

Statistični modeli

Milena Kovač

16. november 2012

Statistični modeli

1. Izvleček iz opazovanj
2. Abstrakcija realnosti
3. Poenostavljena slika, prirejena iz podatkov
4. Opazovanje pojasnimo z vplivi
5. Nepojasnjeni del razlik ostane v ostanku

$$\textit{lastnost} = \textit{funkcija [vplivi]} + \textit{ostanek}$$

Sinonimi za lastnost

- $y_{ij\dots}$, samo izjemoma kaj drugega
- meritve, subjektivne ocene/točke
- opazovanja
- odvisne spremenljivke
- "posledica"

Vplivi

- lastnosti so odvisne od številnih vplivov
- "vzroki"
- vplivi so lahko znani (zabeleženi)
- lahko pa so tudi neznani (spregledani)
- lahko so pomembni (značilni)
- ali nepomembni (zanemarljivi, niso značilni)

Ostanek

- Napaka (naključna napaka, error)
 - napaka pri meritvah (samo do sprejemljive tolerance!)
 - napaka pri izvedbi poskusa
- Ostanek (zavestna napaka, residual)
 - pozabljeni in zanemarjeni vplivi
(neznanje ni opravičilo za površnost!)
 - poenostavljen model
(izpustimo lahko le vplive z majhnim učinkom)

Elementi statističnega modela

1. Enačba modela (equation): $y_{ij..} = ?$
2. Pričakovane vrednosti (expected values): $E(y_{ij..}) = ?$
3. Struktura varianc in kovarianc
(covariance structure, covariance matrices): $cov(y_{ij..}) = ?$
4. Predpostavke (assumptions) in omejitve (restrictions):
opišemo v stavkih

Primer (ovce)

- ✓ Pri ovcah dveh pasem so proučevali maso jagnjet. Jagnjeta so bila odstavljenih hkrati, vendar so bila zaradi različnega datuma rojstva različno stara... ■

Opazovanje	masa ob odstavljivju	y	■
Vplivi	pasma	P	■
	starost	x	■
Regresijski	koeficient	b	■
Ostanek		e	■

Primer (ovce)

Pasma	i	Jagnje	j	Odstavitev	Masa ob prodaji (kg)
				Starost (dni)	Masa (kg)
Texel	1			90	38.7
Texel	2			85	35.3
Texel	3			95	32.1
JS ovca	4			88	26.2
JS ovca	5			91	27.3
JS ovca	6			97	33.4
P_i		(a_{ij})		x_{ij}	y_{ij}

Primer (ovce)

Pasma	i	Jagnje	j	Starost (dni)	Odstavitev	Masa (kg)	Masa ob prodaji (kg)
Texel	1	1	1	90	x_{11}	38.7	y_{11}
Texel	1	2	2	85	x_{12}	35.3	y_{12}
Texel	1	3	3	95	x_{13}	32.1	y_{13}
JS ovca	2	4	1	88	x_{21}	26.2	y_{21}
JS ovca	2	5	2	91	x_{22}	27.3	y_{22}
JS ovca	2	6	3	97	x_{23}	33.4	y_{23}
P_i	(a_{ij})		x_{ij}		y_{ij}		

Primer (ovce)

- ✓ Pri ovcah dveh pasem so proučevali maso jagnjet. Jagnjeta so bila odstavljena hkrati, a so bila ... različno stara ...

Opazovanje	Masa ob odstavljitvi	y_{ij}
Srednja vrednost		μ
Vplivi	Pasma	$P_i \quad i=1, 2$
	Starost	x_{ij}
Regresijski	koeficient	b
Ostanek		$e_{ij} \quad j=1, 2, 3$

Enačba modela:

$$y_{ij} = \mu + P_i + b x_{ij} + e_{ij}$$

Enačba

$$y_{ij} = \mu + \dots + e_{ij}$$

Oznake v modelu

Opazovanje: y

Srednja vrednost: μ ali b_0 ali α

Ostanek: e

Oznake v modelu: vplivi

$$\dots + P_i + b x_{ij} + \dots$$

1. Sistematski vplivi:

(a) vpliv z nivoji: P |

ena črka, **velika**, brez strešic, spominja na ime vpliva
tudi grške črke: μ , β ... |

(b) regresijski koeficient: b ali β |

(c) neodvisna spremenljivka: x |

2. Naključni vplivi: |

(a) ena črka, **mala**, brez strešic, spominja na ime vpliva (a_{ij})

Indeksi v modelu

$$y_{ij} = \mu + P_i + bx_{ij} + e_{ij}$$

- $i = 1, 2 \Leftarrow$ ker sta dve pasmi
- $j = 1, 2, \dots, n_i \Leftarrow$ označuje opazovanja znotraj pasme
- $ij \Leftarrow$ določa vsako opazovanje
- opazovanje ima vedno iste indekse kot napaka,
- pogosto tudi neodvisna spremenljivka x :
pri vsaki meritvi naredimo napako
(tudi $e_{ij} = 0$ je napaka!)

Parametri (ovce)

$$y_{ij} = \mu + P_i + bx_{ij} + e_{ij}$$

- opazovanje: odstavitevna masa jagnjet y_{ij}
- ostanek: e_{ij}
- vplivi: pasma (P), starost (jagnjeta j pri pasmi i - x_{ij})
- parametri (neznanne v modelu): μ, P_1, P_2, b

Parametri (nadalj.)

