

# Uczenie maszynowe

*„Inteligencja sztuczna vs prawdziwa”*

Anna Dawid-Łękowska

28.01.2022



Od zawsze  
chcieliśmy  
zbudować  
maszyny,  
które myślą

**„Pigmalion”**

Jean-Baptiste Regnault  
(1786)





Od zawsze  
chcieliśmy  
zbudować  
maszyny,  
które myślą

**„Pigmalion”**

Jean-Baptiste Regnault  
(1786)



# Początki maszyn uczących

1. Podejście oparte na **kodowaniu wiedzy** w językach formalnych  
*szczególnie skuteczne w łańcuchach logicznych  
i obliczeniach matematycznych*

# Początki maszyn uczących

## 1. Podejście oparte na **kodowaniu wiedzy** w językach formalnych

- wydłużony pysk
- mniej wyraźne wąsy
  - okrągłe oczy
  - większa masa
  - ...



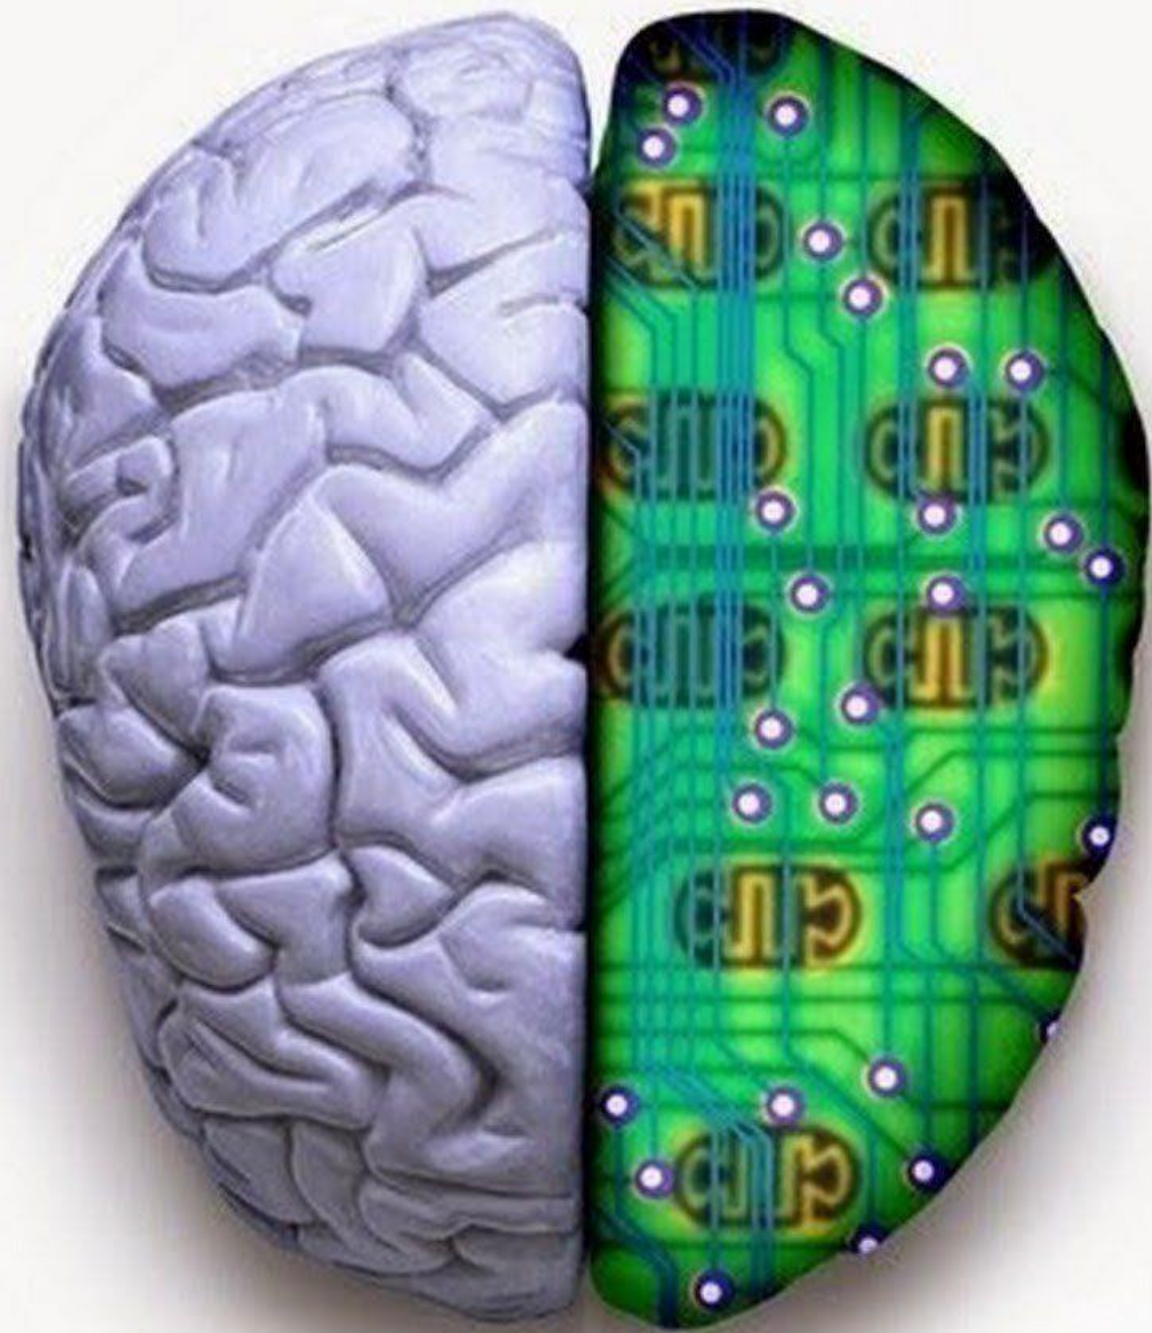
- krótszy pyszczek
- długie wąsy
- migdałowe oczy
- mniejsza masa
- ...



