

# Razvoj statističnih modelov - po izvedbi poskusa

Milena Kovač

2. januar 2013

## Preverimo prvih 8 korakov

- Je poskus potekal po načrtu?
- Preverimo strukturo podatkov:
  - število podatkov po razredih, število neznanih parametrov in stopinj prostosti
  - dodatni vplivi
  - spremenjeni pogoji ...
- Po potrebi popravimo osnovni in možni model!

## 9. Statistična ovrednotenje

**Kriterij:** verjetnost ( $p$ -vrednost), da drži ničelna hipoteza

**Ničelna hipoteza:** ni razlik med nivoju pri izbranem vplivu

**Alternativna hipoteza:** nivoji se med seboj razlikujejo  
najmanj en nivo je različen od drugih

**Verjetnost:**

0.0	$\Leftrightarrow$	1.0
ničelna hipoteza ovržena	$\Leftrightarrow$	ničelna hipoteza drži
razlike so, vsaj ena	$\Leftrightarrow$	razlik ni, nobene

## PRIMER A

Vpliv skupine:  $P = 0.04$

- ničelna hipoteza drži samo v 4 % primerih
- alternativna hipoteza velja v 96 % primerih
- vpliv skupine je v poskusu najverjetneje precej pomemben in ga ne smemo izpustiti iz modela
- izjema: **je ni!**

## PRIMER B

Vpliv krme:  $P = 0.84$

- ničelna hipoteza drži kar v 84 % primerih
- alternativna hipoteza velja v 16 % primerih
- vpliv krme je v izvedenem poskusu najverjetneje popolnoma nepomemben in ga smemo izpustiti iz modela
- izjema: **vpliv krme je osrednji cilj naloge**

## PRIMER C

Vpliv spola:  $P = 0.45$

- ničelna hipoteza drži le v 45 %
- alternativna hipoteza velja v 55 %
- vpliv spola v izvedenem poskusu ni dovolj prepričljiv, rezultat je precej neodločen, in vpliv smemo izpustiti iz modela
- izjema: **vpliv spola je osrednji cilj naloge**

## PRIMER D

Vpliv spola:  $P = 0.65$

- ničelna hipoteza drži le v 65 % primerov
- alternativna hipoteza velja v 35 % primerov
- vpliv spola v izvedenem poskusu ni dovolj prepričljiv, rezultat je precej neodločen, in vpliv smemo izpustiti iz modela
- izjema: **vpliv spola je osrednji cilj naloge**

## PRIMER E

Vpliv mase:  $P = 0.08$

- ničelna hipoteza drži samo v 8 % primerov
- alternativna hipoteza velja v 92 % primerov
- vpliv mase v izvedenem poskusu ni dovolj prepričljiv, a je na meji. Razlik med nivoji ni ali niso dokazane. Morda smo imeli premalo opazovanj ...
- nakazuje se trend, da se lastnost z maso spreminja
- vpliva mase ne izpustitimo iz modela
- izjema: **zmanjkuje stopinj prostosti**

## Kriteriji za izločanje vplivov

P-vrednost	Storimo:	Izjema, kadar
0.00 - 0.05	vedno obdržimo	—
0.05 - 0.40	gotovo obdržimo	zmanjkuje stopinj prostosti za ostanek
0.40 - 0.60	gotovo črtamo	vsi pričakujejo vpliv
0.60 - 1.00	vedno črtamo	je cilj raziskave

## Kriteriji za izbor modela

- statistična značilnost vplivov
- strokovna presoja (število opazovanj in število parametrov, pričakovanja)
- primerjava modela z in brez posameznimi vplivi
- najprej izločamo "podrejene" vplive: interakcije, ugnezdeni vplivi
- obdržimo vse parametre, ki tvorijo celoto
  - regresije: presečišča z ordinato in regresijski koeficienti
  - laktacijske krivulje ...

Vplive izločamo postopoma in raje ponovimo izračun.

Postopek ponavljamo, dokler se model spreminja...

Če črtamo značilni sistematski vpliv ...