- parametri (neznanke v modelu): μ, P_1, P_2, b
- število (neznanih) parametrov: $1 + 2 + 1 = 4$
- število opravljenih meritev: $n = n_1 + n_2 = \sum_i n_i$

Ne zamenjujte vplivov, parametrov in ocen

Vplivi: vzroki za razlike (razpršenost)

- pasma (P) in starost (x_{ij})

Parametri: neznana vrednost za posamezne nivoje

- masa jagnjet pri texel (P_1) in JS ovci (P_2)
- povečevanje odstavitevne mase s starostjo (b)

Ocena: iz podatkov izračunana vrednost parametra

- jagneta tehtajo \hat{P}_1 pri texel in (\hat{P}_2) JS pasmi
- masa jagnet s starostjo narašča z \hat{b} kg/dan

Primer II - ovce

- dodajmo modelu še vpliv živali (naključni vpliv, kvalitativni),
- starost pa opišimo s kvadratno regresijo ugnezdeno znotraj pasme

$$y = \mu + P + b \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right) + b \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right)^2 + a + e$$

Primer II - regresijski koeficienti

- imamo dva različna regresijska koeficiente

- za linearni člen b_I
- za kvadratni člen b_{II}

$$y = \mu + P + b_I \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right) + b_{II} \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right)^2 + a + e$$

Primer II - kvalitativni vplivi

- dodajmo indekse kvalitativnim vplivom (vplivom z razredi)

- imamo dve pasmi P_i
- pri vsaki pasmi P_i imamo več živali a_{ij}
- žival a_{ij} pripada pasmi P_i

$$y = \mu + P_i + b_I \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right) + b_{II} \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right)^2 + a_{ij} + e$$

Primer II - lastnosti in ostanki

- dodajmo indekse za lastnosti in ostanke
 - žival a_{ij} ima samo eno meritev y_{ij} in en ostanek e_{ij}
 - če bi žival imela več meritev, bi jih šteli z dodanim indeksom (npr. y_{ijk})

$$y_{ij} = \mu + P_i + b_I \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right) + b_{II} \left(x - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right)^2 + a_{ij} + e_{ij}$$

Primer II - kvantitativni vplivi

- dodajmo indekse za neodvisno spremenljivko starost
- žival a_{ij} ima eno meritev y_{ij} pri starosti x_{ij}
- pomeni, da pasmi rasteta enako hitro

$$y_{ij} = \mu + P_i + b_I \left(x_{ij} - \left\{ \frac{0}{\bar{X}} \right\}_c \right) + b_{II} \left(x_{ij} - \left\{ \frac{0}{\bar{X}} \right\}_c \right)^2 + a_{ij} + e_{ij}$$

Primer II - starost ugnezdena znotraj pasme

- pomeni, da pasmi rasteta lahko različno hitro
- za vsako pasmo P_i rabimo par regresijskih koeficientov:
 - za linearni člen b_{Ii}
 - za kvadratni člen b_{IIi}

$$y_{ij} = \mu + P_i + b_{Ii} \left(x_{ij} - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right) + b_{IIi} \left(x_{ij} - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right)^2 + a_{ij} + e_{ij}$$

Primer II - konstante v modelu

$$y_{ij} = \mu + P_i + b_{Ii} \left(x_{ij} - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right) + b_{IIi} \left(x_{ij} - \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix} \right)^2 + a_{ij} + e_{ij}$$

- presečišče y z x osjo
- ocene (rešitve) so korigirane na skupno vrednost 0, povprečje \bar{X} ali konstanto c

$$\hat{y}_{ij} = \hat{\mu} + \hat{P}_i + 0 + 0 ; \text{ če } x_{ij} = \begin{Bmatrix} 0 \\ \bar{X} \\ c \end{Bmatrix}$$

- med modeli ni pomembne razlike - so ekvivalentni

Primer - študenti biometrije

- ✓ Pročiti želimo vpliv sedežnega reda na znanje biometrije. Klopi so razvrščene v vrste in stolpce.

Vplivi: vrsta - V_i , $i=1, 2, 3, 4, 5$

Vplivi: stolpec - S_j , $j=1, 2, 3, 4, 5$

Enačba modela:

$$y_{ijk} = \mu + V_i + S_j + e_{ijk}$$

- v klopi sedi več študentov: $k=1, 2, \dots n_{ij}$

Parametri - študenti biometrije

$$y_{ijk} = \mu + V_i + S_j + e_{ijk}$$

- merili smo: y_{ijk}
- ostanešek: e_{ijk}
- vplivi: vrsta (V), stolpec (S)
- parametri: $\mu, V_1, V_2, V_3, V_4, V_5, V_6, V_7, S_1, S_2, S_3$
- število parametrov: $1 + 7 + 3 = 11$

Število študentov poskusu

$$y_{ijk} = \mu + V_i + S_j + e_{ijk}$$

- $ij \Rightarrow$ označuje klop v vrsti i in stolpcu j
- $k \Rightarrow$ označuje študente po klopeh ij ■
- $n = \sum n_{ij} \Leftarrow$ vsota števila (n_{ij}) študentov po klopeh ■
- enako število študentov po klopeh $\Rightarrow n = m_i * m_j * m_k$ ■
pomnožimo število vrst (m_i) s številom klopi v vrsti (m_j) in
številom študentov v klopi (m_k)
- če v vsaki klopi sedijo 4 študenti $\Rightarrow n = 7 * 3 * 4 = 81$

Ali je klop pomembna?