# Paradoks Moraveca

*„Gdy pojawi się nowa generacja inteligentnych urządzeń, to analitycy giełdowi, inżynierowie i ławnicy sądowi mogą zostać zastąpieni maszynami. Ogrodnicy, recepcjoniści i kucharze są w najbliższych dekadach bezpieczni.”*

Steven Pinker



# Początki maszyn uczących

1. Podejście oparte na **kodowaniu wiedzy** w językach formalnych
2. Podejście oparte na wyciąganiu **wzorców z danych**

# Początki maszyn uczących

1. Podejście oparte na **kodowaniu wiedzy** w językach formalnych
2. Podejście oparte na wyciąganiu **wzorców z danych**

to jest **PIES**



to jest **KOT**

**wymyśl jak je  
rozróżnić!**



# Czym jest uczenie maszynowe? (ML)



- Rozwiązują problemy **bez zaprogramowania** jak *dokładnie* ten problem rozwiązać
- Ich skuteczność **rośnie wraz z dostępem do danych** („nauka przez doświadczenie”)

# Typy uczenia maszynowego



**Z nadzorem** – maszyna uczy się na parach wejście-wyjście



**Bez nadzoru** – maszyna grupuje i analizuje jedynie dane wejściowe



**Ze wzmocnieniem** – maszyna uczy się przez reakcje na środowisko

# Nadzorowane uczenie maszynowe


1

## Trening maszyny


Wejście-wyjście:  
dane-etykiety

 jabłko  banan

Trening: minimalizacja  
błędu przez zmiany  $w$

decyzja:  banan błąd ↑  
decyzja:  jabłko błąd ↓

Parametry  $w$  które  
minimalizują błąd =  
gotowa maszyna

decyzja:  banan  
decyzja:  jabłko


2

## Testowanie maszyny

Wejście: nowa dana



Analiza danej przez  
maszynę


Maszyna( $w^*$   )

