

# Algorytmy numeryczne znajdujące minimum lokalne zadanej funkcji celu

dr hab. inż. Piotr Gawron

Instytut Informatyki Teoretycznej i Stosowanej Polskiej Akademii Nauk

11 stycznia 2025



# ✦ Motywacja

- ▶ Bardzo wiele zadań w technice da się wyrazić w postaci problemu optymalizacyjnego.
- ▶ W uczeniu maszynowym często mówimy o funkcji straty (ang. Loss function)

$$f(\theta, \mathbf{X} \times \mathbf{Y}),$$

zależnej od pewnego **zbioru parametrów**  $\theta$  i od pewnego **zbioru danych**  $\mathbf{X} \times \mathbf{Y}$ .

- ▶ Takimi funkcjami opisane są np. sieci neuronowe.
- ▶ Uczenie sieci neuronowej polega na znalezieniu takich wartości parametrów  $\theta$ , które dla zbioru uczącego  $\mathbf{X} \times \mathbf{Y}$  „minimalizują”<sup>1</sup> funkcję straty.

---

<sup>1</sup>W sensie lokalnego minimum.



## ❖ Motywacja

- ▶ Weźmy np. problem klasyfikacji binarnej
  - ▶ Dane uczące składają się z wektorów cech i etykiet<sup>2</sup>:

$$\mathbf{X} \times \mathbf{Y} = \{(X_1, y_1), (X_2, y_2), \dots, (X_N, y_N)\}$$

- ▶ Funkcja klasyfikująca przyporządkowuje wektorowi cech etykietę:

$$f_{\text{cls}} : \mathbf{X} \ni X \mapsto y \in \mathbf{Y}$$

- ▶ W procesie uczenia wykorzystamy funkcję straty:

$$l(y, \hat{y}) = (y - \hat{y})^2,$$

gdzie  $\hat{y} = f_{\text{cls}}(X)$ .

---

<sup>2</sup>Dla uproszczenia nie dzielimy zbioru danych na zbiory uczący i testujący.



# Metoda spadku wzdłuż gradientu



## ❖ Funkcja straty dla zbioru uczącego

- ▶ Funkcja straty  $l(\theta, y, \hat{y}) = (y - \hat{y})^2$ , jest zależna od parametrów  $\theta$ , gdyż  $\hat{y} = f_{\text{cls}}(\theta, X)$ .
- ▶ Możemy uogólnić funkcję straty tak, by brała wartości z całego zbioru  $\mathcal{X} \times \mathcal{Y}$  na raz:

$$L(\theta, \mathbf{X}, \mathbf{y}) = \sum_{i=1}^N (y_i - f_{\text{cls}}(\theta, X_i))^2.$$

- ▶ Ponieważ zbiór  $\mathcal{X} \times \mathcal{Y}$  jest ustalony, to funkcję  $L$  można zapisać jako  $L(\theta)$ .



## Optymalizacja funkcji straty

- ▶ Proces uczenia modelu (np. sieci neuronowej) polega na procesie minimalizacji funkcji straty  $L(\theta)$ .
- ▶ Minimalizację funkcji  $L$  można dokonać iteracyjnie metodą spadku wzdłuż gradientu  $\nabla_{\theta}L(\theta)$ .