$$y_{ijk} = \mu + V_i + S_j + VS_{ij} + e_{ijk}$$

- oznaka VS_{ij} predstavlja klop v vrsti V_i in stolpcu S_j
- uporabimo jo, če bi bilo kakorkoli možno, da bi klop ugodno ali neugodno vplivala na rezultate študentov v njej (popisana klop, lahka dostopnost pedagoga ...)
- poseben, specifičen vpliv, dodatno poleg splošnega trenda
- tak sestavljen vpliv je **interakcija**
- ozname dobi od sestavlajočih vplivov
- indeksi po abecednem vrstnem redu

Poskusimo I

- Vplivi A , R in C so sistematski, kvalitativni in križno klasificirani (prepleteni)
- Vpliv x je sistematski, kvantitativni, npr. polinom druge stopnje ...
- Vplivi g , a in p so naključni, kvalitativni, ugnezdeni znotraj vseh prej navedenih kvalitativnih vplivov

$$\begin{aligned}y = & \mu + C + R + A + \\& + b_1(x - \bar{x}) + b_2(x - \bar{x})^2 + \\& + g + a + p + e\end{aligned}$$

- Vpišite v model še dvojne in trojne interakcije med vplivi A , R in C
- Ena meritev za vsak razred/nivo pri vplivu p

Preverimo rezultat I

- Vplivi A , R in C so sistematski, kvalitativni in križno klasificirani
- Vpliv x je sistematski, kvantitativni ...
- Vplivi g , a in p so naključni, kvalitativni, ugnezdeni znotraj vseh prej navedenih kvalitativnih vplivov
- Vpišite v model še dvojne in trojne interakcije med vplivi A , R in C
- Ena meritev za vsak razred/nivo pri vplivu p

$$\begin{aligned}y_{ijklmn} = & \mu + C_i + R_j + A_k + CR_{ij} + CA_{ik} + RA_{jk} + CRA_{ijk} + \\& + b_I(x_{ijklmno} - \bar{x}) + b_{II}(x_{ijklmno} - \bar{x})^2 + \\& + g_{ijkl} + a_{ijklm} + p_{ijklmn} + e_{ijklmn}\end{aligned}$$

Poskusimo II

- Vplivi C in R sta sistematska, kvalitativna in križno klasificirana
- A je sistematski, kvalitativni in ugnezden znotraj R
- Vpliv x_1 in x_2 sta sistematska, kvantitativna ...
- Vplivi g , a in p so naključni, kvalitativni, , ugnezdeni znotraj vpliva A , a znotraj g in p znotraj a

$$\begin{aligned}y = & \mu + C + R + A + \\& + b_1 (x_1 - \bar{x}_1) + b_2 (x_2 - \bar{x}_2) + \\& + g + a + p + e\end{aligned}$$

- Vpišite v model še dvojne in trojne interakcije med vplivi A , R in C

Preverimo rezultat II

- Vplivi C in R sta sistematska, kvalitativna in križno klasificirana
- A je sistematski, kvalitativni in ugnezden znotraj R
- Vpliv x_1 in x_2 sta sistematska, kvantitativna ...
- Vplivi g , a in p so naključni, kvalitativni, ugnezdeni znotraj vpliva A , a znotraj g in p znotraj a
- Vpišite v model še dvojne in trojne interakcije med vplivi A , R in C

$$\begin{aligned}y_{ijklmno} = & \mu + C_i + R_j + A_{jk} + CR_{ij} + \\& + b_1 (x_{1ijklmno} - \bar{x}_1) + b_2 (x_{2ijklmno} - \bar{x}_2) + \\& + g_{jkl} + a_{jklm} + p_{iklmn} + e_{ijklmno}\end{aligned}$$

Členi na desni strani modela

1. Regresijski koeficienti

2. Pojasnevalne spremenljivke

(a) neodvisna spremenljivka

- i. kvantitativna spremenljivka
- ii. merimo, štejemo, točkujemo (ocenujemo)
- iii. razvrstimo od manjše do večje vrednosti