Decyzja maszyny:  
etykieta

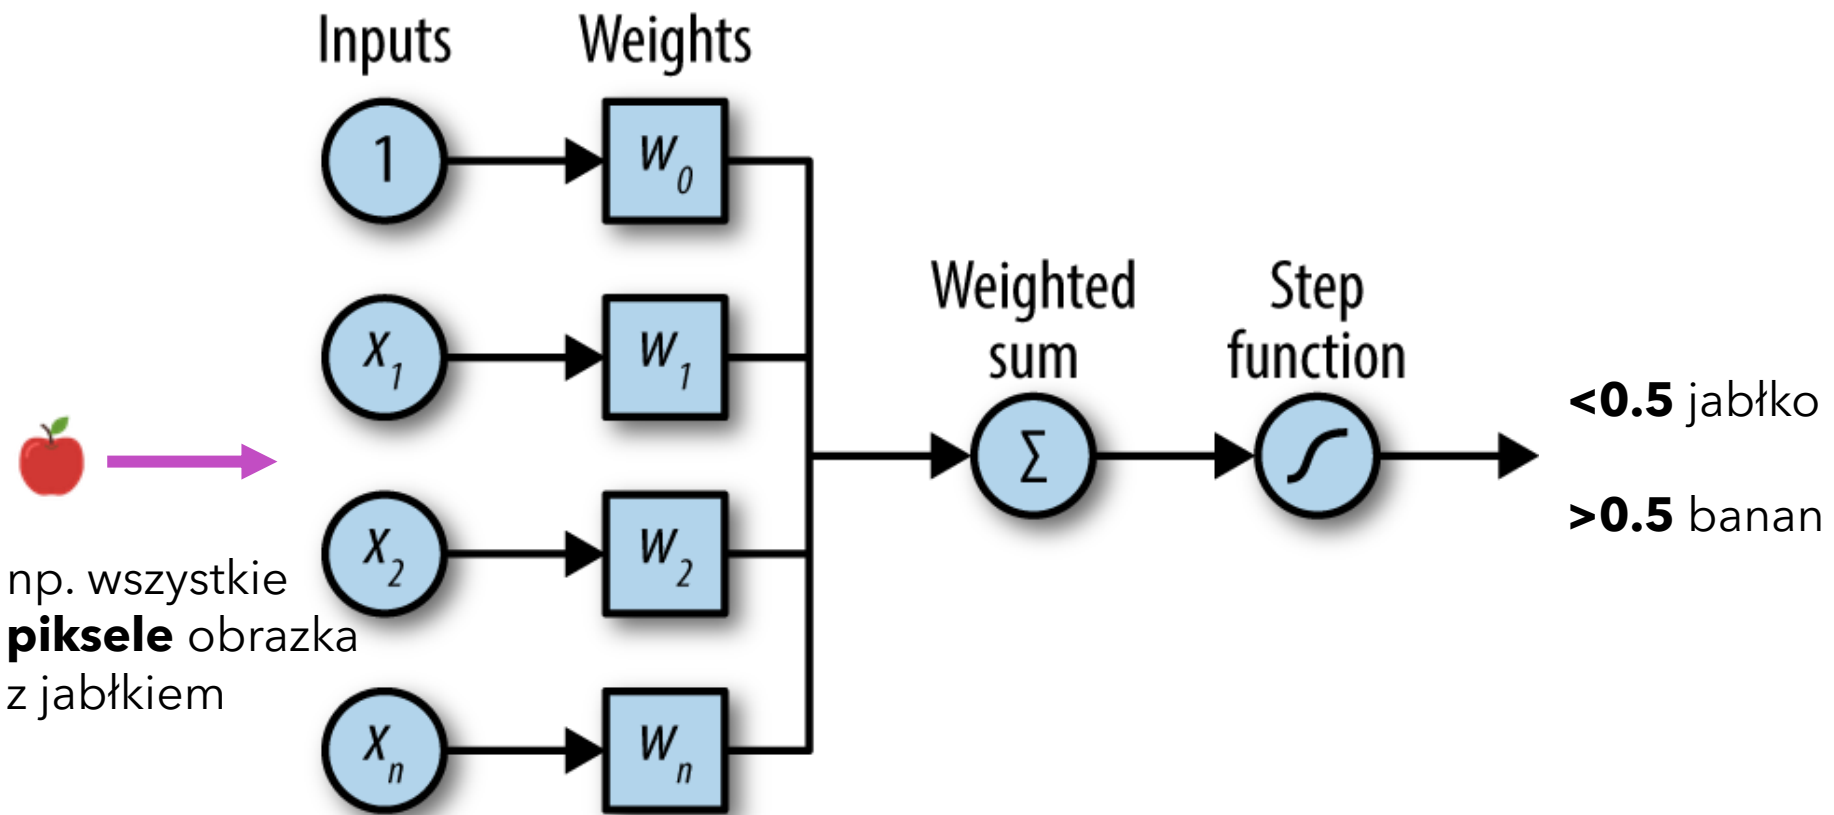
**banan**  
pewność: 80%



# Sztuczny neuron



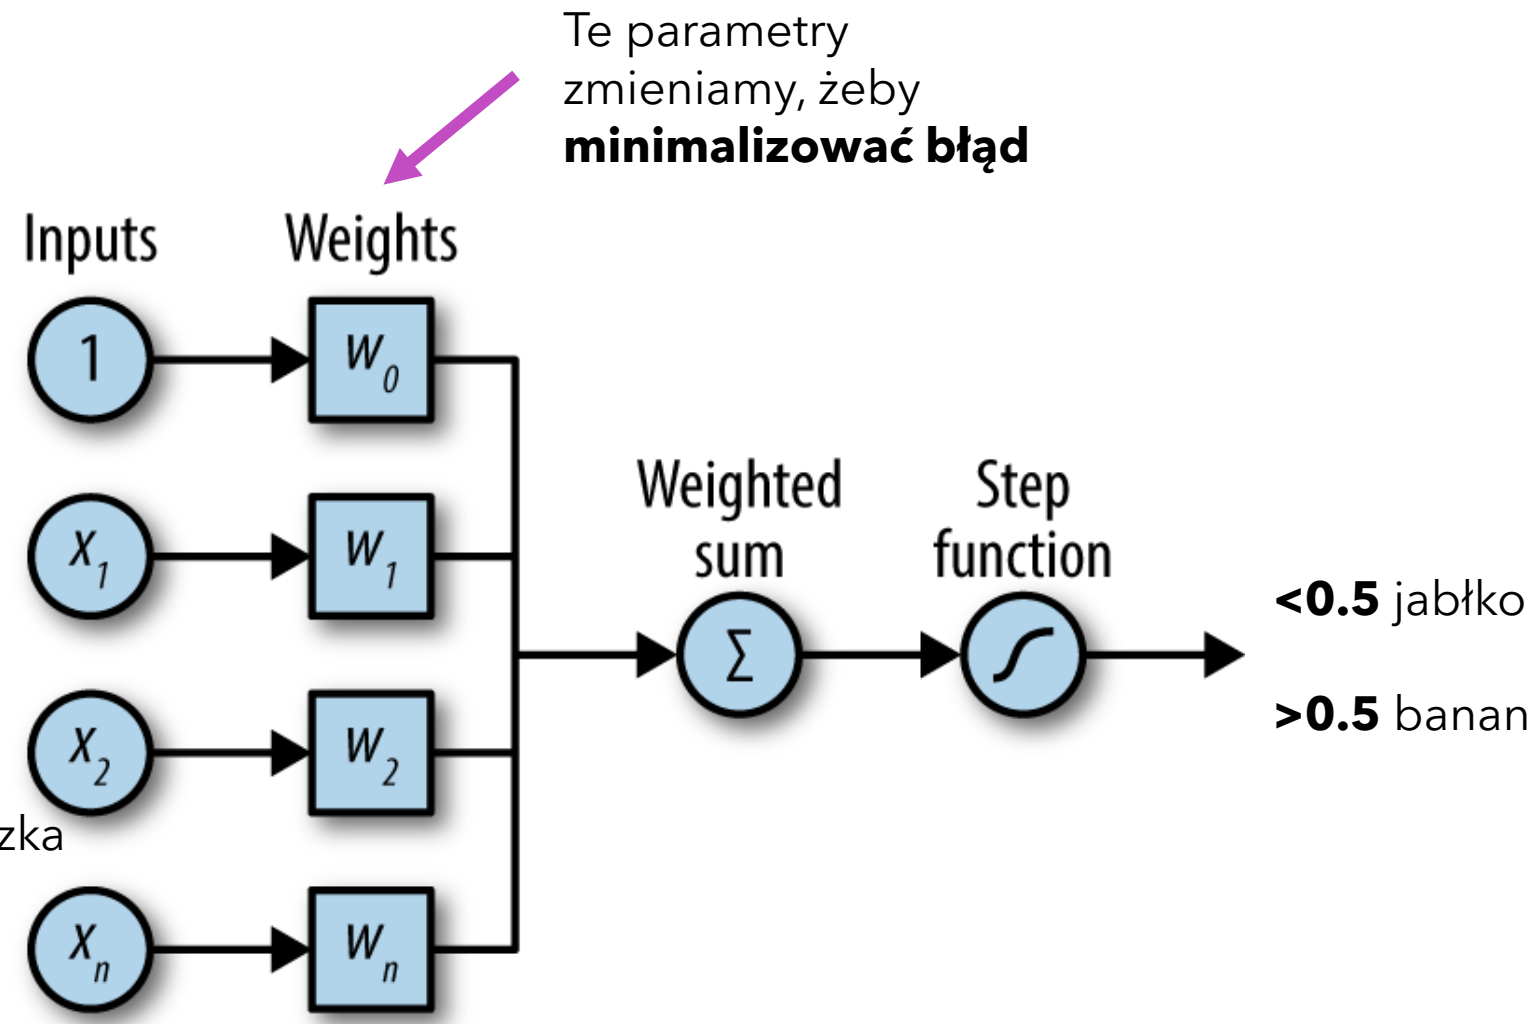
# Sztuczny neuron



# Sztuczny neuron



np. wszystkie **piksele** obrazka z jabłkiem

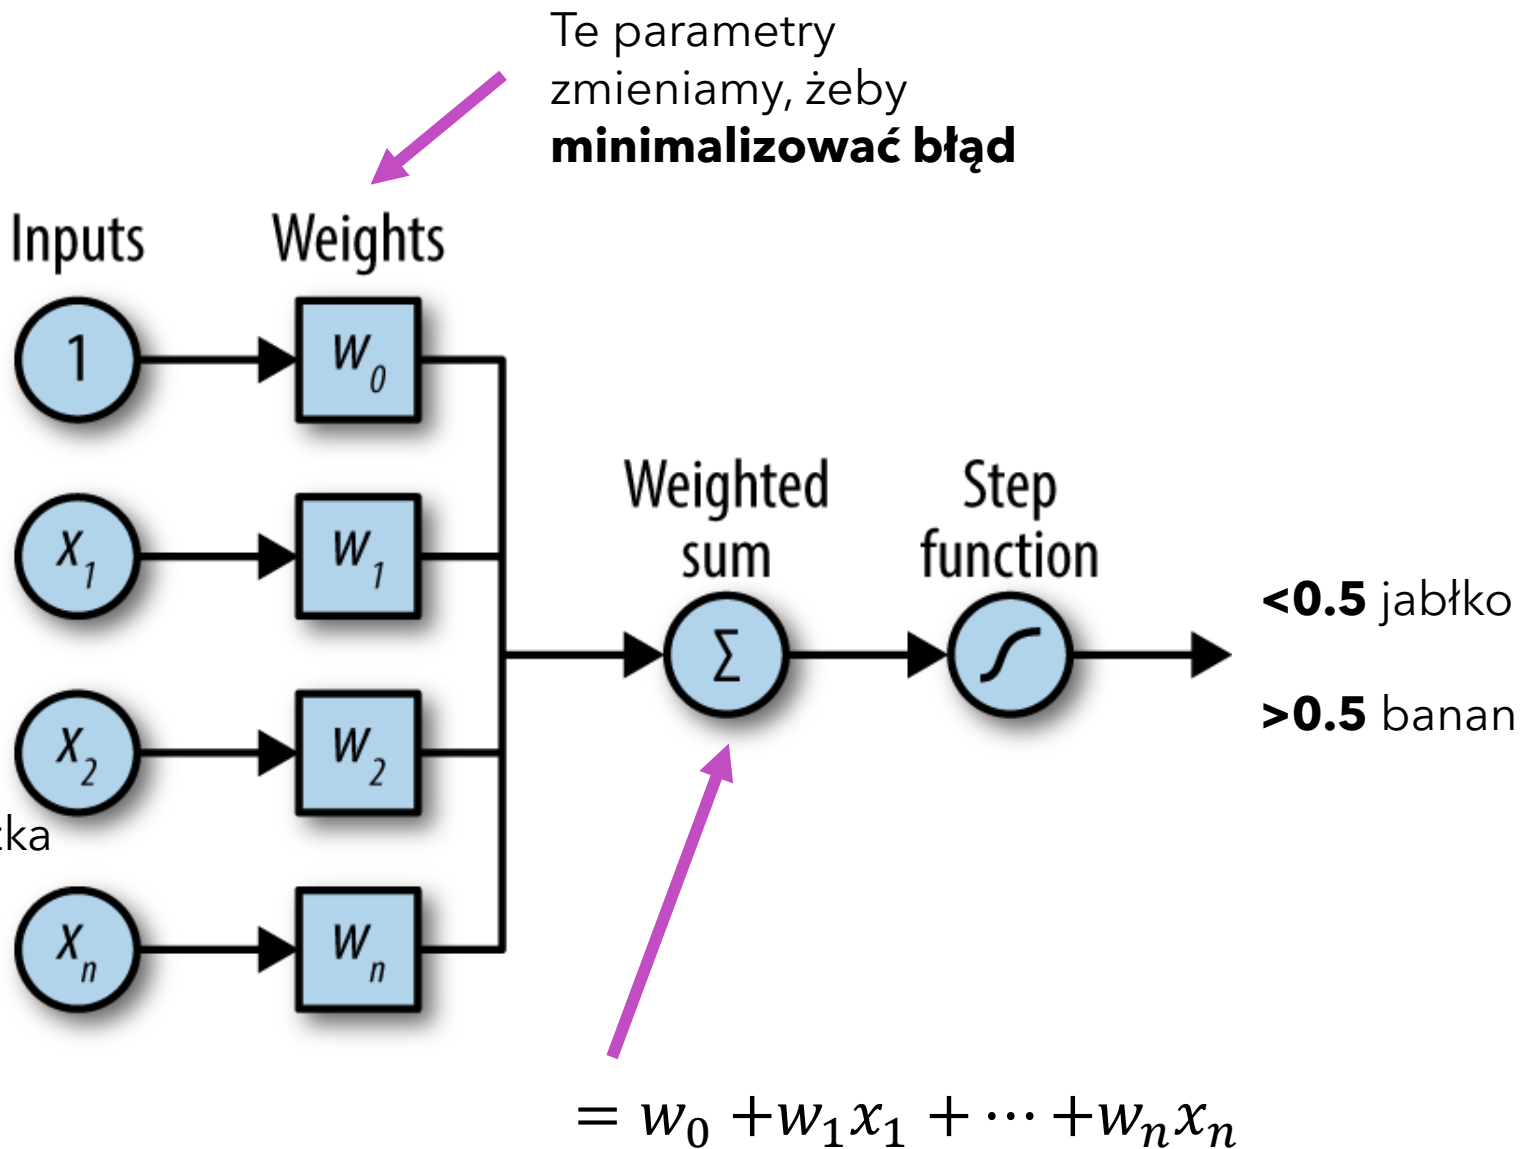




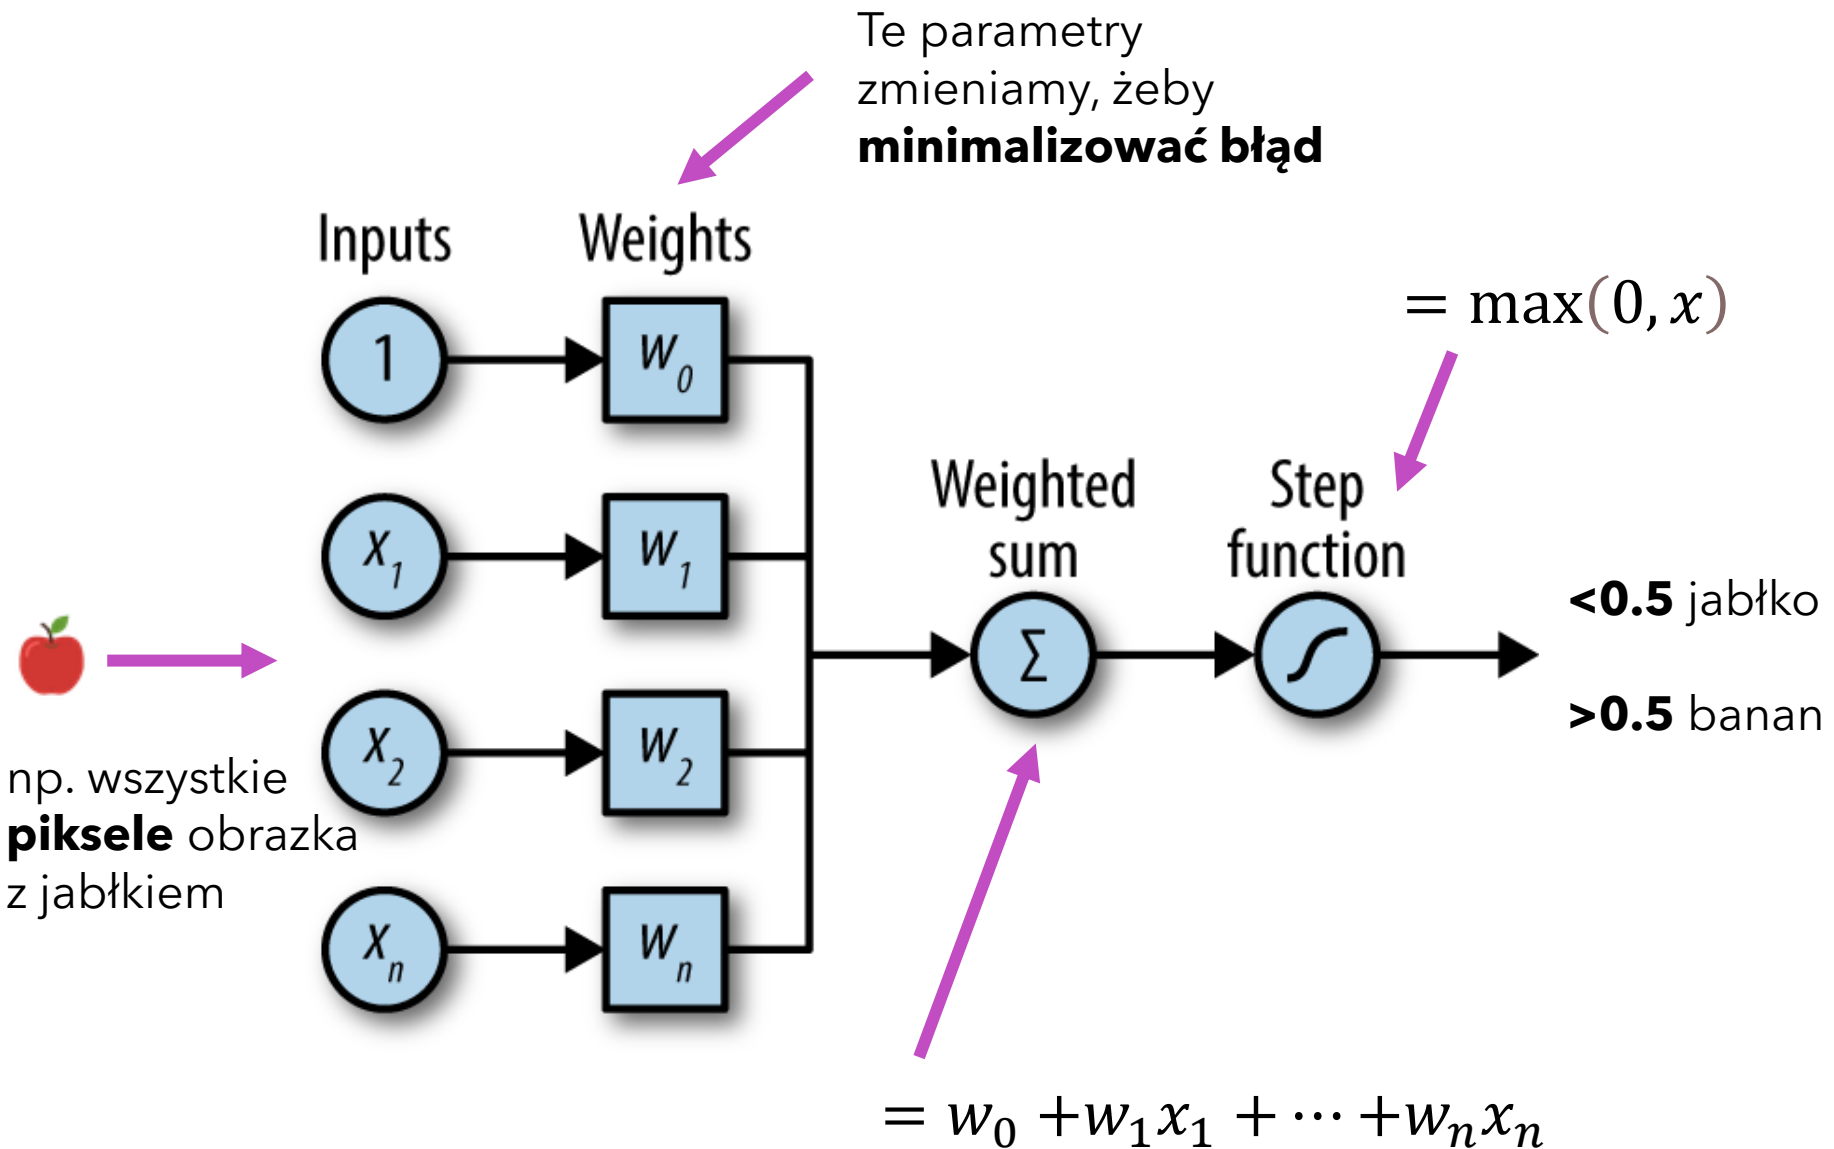
# Sztuczny neuron



np. wszystkie **piksele** obrazka z jabłkiem





# Sztuczny neuron



Neurony  
można  
łączyć w  
warstwy



*głębokie  
uczenie  
maszynowe*





Neurony  
można  
łączyć w  
warstwy

*głębokie*  
*uczenie*  
*maszynowe*



**Głębokie sieci  
neuronowe  
budują  
bardziej złożone  
koncepty  