- rezultati so neočiščeni
- rezultati so pristranski in "frizirani", ponarejeni
- več nepojasnjene variance, pomembni rezultati so manj očitni
- **tega ne smemo nikdar storiti!**
- črtanje naključnega vpliva:
  - samo poveča varianco (neodvisni nivoji)
  - tudi pristranske ocene (odvisni nivoji - sorodstvo)

## Če obdržimo nepomembni vpliv ...

- porabimo več stopinj prostosti
- rezultati niso napačni, se ne smejo razlikovati pomembno od rezultatov z modelom brez nepomembnega vpliva
- obrazložiti moramo, zakaj je v modelu nekaj nepomembnega - nejasni komentarji
- raje izključimo iz modela z besedami:
  - na osnovi predhodnih obdelav smo vpliv izključili iz nadaljnjih analiz

Deduktivni postopek

možni model



postopoma izločamo vplive z nepomembnimi vplivi



**optimalni model**



osnovni model

$$y_i = \mu + e_i$$

Induktivni postopek

osnovni model



postopoma dodajamo vplive in jih preizkušamo

izpustimo nepomembne vplive



**optimalni model**



teoretični model

Pri tem postopku se nam lahko zgodi, da katerega od pomembnih, značilnih vplivov ali kombinacije ne preizkusimo.

## Prilagodljivost modela

= kako dobro se model prilagaja podatkom (ang. fit of the model)

- več parametrov  $\Rightarrow$  večji delež pojasnjene variance  
 $\Rightarrow$  bolj se bo model prilegal
- število parametrov = število podatkov
  - model se prilagaja popolnoma
  - z modelom nismo nič pridobili
  - model ni uporaben (zakon skromnosti)
- skrbno načrtovan in izveden poskus  
 $\Rightarrow$  večji delež pojasnjene variance

## 10. Strokovna presoja

### Vsak model mora biti

- statistično utemeljen in strokovno interpretiran

### Interpretacija

- opravimo v istem vrstnem redu, kot so vplivi v modelu
- vse značilne vplive moramo prikazati in utemeljiti
- nepričakovani rezultati:
  - preverimo model
  - iščimo smiselno razlago (ni vse zanič, kar je v nasprotju z dosedanjim znanjem)
  - morda je možno razrešiti nejasnost samo z novim poskusom
- **potrebna ponovitev?**

## 11. Proces izgradnje modela

- izgradnja modela ni enkraten proces.
- Vračamo se:
  - na statistično ovrednotenje ali
  - povsem na začetek, na listo vplivov ali celo
  - iskanje dodatnih informacije v katerem od obstoječih informacijskih sistemov

**POMNI!** Pri presoji modela ne smemo absolutno zagovarjati svoje teorije - hipoteze. Poskusimo se vživeti v vlogo kritika, osvetlimo tudi druge plati medalje!

## Krivulje: kompleti parametrov

- linearna enačba: parametri v parih

$$\cdots + M_j + b_j(x_{ijklm} - 100) + \cdots$$

$$\cdots + PM_{ij} + b_{ij}(x_{ijklm} - 100) + \cdots$$

- kvadratna enačba: trije parametri za vsako parabolo

$$\cdots + PM_{ij} + b_{Iij}x_{ijklm} + b_{IIij}x_{ijklm}^2 + \cdots$$

- izpustimo lahko kvadratni člen, če ni značilen  
⇒ linearja regresija

- za vse nivoje imamo iste enačbe

## Nezaželene kombinacije

- črtamo presečišče premic z ordinato  
 $\Rightarrow$  vse premice skozi isto točko na ordinati

$$\cdots + M_j + b_j x_{ijklm} + \cdots$$

- tudi v naslednjih enačbah parametri niso v kompletu
- kvadratnih členov je manj

