




# Politechnika Wroclawska

## Identyfikacja



Wojciech Myszka  
Maj 2015



# Wstęp

## Rozglądamy się



Ten prostokąt („black box”) nazywać będziemy **Obiektem** (identyfikacji).



# Co można z tym zrobić?

## Narysować?





# Co można z tym zrobić?

Narysować?



Ten drugi prostokąt to **Model** na różnych stadiach modelowania.

Naszym dążeniem jest aby **Model** był jak najbardziej podobny do **Obiektu**.

# Co jeszcze można?

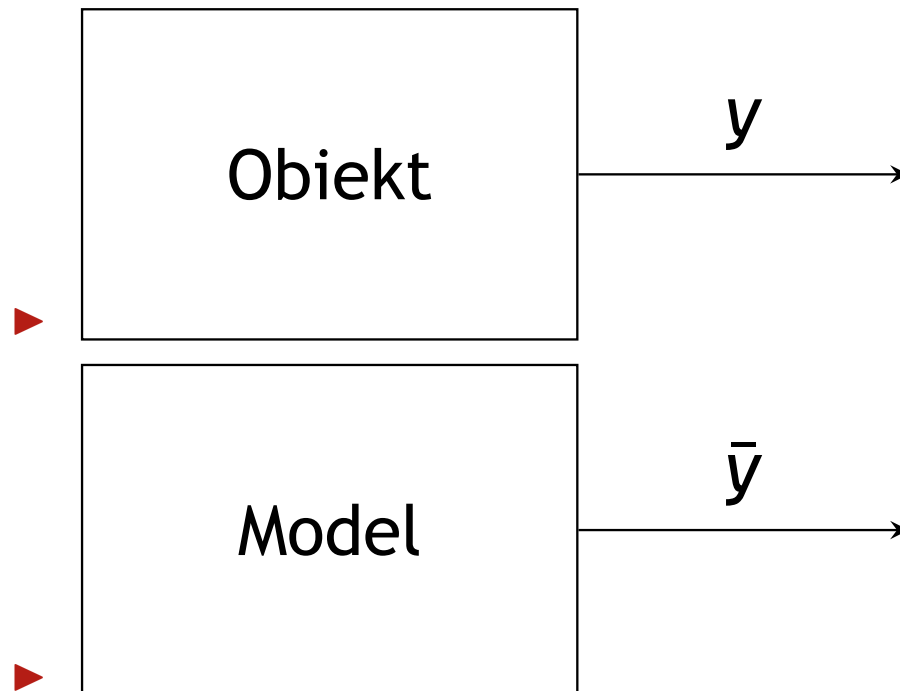
- ▶ Gdy zależy nam na czymś innym niż **wygląd** musimy zmienić zestaw interesujących nas cech charakterystycznych.
- ▶ Wyszczególniamy pewne cech, które będziemy obserwować. Bardzo często nazywa się je **Wyjściem Obiektu**.
- ▶ Obiekt nasz wygląda tak:



- ▶  $y$  to **wyjście** Obiektu.