z prostszych**

# ML jest wokół nas!



Rozpoznawanie obrazków



Przewidywanie pogody



Diagnoza medyczna



Wyszukiwarka Google'a



SI pokonuje mistrzów w gry

# 'AI IS THE NEW ELECTRICITY'



“Just as electricity transformed almost everything 100 years ago, today I actually have a hard time thinking of an industry that I don’t think AI will transform in the next several years.”

**Andrew Ng**

Former chief scientist at Baidu, Co-founder at Coursera



The image features a dense, intricate network of glowing blue lines and nodes, resembling a data network or a complex system. The lines are of varying thickness and brightness, with some nodes appearing as bright white or yellow spheres. The background is a dark, blurred cityscape at night, with lights from buildings and streets visible. The overall color palette is dominated by deep blues and blacks, with the glowing elements providing a stark contrast.

Wszystko  
dobrze?




Co widzą ludzie:



autobus szkolny

+



szum

(przeskalowany dla wizualizacji)

=




autobus szkolny

Co widzą (niektóre)  
maszyny:



autobus szkolny

+



szum

(przeskalowany dla wizualizacji)

=



struś



Co widzą ludzie:



autobus szkolny

Co widzą (niektóre)  
maszyny:



autobus szkolny



szum  
(przeskalowany dla wizualizacji)



struś