## ❖ Algorytm minimalizacji zgodnie z metodą spadku wzdłuż gradientu

Wybierz  $\theta_{\text{init}}$

$\theta_0 \leftarrow \theta_{\text{init}}$

**for**  $k \in \{1, 2, \dots, K\}$  **do**

$g_k \leftarrow \nabla_{\theta_{k-1}} L(\theta_{k-1})$

$\theta_k \leftarrow \theta_{k-1} - \gamma_k g_k$

**end for**

▷ np. (pseudo-)losowo z ustalonego rozkładu

▷ Policz kierunek największego spadku

▷ Zrób krok w dół o długości  $\gamma_k$

### Przypomnienie

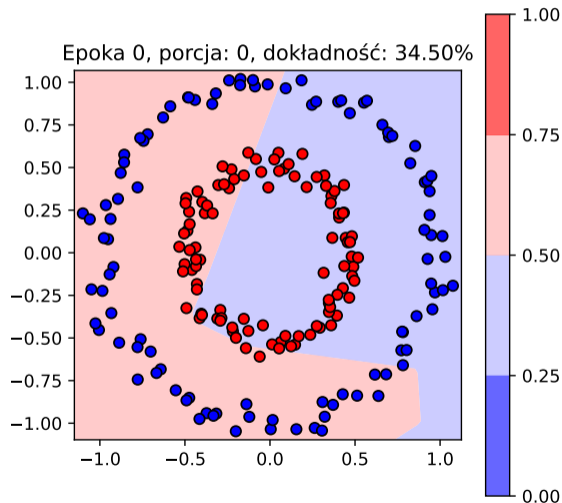
$$L(\theta) = L(\theta, \mathbf{X}, \mathbf{y}) = \sum_{i=1}^N (y_i - f_{\text{cls}}(\theta, X_i))^2$$



# Przykład 1

## Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.






# Przykład 1

## Uczenie klasyfikatora


- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



# Przykład 1

## Uczenie klasyfikatora


- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



# Przykład 1

## Uczenie klasyfikatora


- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



# Przykład 1

## Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



## Przykład 2

### Przybliżenie funkcji sin wielomianem trzeciego stopnia

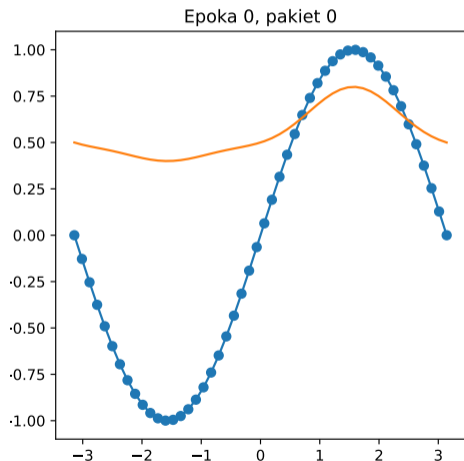
- ▶ Funkcja straty:

$$L(\theta) = \sum_i (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



## Przykład 2

### Przybliżenie funkcji sin wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$L(\theta) = \sum_i (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



## Przykład 2

### Przybliżenie funkcji sin wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$L(\theta) = \sum_i (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.



## Przykład 2

### Przybliżenie funkcji sin wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$L(\theta) = \sum_i (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji wszystkie dostępne punkty jednocześnie.





# Metoda stochastycznego spadku wzdłuż gradientu



## Iteracja, porcja, epoka

Uczenie modeli jest zazwyczaj realizowane iteracyjnie.

- ▶ **Iteracją** nazywamy pojedynczy krok algorytmu optymalizacyjnego.
- ▶ **Porcją** (ang. batch) nazywamy podzbiór danych przetwarzany w jednej iteracji.
- ▶ **Epoka** to zbiór iteracji, podczas wykonywania którego wykorzystano wszystkie dane uczące dokładnie raz.



## Metoda stochastycznego spadku wzdłuż gradientu

- ▶ Tym razem zbiór danych tasujemy tzn. ustawiamy w przypadkowej kolejności,
- ▶ i będziemy liczyć gradient  $l(\theta, y, \hat{y}) = (y - \hat{y})^2$  z  $\hat{y} = f_{\text{cls}}(\theta, X)$  dla każdego punktu osobno.