# Porównanie Obiektu i Modelu

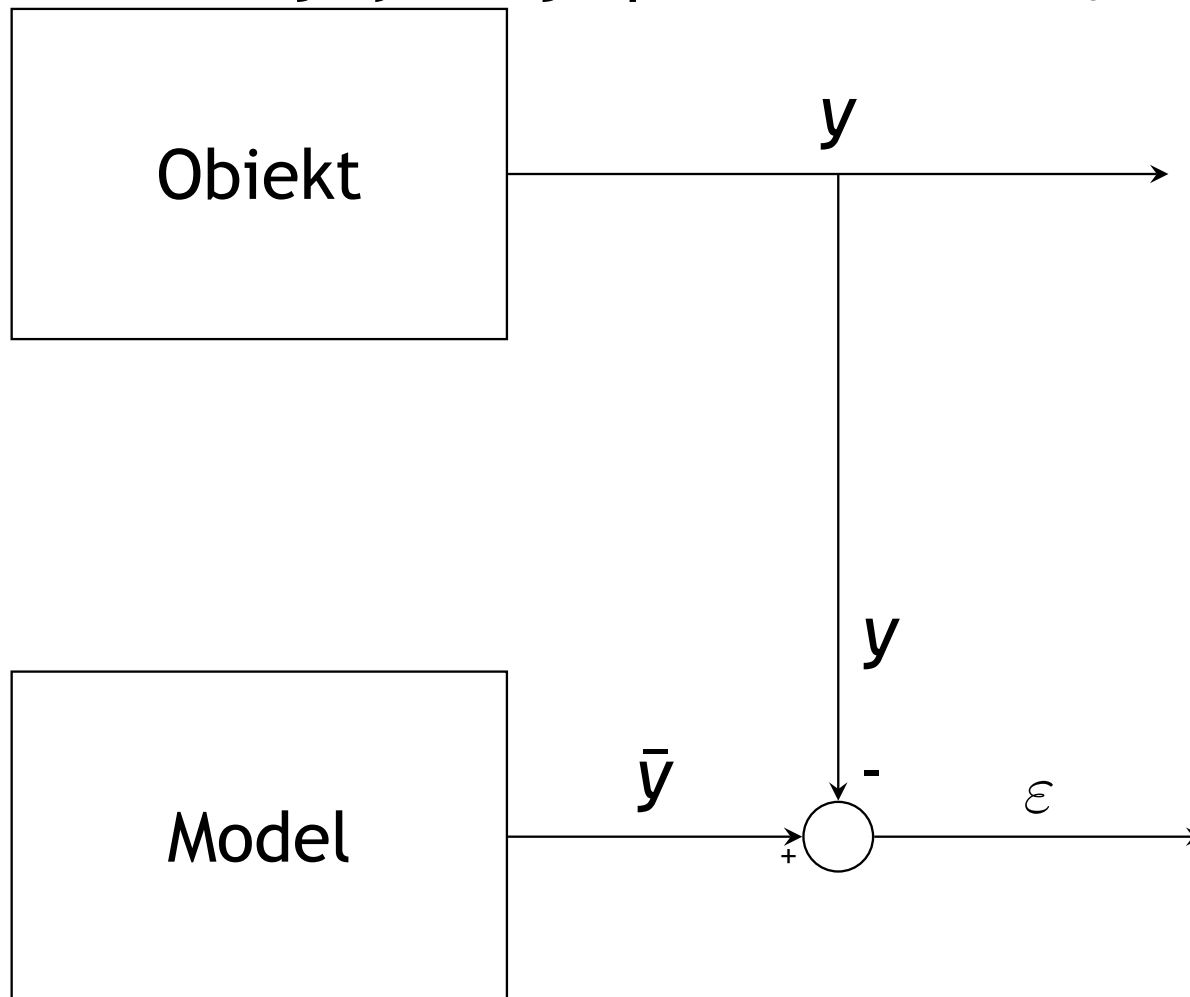
- ▶ Aby uzyskać zgodność Obiektu z Modelem, model również musi być wyposażony w wyjście.



- ▶ Wyjście modelu to  $\bar{y}$ .

# Porównanie obiektu i modelu

Dokładniej sytuacja przedstawia się tak:





# Model

Kilka najprostszych sytuacji:

1. O zmiennej  $y$  nie potrafimy nic powiedzieć. . .
2. Trudno cokolwiek wnioskować o modelu.
3. Możemy założyć, że  $y$  jest realizacją zmiennej losowej. . .
4. Zatem możemy badać pewne statystyczne charakterystyki:
  - ▶ średnią,
  - ▶ wariancję,
  - ▶ momenty,
  - ▶ rozkład prawdopodobieństwa
  - ▶ . . .

i w ten sposób opisać Obiekt





# Charakterystyki statystyczne

1. Losowy charakter zmiennej  $y$  to bardzo silne założenie. Oprócz zmiennych losowych, możemy również rozpatrywać:
  - ▶ zmienne deterministyczne (zawsze zachowują się tak samo),
  - ▶ zmienne niedeterministyczne i nielosowe (zmieniają się w sposób nie dający się opisać za pomocą gęstości).
2. Jeszcze gorzej jest gdy charakterystyki zmieniają się w czasie. . .
3. . . . albo obiekt nie spełnia założenia ergodyczności (uśrednianie po realizacjach może być zastąpione uśrednianiem po czasie).



# Parametry statystyczne

Założmy, że  $y_i, i = 1, 2, \dots, N$ , to kolejne realizacje zmiennej losowej  $Y$ .

Zazwyczaj korzystamy z następujących estymatorów podstawowych parametrów statystycznych:

- ▶ Średnia  $m_y$ :

$$m_y = \frac{1}{N} \sum_{i=1}^N y_i$$

- ▶ Wariancja

$$s_y^2 = \frac{1}{N} \sum_{i=1}^N (y_i - m_y)^2 \text{ a czasami } s_y^2 = \frac{1}{N-1} \sum_{i=1}^N (y_i - m_y)^2$$




# Gęstość

Następnym krokiem może być powiedzenie czegoś o funkcji gęstości.

