

# *Statystyka - wykład II*

*Pomoce do samodzielnej pracy*

# REGRESJA LINIOWA

Prosta ( $y = ax + b$ ) najlepiej charakteryzująca zależność między  $x$  i  $y$ .

$y$  – zmienna objaśniana (czasem nazywana też zależną)

$x$  – zmienna objaśniająca (czasem nazywana też niezależną)

$a$  – współczynnik kierunkowy, współczynnik regresji  $y$   
względem  $x$

$b$  – wyraz wolny

# REGRESJA LINIOWA

Metoda najmniejszych kwadratów ma na celu dopasowanie do zebranych danych, pary wyników takiej linii prostej, która jest do nich najlepiej dopasowana (obliczeniowo).

$$a = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$b = \bar{y} - a\bar{x}$$

gdzie:  $\bar{x}$  oznacza wartość średnią zmiennej objaśniającej  
 $\bar{y}$  oznacza wartość średnią zmiennej objaśnianej

# RESZTY

Kiedy mamy wyliczone parametry funkcji regresji liniowej, możemy wyliczyć o ile nasze doświadczalne  $y$  różnią się od teoretycznego  $y$  obliczonego na podstawie funkcji regresji dla konkretnych wartości  $x$ . Każda taka różnica jest nazywana resztą albo składnikiem resztowym.

Wykres reszt pokazuje, na ile reszty odchylają się od linii regresji. Na wykresie reszt otrzymanych z modelu względem zmiennej objaśniającej nie powinno być widać żadnej zależności. Jeśli taka zależność jest widoczna, to regresja liniowa nie jest optymalną metodą szacowania  $y$  na podstawie  $x$ .

# OCENA OSZACOWANIA FUNKCJI REGRESJI

- Odchylenie standardowe składnika resztowego.
- Współczynnik determinacji.

# ODCHYLENIE STANDARDOWE SKŁADNIKA RESZTOWEGO

To inaczej błąd standardowy szacunku. Informuje, o ile średnio wartości empiryczne zmiennej odchylają się od wartości teoretycznych obliczonych na podstawie oszacowanej funkcji regresji:

$$S_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - 2}}$$

gdzie:  $\hat{y}$  oznacza estymowaną wartość zmiennej objaśnianej

# WSPÓŁCZYNNIK DETERMINACJI

- Pozwala stwierdzić czy oszacowane równanie regresji jest przydatne do przewidywania czy nie.
- Nazywa się go często współczynnikiem dopasowania regresji i oznacza jako  $R^2$ .
- Określa on stopień w jakim linia regresji najmniejszych kwadratów wyjaśnia zmienność obserwowanych danych.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$$

# OBSERWACJE NIETYPOWE

Obserwacje nietypowe (odstające) to obserwacje, które nie pasują do modelu, tzn. są o wiele za duże lub o wiele za małe. Często (choć nie zawsze) zmienne odstające biorą się z błędów pomiarowych lub pomyłek przy wprowadzaniu informacji do baz danych.

Obserwacja odstająca to obserwacja, która nie należy do poniższego przedziału:

$$x_{ods} \notin [Q_1 - k(Q_3 - Q_1), Q_3 + k(Q_3 - Q_1)]$$

gdzie najczęściej przyjmuje się  $k = 1,5$ .



# EKSTRAPOLACJA

Prognozowanie wartości pewnej zmiennej lub funkcji poza zakresem, dla którego mamy dane, przez dopasowanie do istniejących danych pewnej funkcji, następnie wyliczenie jej wartości w szukanym punkcie.

Pokrewną metodą jest interpolacja, gdzie po dopasowaniu funkcji wyliczamy jej wartość pomiędzy znanymi jej punktami.