(b) vplivi z nivoji

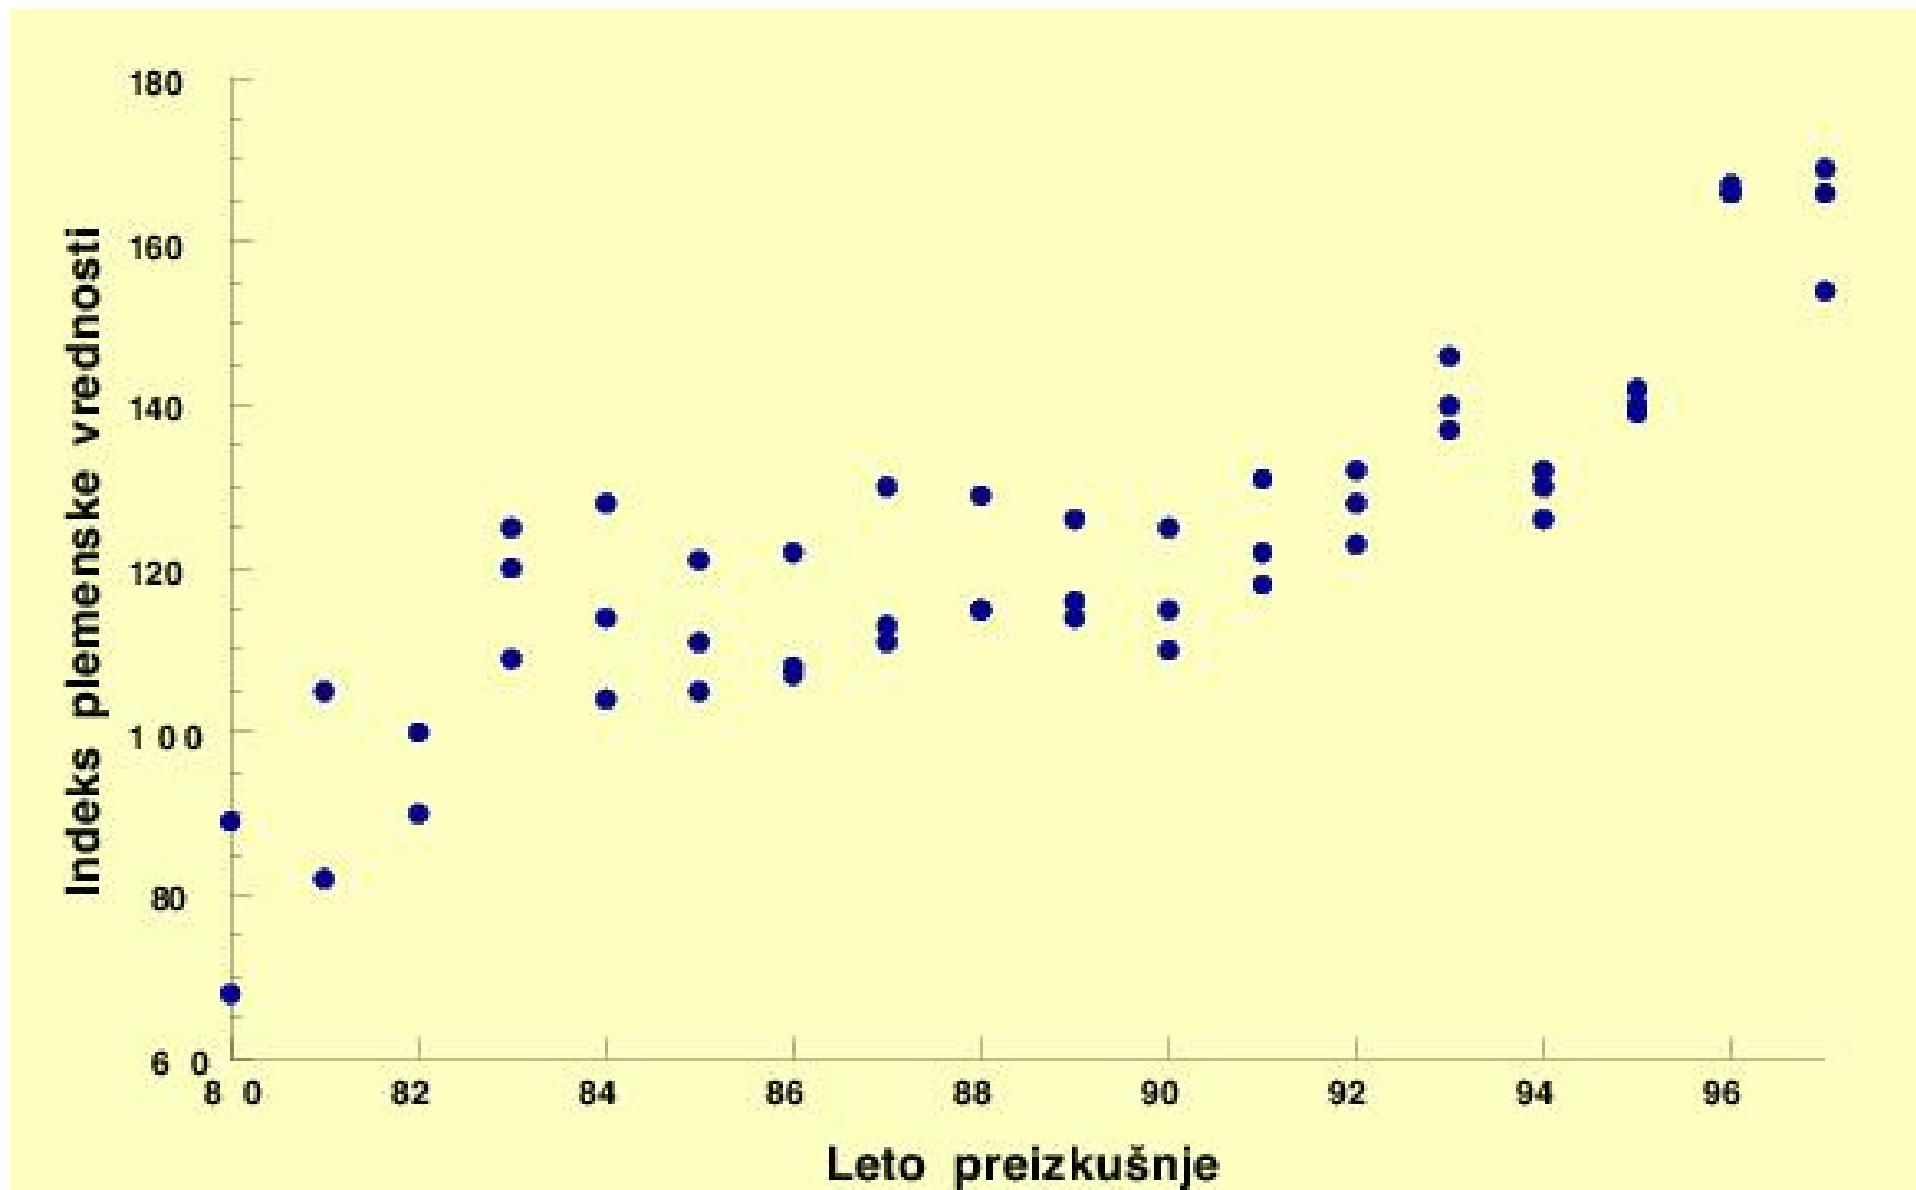
- i. kvalitativna spremenljivka
- ii. nimajo vrednosti, razvrstitve so poljubne