# Gęstość

Procedura aproksymacji funkcji gęstość przez całe lata była taka:


- ▶ Na podstawie obserwacji ( $y_i$ ) przygotowywano histogram (oraz szacowano podstawowe parametry: wartość średnia, dyspersja, . . . )



# Gęstość

Procedura aproksymacji funkcji gęstość przez całe lata była taka:


- ▶ Następnie dopasowywano funkcję gęstości



# Gęstość

Procedura aproksymacji funkcji gęstość przez całe lata była taka:

- ▶ Następnie dopasowywano funkcję gęstości



- ▶ i przeprowadzano testy statystyczne



# Gęstość – estymacja nieparametryczna

1. Obserwując sposób tworzenia histogramu, ktoś wpadł na prosty pomysł:
2. Gdy  $y_1, y_2, \dots, y_n$  to próbka niezależnych realizacji zmiennej losowej  $Y$  o nieznannej funkcji gęstości  $f$ ,
3. Estymatorem funkcji gęstości będzie:


$$\hat{f}_h(x) = \frac{1}{n} \sum_{i=1}^n K_h(x - y_i) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - y_i}{h}\right)$$

4.  $K$  to funkcją jądra (o właściwościach funkcji gęstości) a  $h$  to parametr wygładzania (ang. *bandwidth parameter*). Będzie o nim nieco później.



