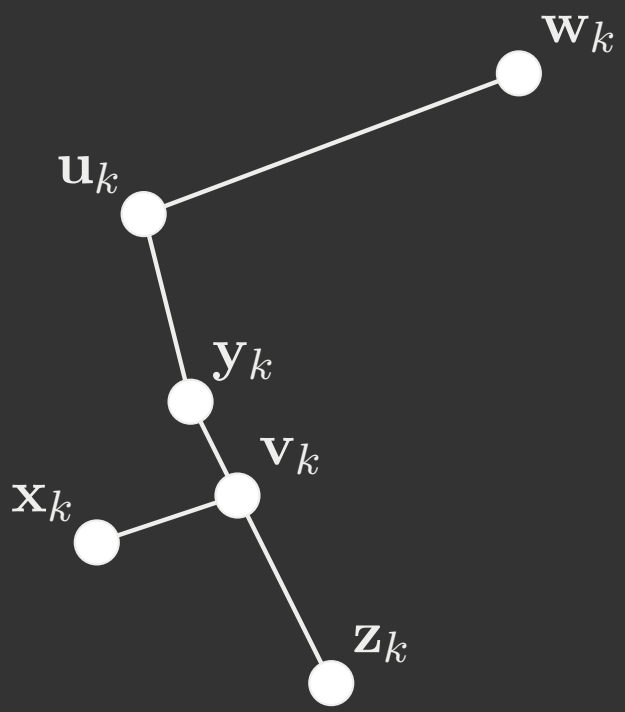

* Todas as listas tem o mesmo tamanho;
* São listas de números;
* Podem ser interpretadas como elementos de algum $\mathbb{R}^d$!

>>> Conclusão

Repetindo o processo k vezes, obtemos

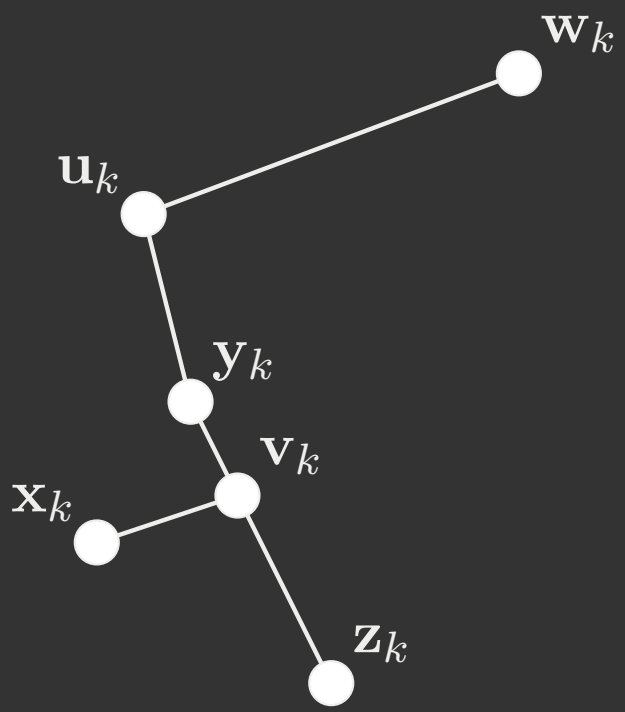

* Todas as listas tem o mesmo tamanho;
* São listas de números;
* Podem ser interpretadas como elementos de algum $\mathbb{R}^d$!
* MERGULHAMOS O GRAFO!!!!!

>>> Aplicações

>>> Aplicações

Com o poder da álgebra linear, podemos:

>>> Aplicações

Com o poder da álgebra linear, podemos:

* Classificar vértices;

>>> Aplicações

Com o poder da álgebra linear, podemos:

* Classificar vértices;
* Novas arestas;

>>> Aplicações

Com o poder da álgebra linear, podemos:

* Classificar vértices;
* Novas arestas;
* Classificar grafos;

>>> Aplicações

Com o poder da álgebra linear, podemos:

* Classificar vértices;
* Novas arestas;
* Classificar grafos;
* Agrupamento.

>>> Referências I

[1] *Graph Neural Networks - a perspective from the ground up - YouTube*. Acessado: 29-09-2023. URL: https://www.youtube.com/watch?v=GXhBEj1ZtE8.

[2] William L. Hamilton. *Graph Representation Learning (Synthesis Lectures on Artificial Intelligence and Machine Learning, 46)*. Morgan & Claypool Publishers, 2020. ISBN: 9781681739649.

[3] *Introduction to Machine Learning | MIT Open Learning Library*. Acessado: 29-09-2023. URL: https://openlearninglibrary.mit.edu/courses/course-v1:MITx+6.036+1T2019/about.

[4] *Learn PyTorch for deep learning in a day. Literally. - YouTube*. Acessado: 29-09-2023. URL: https://www.youtube.com/watch?v=Z_ikDlimN6A&.

>>> Referências II

[5] *Perceptron Learning Algorithm: A Graphical Explanation Of Why It Works | by Akshay L Chandra | Towards Data Science*. Acessado: 25-09-2023. URL: https://towardsdatascience.com/perceptron-learning-algorithm-d5db0deab975.

[6] *Training Deep Neural Networks. Deep Learning Accessories | by Ravindra Parmar | Towards Data Science*. Acessado: 25-09-2023. URL: https://towardsdatascience.com/training-deep-neural-networks-9fdb1964b964.