Regresijski koeficient

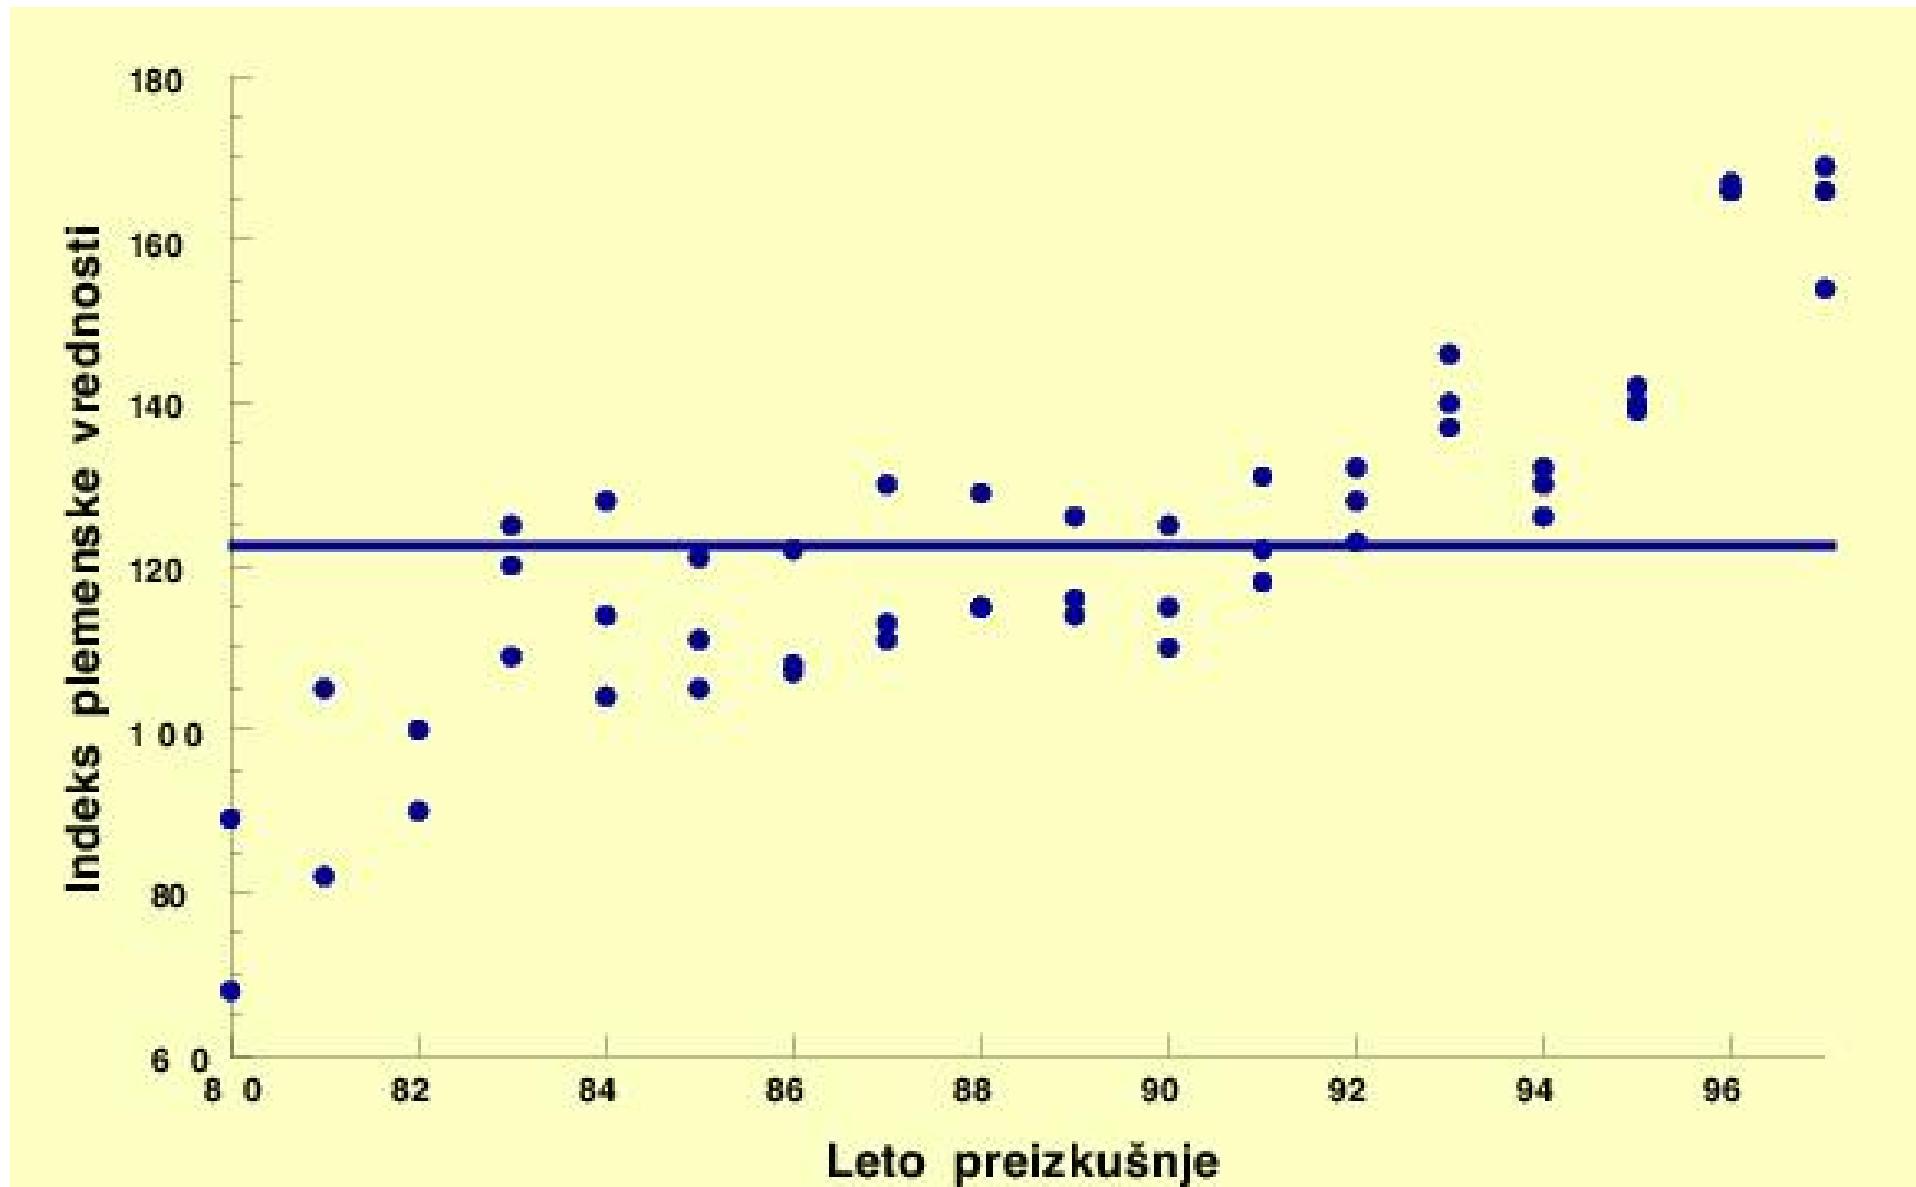
1. Oznaka: b , b_i (mala črka "b") ali β , β_i (grška črka " β ")
2. Smerni koeficient premice pri linearni regresiji
3. Sestavlja celoto z neodvisno spremenljivko x_i
4. Primer linearne regresije