# Jak to działa?

## Histogram








# Jak to działa?


## Aproksymacja nieparametryczna





# Przykłady użycia różnych funkcji jądra


## Gaussa ( $n=1$ )





# Przykłady użycia różnych funkcji jądra


## Gaussa (n=10)





# Przykłady użycia różnych funkcji jądra


## Gaussa (n=100)





# Przykłady użycia różnych funkcji jądra


## Gaussa (n=1000)





# Przykłady użycia różnych funkcji jądra


## Prostokątne (n=1)





# Przykłady użycia różnych funkcji jądra


## Prostokątne (n=10)





# Przykłady użycia różnych funkcji jądra

## Prostokątne (n=100)








# Przykłady użycia różnych funkcji jądra


## Prostokątne (n=1000)





# Przykłady użycia różnych funkcji jądra


## Półokrągłe ( $n=1$ )





# Przykłady użycia różnych funkcji jądra


## Półokrągłą ( $n=10$ )





# Przykłady użycia różnych funkcji jądra


## Półokrągłe (n=100)





# Przykłady użycia różnych funkcji jądra


## Półokrągłe (n=1000)





# Przykłady użycia różnych funkcji jądra


## Trójkątne (n=1)





# Przykłady użycia różnych funkcji jądra


## Trójkątne (n=10)





# Przykłady użycia różnych funkcji jądra

## Trójkątne (n=100)








# Przykłady użycia różnych funkcji jądra

## Trójkątne (n=1000)



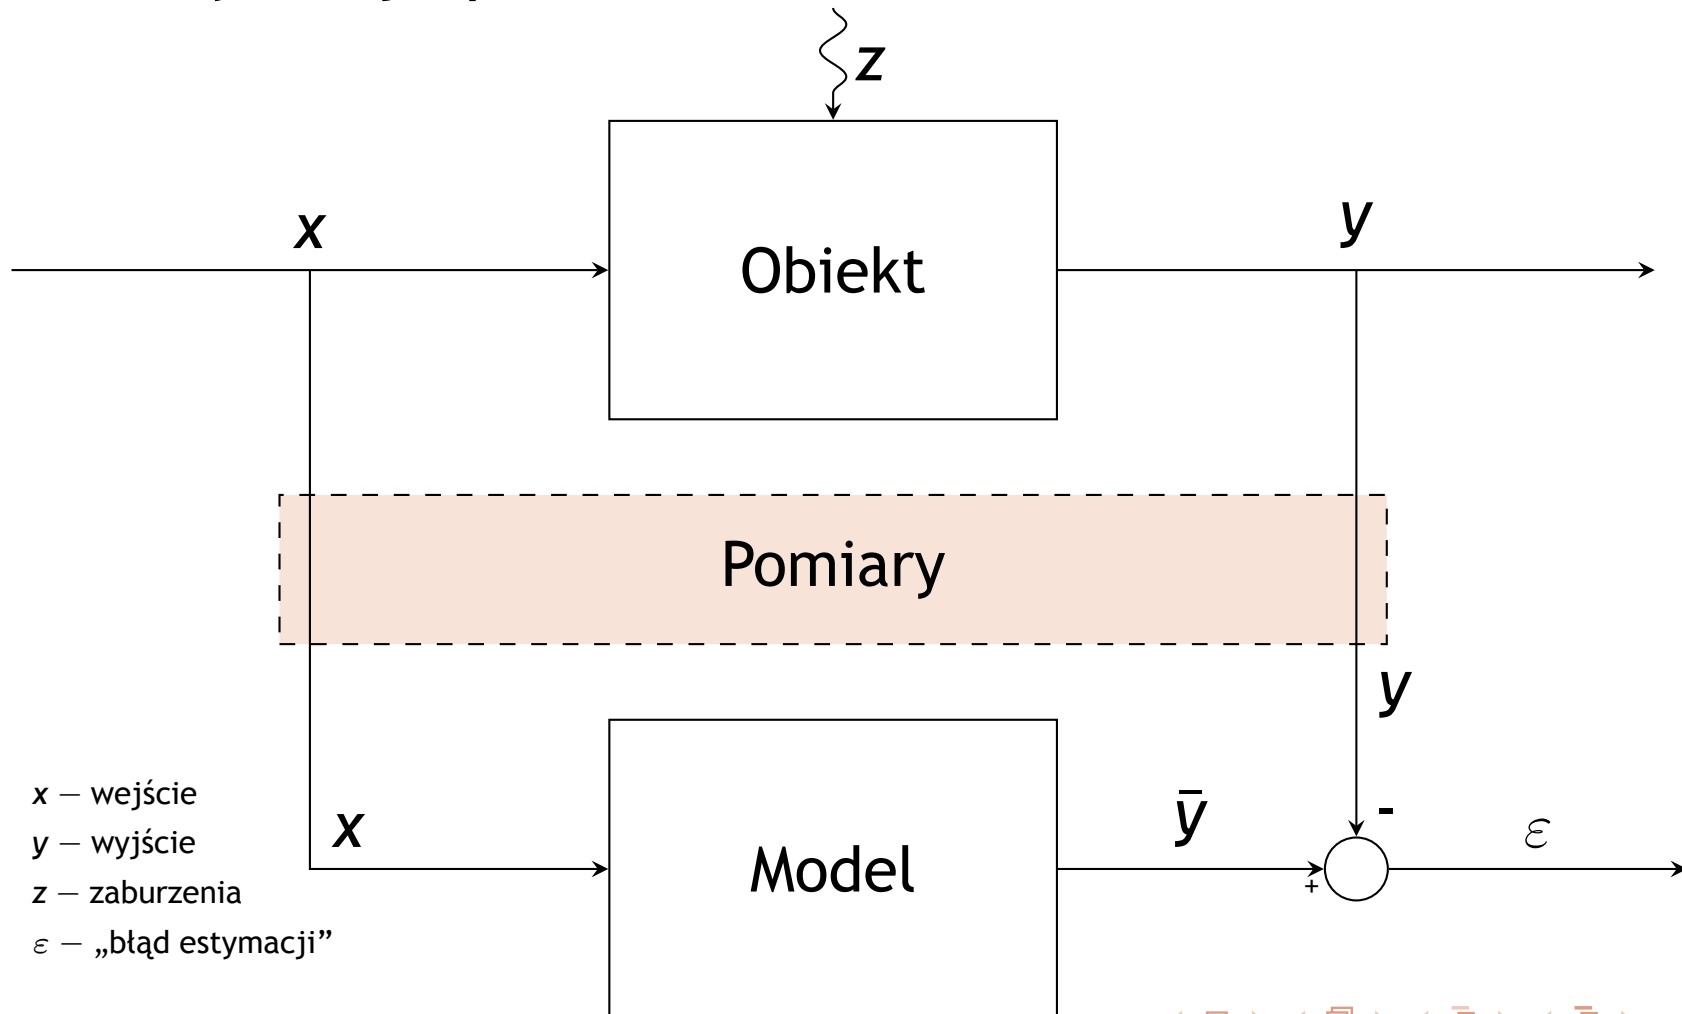


# Eksperyment

1. Właściwie trudno tu mówić o prowadzeniu eksperymentu (w obiegowym tego słowa rozumieniu).
2. Rola eksperymentatora sprowadza się do roli **obserwatora**.
3. Ten rodzaj eksperymentu nazywany również bywa **eksperymentem biernym**.