Co widzą ludzie:



autobus szkolny

Co widzą (niektóre)  
maszyny:



autobus szkolny



szum  
(przeskalowany dla wizualizacji)




struś






Klasyfikator husky vs wilk








Klasyfikator nauczył się  
**tła...**







Klasyfikator nauczy się  
na  
**Może uczyć się  
nieistotnych  
korelacji!**





## SI Amazona odziedziczyła uprzedzenia z historycznych decyzji rekrutacyjnych



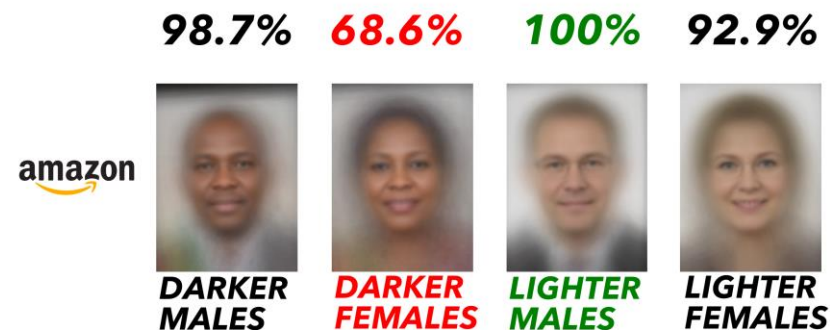
<https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scrap-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G>

## TayTweets, chatbot Microsoftu uczony na danych z Twittera stał się rasistą



<https://towardsdatascience.com/biases-in-machine-learning-61186da78591>

## Amazon Rekognition gorzej rozpoznaje kobiety i osoby o ciemniejszej skórze



<https://medium.com/@Joy.Buolamwini/response-racial-and-gender-bias-in-amazon-rekognition-commercial-ai-system-for-analyzing-faces-a289222eeced>

SI Amazona odziedziczyła uprzedzenia z historycznych decyzji rekrutacyjnych



<https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scrap-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G>


TayTweets, chatbot Microsoftu uczony na danych z Twittera stał się rasistą



<https://towardsdatascience.com/biases-in-machine-learning-61186da78591>

Niesprawiedliwa!