$(X_i, y_i) \leftarrow (X_{\sigma(i)}, y_{\sigma(i)})$  dla każdego  $i$

Wybierz  $\theta_{\text{init}}$

$\theta_0 \leftarrow \theta_{\text{init}}$

**for**  $k \in \{1, 2, \dots, K\}$  **do**

**for**  $i \in \{1, 2, \dots, N\}$  **do**

$g_{(k,i)} \leftarrow \nabla_{\theta_{(k,i)-1}} l(\theta_{(k,i)-1})$

$\theta_{(k,i)} \leftarrow \theta_{(k,i)-1} - \gamma_k g_{(k,i)}$

**end for**

**end for**

▷ Tasowanie permutacją  $\sigma$

▷ np. (pseudo-)losowo z ustalonego rozkładu

▷ Dla każdej epoki

▷ Dla każdego punktu

▷ Policz kierunek największego spadku

▷ Zrób krok w dół o długości  $\gamma_k$



## Przykład 2

### Optymalizacja stochastyczna

#### Przybliżenie funkcji sin wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji tylko jeden punkt.



## Przykład 2

### Optymalizacja stochastyczna

#### Przybliżenie funkcji sin wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji tylko jeden punkt.



## Przykład 2

### Optymalizacja stochastyczna

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji tylko jeden punkt.



## Przykład 2

### Optymalizacja stochastyczna

#### Przybliżenie funkcji sin wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji tylko jeden punkt.



## Przykład 2

### Optymalizacja stochastyczna

#### Przybliżenie funkcji sin wielomianem trzeciego stopnia

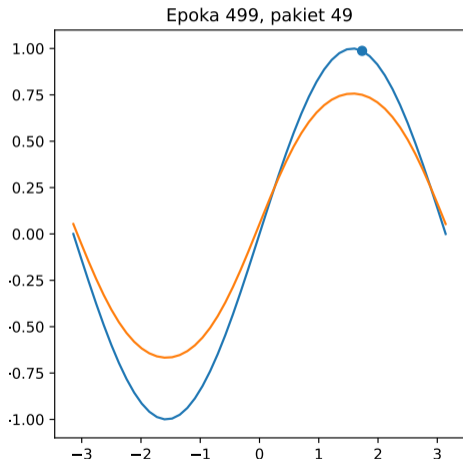
- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji tylko jeden punkt.





## Przykład 2

### Optymalizacja stochastyczna

#### Przybliżenie funkcji sin wielomianem trzeciego stopnia

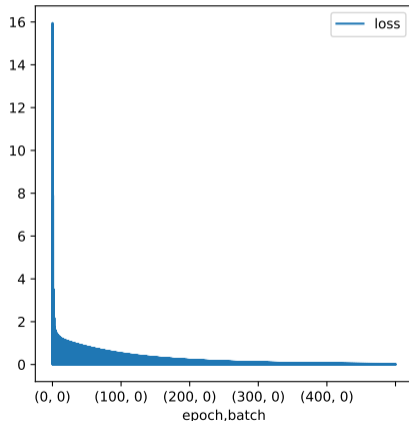
- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji tylko jeden punkt.



# Praktyka — uczenie porcjami



## ❖ Funkcja straty dla porcji próbek

- ▶ Tym razem tasujemy i dzielimy zbiór danych na porcje (ang. batches):
- ▶  $(X, y)_b = \{(X_1, y_1)_b, \dots, (X_{B_b}, y_{B_b})_b\}$  oraz  $\bigcup_{b=1}^B (X, y)_b = \mathcal{X} \times \mathcal{Y}$ .
- ▶ Zatem naszą funkcją straty będzie:

$$L(\theta) = L(\theta, \mathbf{X}_b, \mathbf{y}_b) = \sum_i (y_{b,i} - f_{\text{cls}}(\theta, X_{b,i}))^2,$$

ale będzie ona liczona dla każdej porcji.



## Algoritm minimalizacji zgodnie z metodą spadku wzdłuż gradientu wykorzystujący porcje

Wybierz  $\theta_{\text{init}}$

$\theta_0 \leftarrow \theta_{\text{init}}$

**for**  $k \in \{1, 2, \dots, K\}$  **do**

**for**  $b \in \{1, 2, \dots, B\}$  **do**

$g^{(k,b)} = \nabla_{\theta_{(k,b)-1}} L(\theta_{(k,b)-1})$

$\theta_{(k,b)} \leftarrow \theta_{(k,b)-1} - \gamma_k g^{(k,b)}$

**end for**

**end for**

▷ np. (pseudo-)losowo z ustalonego rozkładu

▷ Dla każdej epoki

▷ Dla każdej porcji

▷ Kierunek największego spadku

▷ Zrób krok w dół o długości  $\gamma_k$




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.






# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.

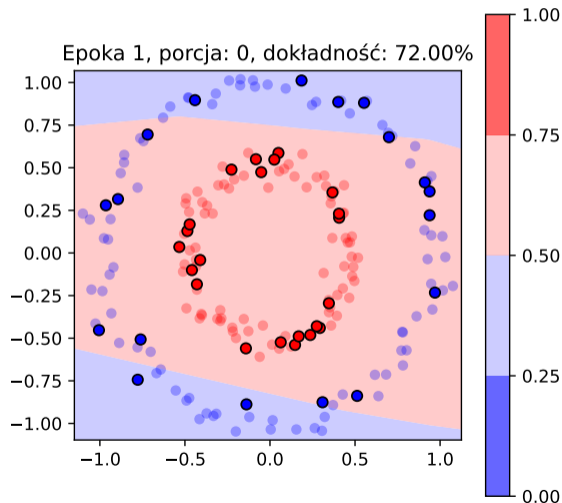


# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.




# Przykład 1

## Optymalizacja porcjami

### Uczenie klasyfikatora

- ▶ Klasyfikacja binarna z wykorzystaniem perceptronu.
- ▶ Problem klasyfikacji zbioru nieseparowalnego liniowo.
- ▶ Sieć neuronowa dwuwarstwowa.
- ▶ Parametry  $\theta$  to wagi sieci neuronowej.
- ▶ Wykorzystujemy do optymalizacji porcje 40 punktów z 200.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.





## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia

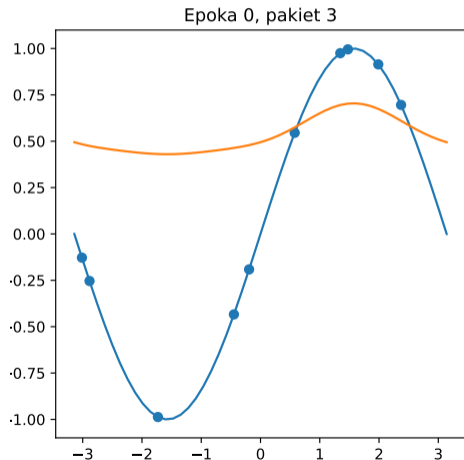
- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia

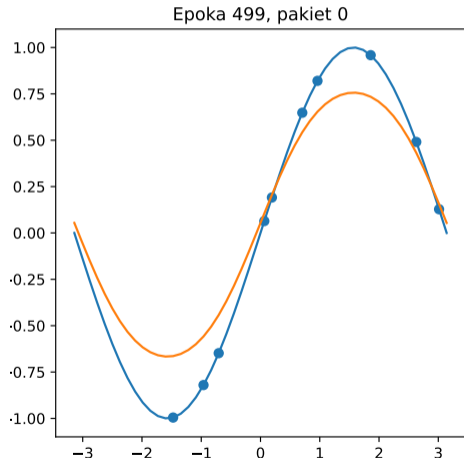
- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.





## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2x + \theta_3x^2 + \theta_4x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Przykład 2

### Optymalizacja porcjami

#### Przybliżenie funkcji $\sin$ wielomianem trzeciego stopnia


- ▶ Funkcja straty:

$$l(\theta) = (\sin(X_i) - w(X_i))^2.$$

- ▶ Wielomian:

$$w(x) = \theta_1 + \theta_2 x + \theta_3 x^2 + \theta_4 x^3.$$

- ▶ Wykorzystujemy do optymalizacji porcję 10 punktów z 50.



## Podsumowanie

- ▶ Optymalizacja (uczenie) porcjami jest często wykorzystywane w praktyce.
- ▶ Pozwala na umieszczenie w pamięci GPGPU modelu i części danych jednocześnie.
- ▶ Wykorzystuje architekturę wektorową procesorów GPGPU.
- ▶ Pozwala również wyskoczyć z lokalnego minimum podczas optymalizacji.