# Prawdziwy eksperyment (czynny): na obiekt możemy wpływać

Nowa sytuacja przedstawia się tak:





# Nazewnictwo

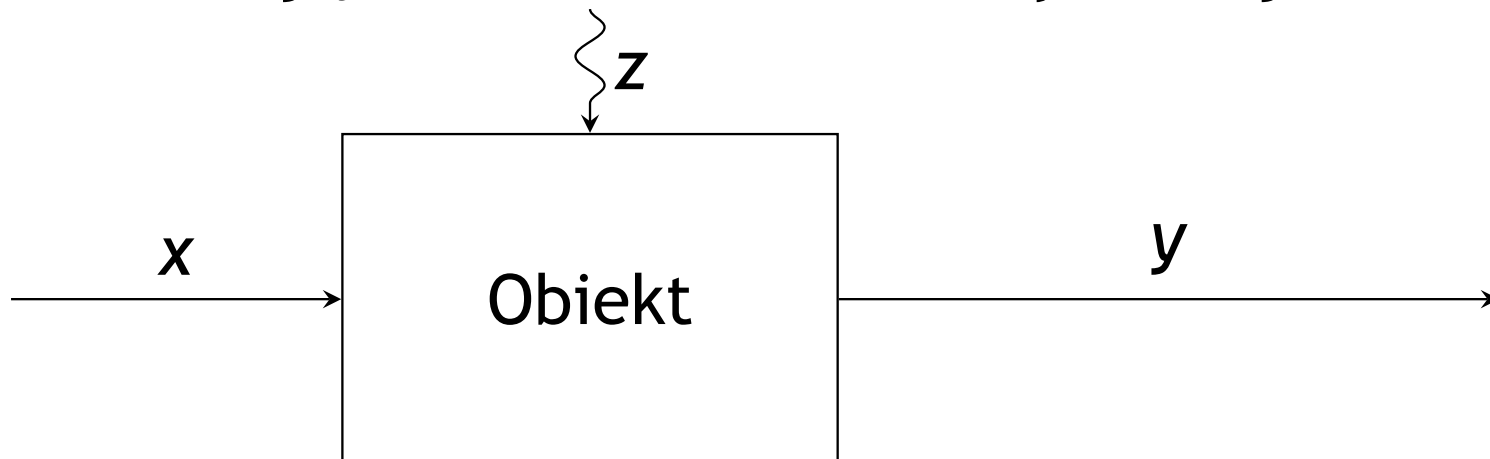
1. SISO – Single Input, Single Output ( $x$  i  $y$  jednowymiarowe)
2. MISO – Multiple Input, Single Output ( $X$  wektor,  $y$  jednowymiarowe)
3. MIMO – Multiple Input, Multiple Output ( $X$ ,  $Y$  – wektory)



# Zburzenia

Jeżeli chodzi o zaburzenia, to:

- ▶ zakłada się, że są „przyzwoite”:
  - ▶ losowe,
  - ▶ niezależne,
  - ▶ o stałym rozkładzie,
  - ▶ najczęściej normalne.
- ▶ Oddziałują na obiekt we właściwym miejscu:



# Zburzenia

Jeżeli chodzi o zaburzenia, to:

- ▶ zakłada się, że są „pryzwoite”:
  - ▶ losowe,
  - ▶ niezależne,
  - ▶ o stałym rozkładzie,
  - ▶ najczęściej normalne.
- ▶ Oddziałują na obiekt we właściwym miejscu:





# Identyfikacja I

- ▶ Zakładając, że prawo według którego działa obiekt da się opisać pewną funkcją:  $y = f(x)$
- ▶ identyfikacja polega na wyznaczeniu takiej funkcji  $\bar{y} = \bar{f}(x)$ , że różnica  $\varepsilon = \|\bar{y} - y\|$  jest najmniejsza (używając wybranej metryki  $\|\cdot\|$ ).
- ▶ Dokonuje się tego na podstawie zestawu obserwacji:  $\{x_i, y_i\}, i = 1, 2, \dots, N$
- ▶ rozwiązując zadanie optymalizacji:

$$Q = \sum_{i=1}^N \|\bar{f}(x_i) - y_i\| \rightarrow \min!$$



# Identyfikacja II

- ▶ Ponieważ tak ogólnie postawione zadanie nie jest łatwe do rozwiązania, zakłada się jakąś parametryczną postać funkcji  $\bar{f}(x)$ .