Amazon Rekognition gorzej rozpoznaje kobiety i osoby o ciemniejszej skórze



<https://medium.com/@Joy.Buolamwini/response-racial-and-gender-bias-in-amazon-rekognition-commercial-ai-system-for-analyzing-faces-a289222eeced>

*Ludzie martwią się, że komputery  
staną się zbyt inteligentne  
i przejmą władzę nad światem,  
ale prawdziwym problemem jest  
to, że są zbyt głupie  
i już przejęły władzę nad światem.*

Pedro Domingos  
„The Master Algorithm”







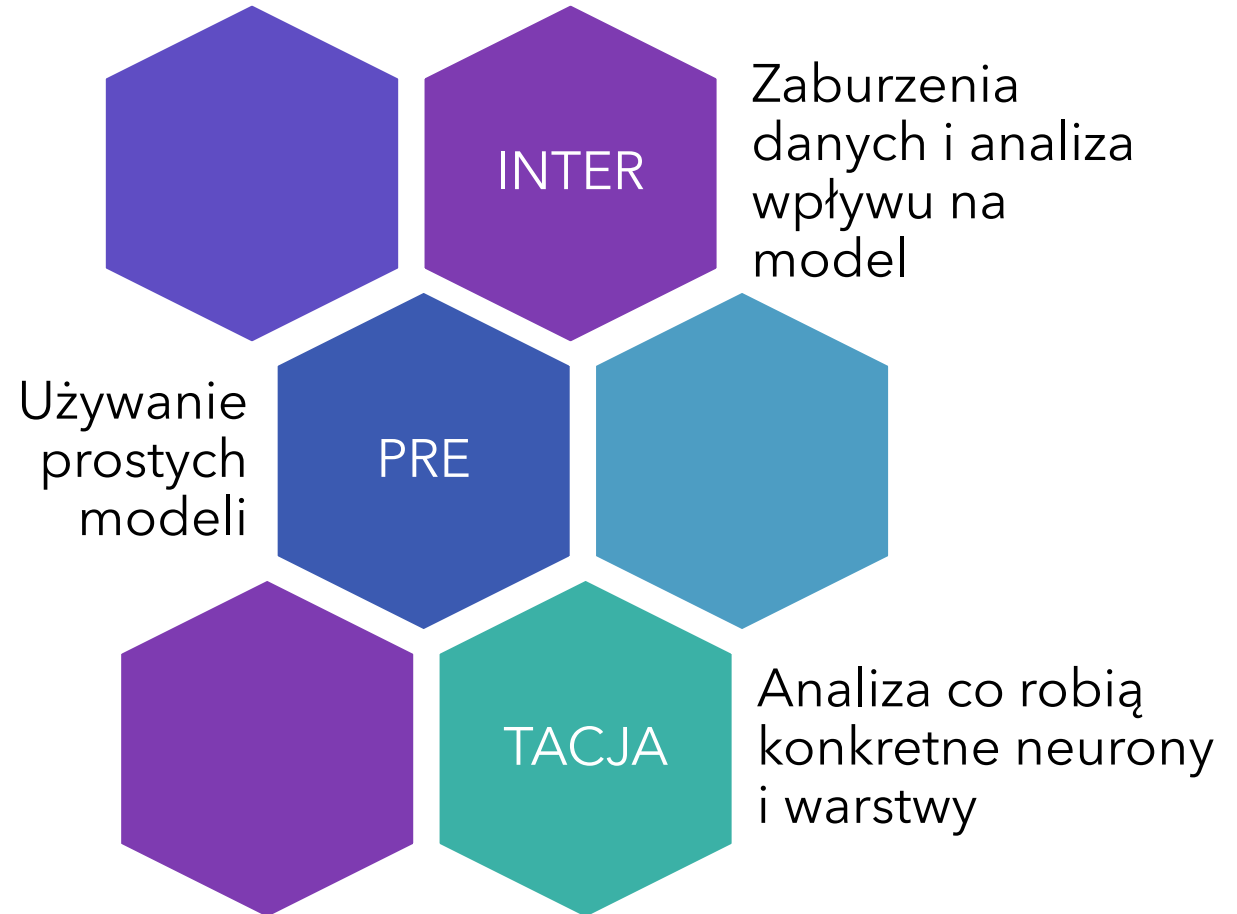
Wszystko  
dobrze?

Nie.

Potrzebujemy  
interpretowalności.



# Sposoby interpretacji






„... tnących drzewo?”



„Czemu myślę, że ten obrazek przedstawia wilka?”



„Czemu myślę, że ten obrazek przedstawia ludzi myjących zęby?”



Dzięki za uwagę!