$$y_i = \dots + \beta_1 * x_i + \dots$$

Linearna regresija



Vzporedno z x-osjo?



Sestavimo model!

Neodvisna spremenljivka: | leto preizkušnje
(x , kvantitativna in diskretna spremenljivka,
regresija) |

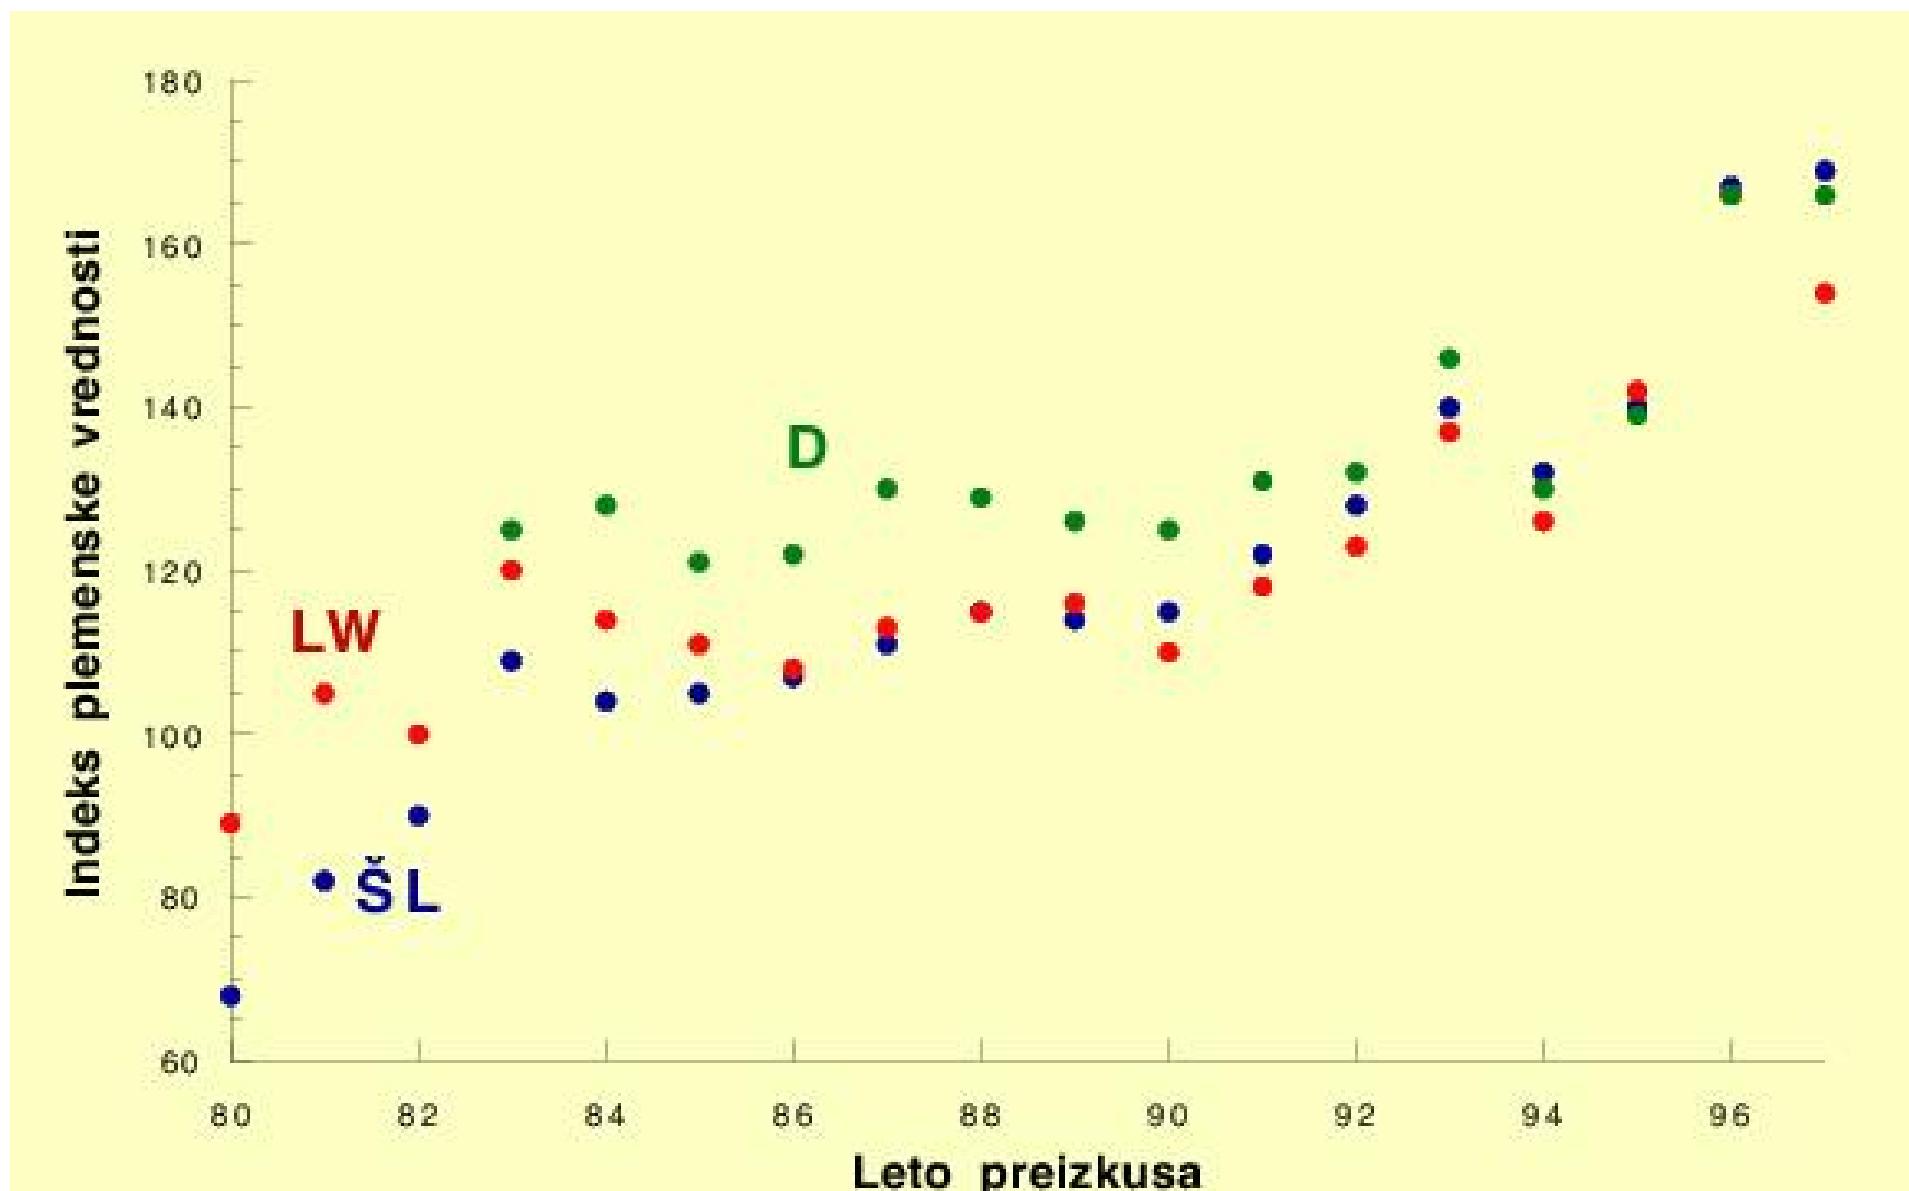
Ovisna spremenljivka: | indeks plemenske vrednosti
(y , kvantitativna in zvezna spremenljivka,
N-porazdelitev)

Model: | $y_i = \mu + b(x_i - 80) + e_i$

Regresijski koeficient: | $\hat{b} = 0$ točk / leto

Ekvivalentni model: | $y_i = \mu + e_i$

Indeks plemenske vrednosti po pasmah



Model in indeksi - IPV

a) Napišimo model - vplivi z nivoji: pasma

$$y = \mu + P_i +$$

- P_i - sistematski vpliv pasme, $i = 1, 2, 3$; ■

b) Dodajmo kvantitativne vplive - katera funkcija je primerna?

$$y = \mu + P_i + b_I(x - 80) + b_{II}(x - 80)^2 + b_{III}(x - 80)^3 + ■$$

c) Regresija je ugnezdena znotraj pasme:
 b -ji dobijo indeks od pasme

$$y = \mu + P_i + b_{Ii}(x - 80) + b_{IIi}(x - 80)^2 + b_{IIIi}(x - 80)^3 + ■$$

Model in indeksi - IPV

d) Dodajmo še ostanek:

$$y = \mu + P_i + b_{Ii}(x - 80) + b_{IIi}(x - 80)^2 + b_{IIIi}(x - 80)^3 + e$$

e) Opremimo odvisno spremenljivko in ostanek z indeksi:

- imamo več opazovanj ($j = 1, 2, \dots, n_i$) za i -to pasmo
- vsaka meritev ima napako

$$y_{ij} = \mu + P_i + b_{Ii}(x - 80) + b_{IIi}(x - 80)^2 + b_{IIIi}(x - 80)^3 + e_{ij}$$

f) Uredimo še neodvisno spremenljivko z indeksi:

- vsako leto (x_{ij}) imamo za i -to pasmo eno vrednost y_{ij}

$$y_{ij} = \mu + P_i + b_{Ii}(x_{ij} - 80) + b_{IIi}(x_{ij} - 80)^2 + b_{IIIi}(x_{ij} - 80)^3 + e_{ij}$$

Meritve debeline hrbtne mišice

Žival	Gne- zdo	Pas- ma	Masa (kg)	D H M (mm)			Temp. peke ($^{\circ}$ C)
				1	2	3	
1	1	11	113	81.3	79.4	80.2	180
2	1	11	106	76.0	74.0	75.2	80
3	2	11	119	81.0	83.4	85.0	180
4	2	11	107	93.2	92.0	92.8	80
5	3	22	101	74.9	73.6	72.7	180
6	3	22	106	84.8	84.2	85.6	80
7	4	22	117	75.8	78.0	76.3	180
8	4	22	120	88.2	84.9	86.5	80

Izpeljimo (sestavimo, nastavimo, napišimo) statistični model!

Glavni vplivi

Vpliv	sist./naklj.	kvant./kvalit.	oznaka	opomba
Žival	naključni	kvalitativni	a_{ijk}	znotraj gnezda
Gnezdo	naključni	kvalitativni	g_{ij}	znotraj pasme
Pasma	sistematski	kvalitativni	P_i	
Masa	sistematski	kvantitativni	$x_m?$	
Temperatura	sistematski	kvantitativni	$x_t?$	

Model in indeksi - DHM

a) Napišimo model - vplivi z nivoji: pasma, gnezdo, žival

$$y = \mu + P_i + g_{ij} + a_{ijk}$$

- P_i - sistematski vpliv pasme, $i = 1, 2, 3$;
- g_{ij} - naključni vpliv gnezda znotraj pasme, $j = 1, 2, \dots n_i$;
- a_{ijk} - naključni vpliv živali znotraj pasme, $k = 1, 2, \dots n_{ij}$

b) Dodajmo kvantitativne vplive

- sistematski vpliv - umestimo pred naključni del, brez indeksov
- določimo tudi konstanto

$$y = \mu + P_i + b_m(x_m - 110) + b_t(x_t - 80) + g_{ij} + a_{ijk}$$

Model in indeksi - DHM

- c) Samo če je regresija ugnezdena znotraj pasme:
 b -ji dobijo indeks od pasme (npr. temperatura)
presodimo po grafu, znanju, statistični preveritvi ...

$$y = \mu + P_i + b_m(x_m - 110) + b_{ti}(x_t - 80) + g_{ij} + a_{ijk} \blacksquare$$

- d) Dodajmo še ostanek:

$$y = \mu + P_i + b_m(x_m - 110) + b_{ti}(x_t - 80) + g_{ij} + a_{ijk} + e \blacksquare$$

Model in indeksi - DHM

- e) Opremimo odvisno spremenljivko (lastnost) in ostanek z indeksi:
žival a_{ijk} ima več ponovitev in sicer $l = 1, 2, \dots n_{ijk}$
 n_{ijk} je število ponovitev za vsako žival (v preglednici $n_{ijk} = 3$)
če so vsi $n_{ijk} = 1$, ne dodamo novega indeksa

$$y_{ijkl} = \mu + P_i + b_m(x_m - 110) + b_{ti}(x_t - 80) + g_{ij} + a_{ijk} + e_{ijkl}$$

- f) Uredimo še neodvisno spremenljivko z indeksi:
vse tri meritve y_{ijkl} imajo za par isto vrednost x_{mijk} in x_{tijk}
pogosto so indeksi isti ...

$$y_{ijkl} = \mu + P_i + b_m(x_{mijk} - 110) + b_{ti}(x_{tijk} - 80) + g_{ij} + a_{ijk} + e_{ijkl}$$

Alternativne možnosti modela za DHM

- namesto črk uporabimo (arabske) številke

$$y_{ijkl} = \mu + P_i + b_1(x_{1ijk} - 110) + b_{2i}(x_{2ijk} - 80) + g_{ij} + a_{ijk} + e_{ijkl}$$

- namesto konstante je lahko povprečje

$$y_{ijkl} = \mu + P_i + b_1(x_{1ijk} - \bar{x}_1) + b_{2i}(x_{2ijk} - \bar{x}_2) + g_{ij} + a_{ijk} + e_{ijkl}$$

- konstanta je lahko enaka tudi 0

$$y_{ijkl} = \mu + P_i + b_1 x_{1ijk} + b_{2i} x_{2ijk} + g_{ij} + a_{ijk} + e_{ijkl}$$

- namesto malih uporabimo velike črke (manj možnosti napak)

$$y_{ijkl} = \mu + P_i + b_M(x_{Mijk} - \bar{x}_M) + b_{Ti}(x_{Tijk} - \bar{x}_T) + g_{ij} + a_{ijk} + e_{ijkl}$$