- ▶ liniową:

$$\bar{y} = ax + b$$

( $x$  i  $y$  oraz  $a$  i  $b$  mogą być wektorami).

- ▶ wielomianową:

$$\bar{y} = \sum_{j=0}^n a_j x^j$$





# Identyfikacja III

- ▶ czy ogólniej

$$\bar{y} = \sum_{j=0}^n a_j f_j(x)$$

- ▶ Kwestia doboru modelu (funkcji  $f(x)$ ) jest bardzo ważna (i trochę na poboczu niniejszych rozważań). Najlepiej by było, żeby odzwierciedlała ona zjawiska fizyczne zachodzące w obiekcie. Pojawia się szereg kwestii – fizycznej interpretacji poszczególnych parametrów modelu (w przypadku modelu parametrycznego).



# Identyfikacja IV

- ▶ Dochodzi do tego jeszcze kwestia taka, że tak  $y$  jak i  $x$  w realnym świecie mają jakieś wymiary fizyczne. Zatem funkcja  $f$  powinna mieć również jakąś interpretację „fizyczną” (czy, na przykład, ekonomiczną, gdy rozważamy takie procesy).



# Model

Z różnych względów, najpopularniejszym modelem jest model liniowy (lub liniowy ze względu na parametry). Do identyfikacji parametrów używa się najbardziej znanych (standardowych) wzorów:

Jeżeli

$$y = \sum_j a_j x_j$$

to możemy to zapisać w postaci wektorowej

$$y = \mathbf{a}'\mathbf{x}$$

Utworzymy macierz

$$X = [\mathbf{x}_1, \mathbf{x}_2 \dots, \mathbf{x}_N]$$



# Model cd

i wektor

$$Y' = [y_1, y_2, \dots, y_N]$$

Przyjmując normę kwadratową możemy kryterium identyfikacji zapisać jako:

$$Q = (a'X - Y')(a'X - Y')' = a'XX'a - a'XY - Y'X'a + Y'Y$$

minimum formy kwadratowej wysnaczyć jest stosunkowo prosto (pochodna po  $a$  i miejsce zerowe układu równań liniowych):

$$a = (X'X)^{-1}X'Y$$



# Model nieliniowy

Ogólnie, przyjmując ogólniejszy model nieliniowy

$$y = F(x, a)$$

zadanie identyfikacji sprowadza się do minimalizacji

$$Q = \sum_{i=1}^N (F(x_i, a) - y_i)^2 \rightarrow \min!$$

Czy da się problem rozwiązać w przypadku ogólnym? To znaczy poszukać funkcji

$$y = F(x)$$



# Identyfikacja nieparametryczna

- ▶ Idea zaczerpnięta ze statystyki
- ▶ Ze statystycznego punktu widzenia interesuje nas coś takiego:

$$E(Y|X) = m(X)$$

$\bar{y}$  jako warunkowa wartość oczekiwana, przy ustalonej wartości  $x$ .



$$E(Y|X = x) = \int yf(y|x)dy = \int y \frac{f(x, y)}{f(x)} dy = \frac{\int yf(x, y)dy}{f(x)}$$

Da się to przedstawić jako pewne operacje na funkcjach gęstości



# Identyfikacja nieparametryczna (2)

- ▶ Jeżeli przyjąć nieparametryczne estymatory gęstości, oraz do estymacji gęstości dwu zmiennych użyć jądra będącego iloczynem jąder dla jednej zmiennej

$$K(x, y) = K(x)K(y)$$

$$\hat{f}(x, y) = n^{-1}h^{-2} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) K\left(\frac{y - y_i}{h}\right)$$

i

$$\hat{f}(x) = n^{-1}h^{-1} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$



# Identyfikacja nieparametryczna (3)

- ▶ Otrzymujemy estymator postaci:

$$\hat{m}_h(x) = \frac{\sum_{i=1}^n K_h(x - x_i) y_i}{\sum_{i=1}^n K_h(x - x_i)}$$

- ▶ bo  $\int y K\left(\frac{y-y_i}{h}\right) dy = y_i$
- ▶ Można to zapisać również inaczej:  $m(x) = \sum_i w_{in} y_i$

gdzie  $w_{in} = \frac{K\left(\frac{x-x_i}{h}\right)}{\sum_{j=1}^n K\left(\frac{x-x_j}{h}\right)}$