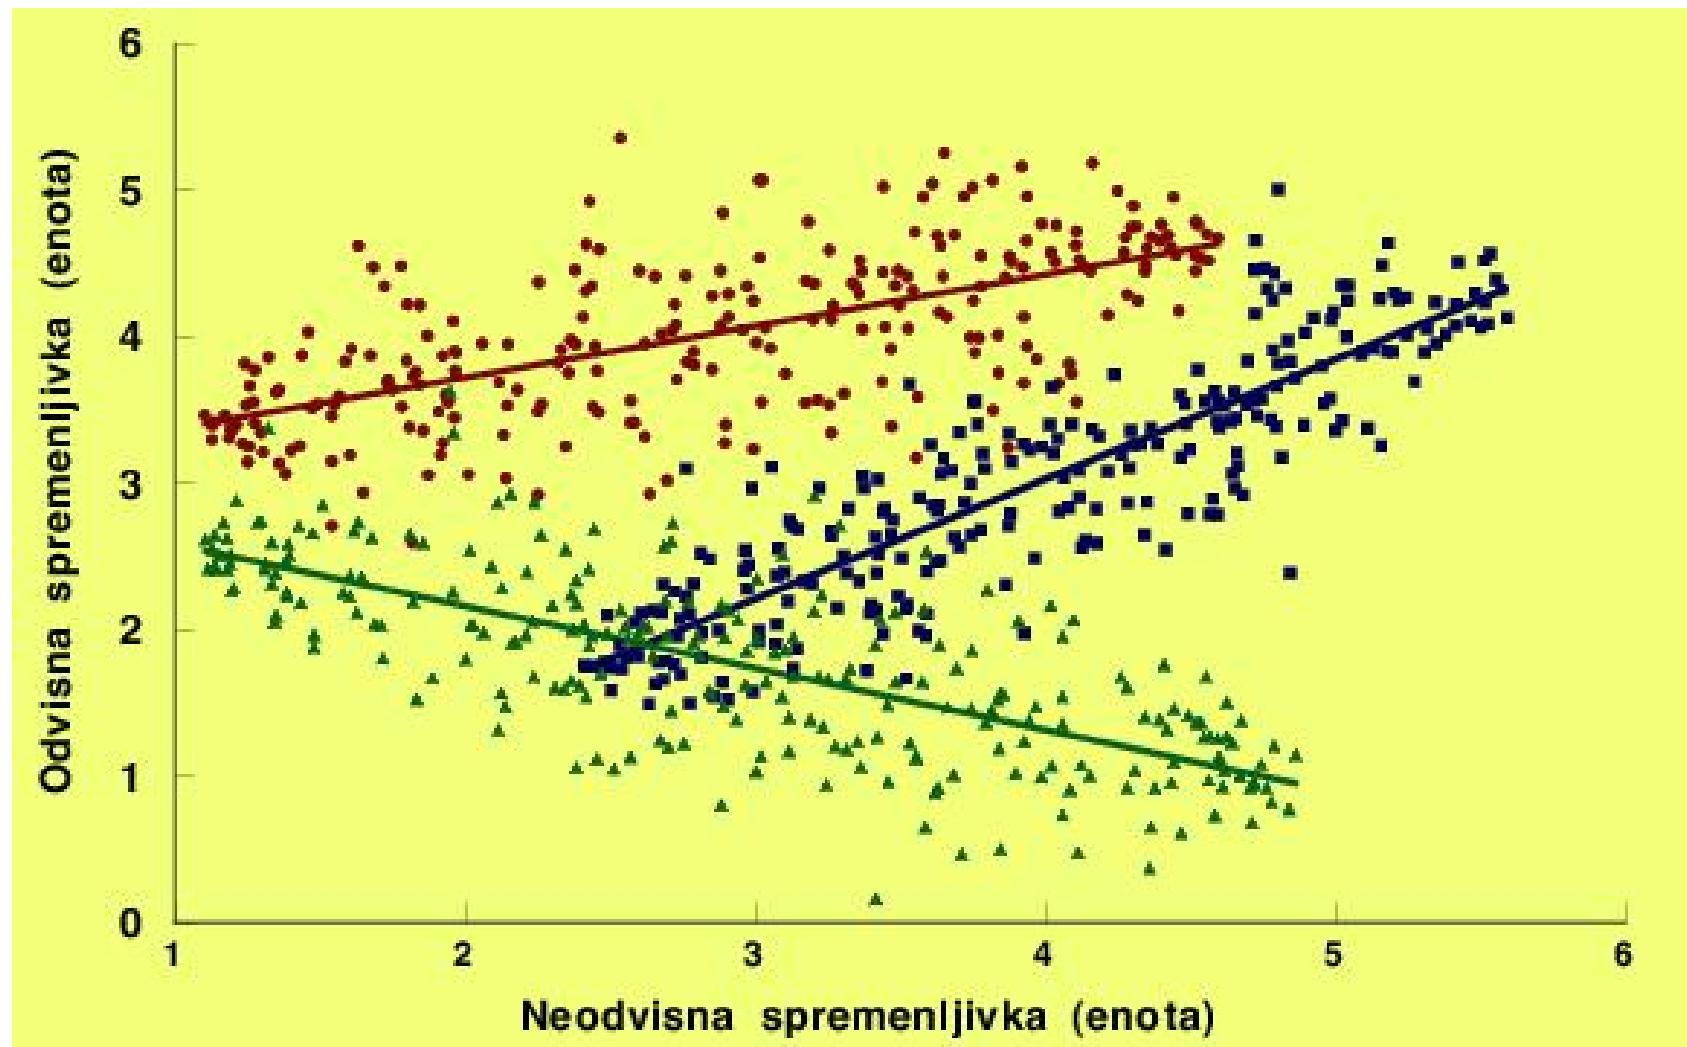
$$\cdots + PM_{ij} + b_{Iij} x_{ijklm} + b_{IIj} x_{ijklm}^2 + \cdots$$

- linearnih členov je več

$$\cdots + M_j + b_{Iij} x_{ijklm} + b_{IIj} x_{ijklm}^2 + \cdots$$

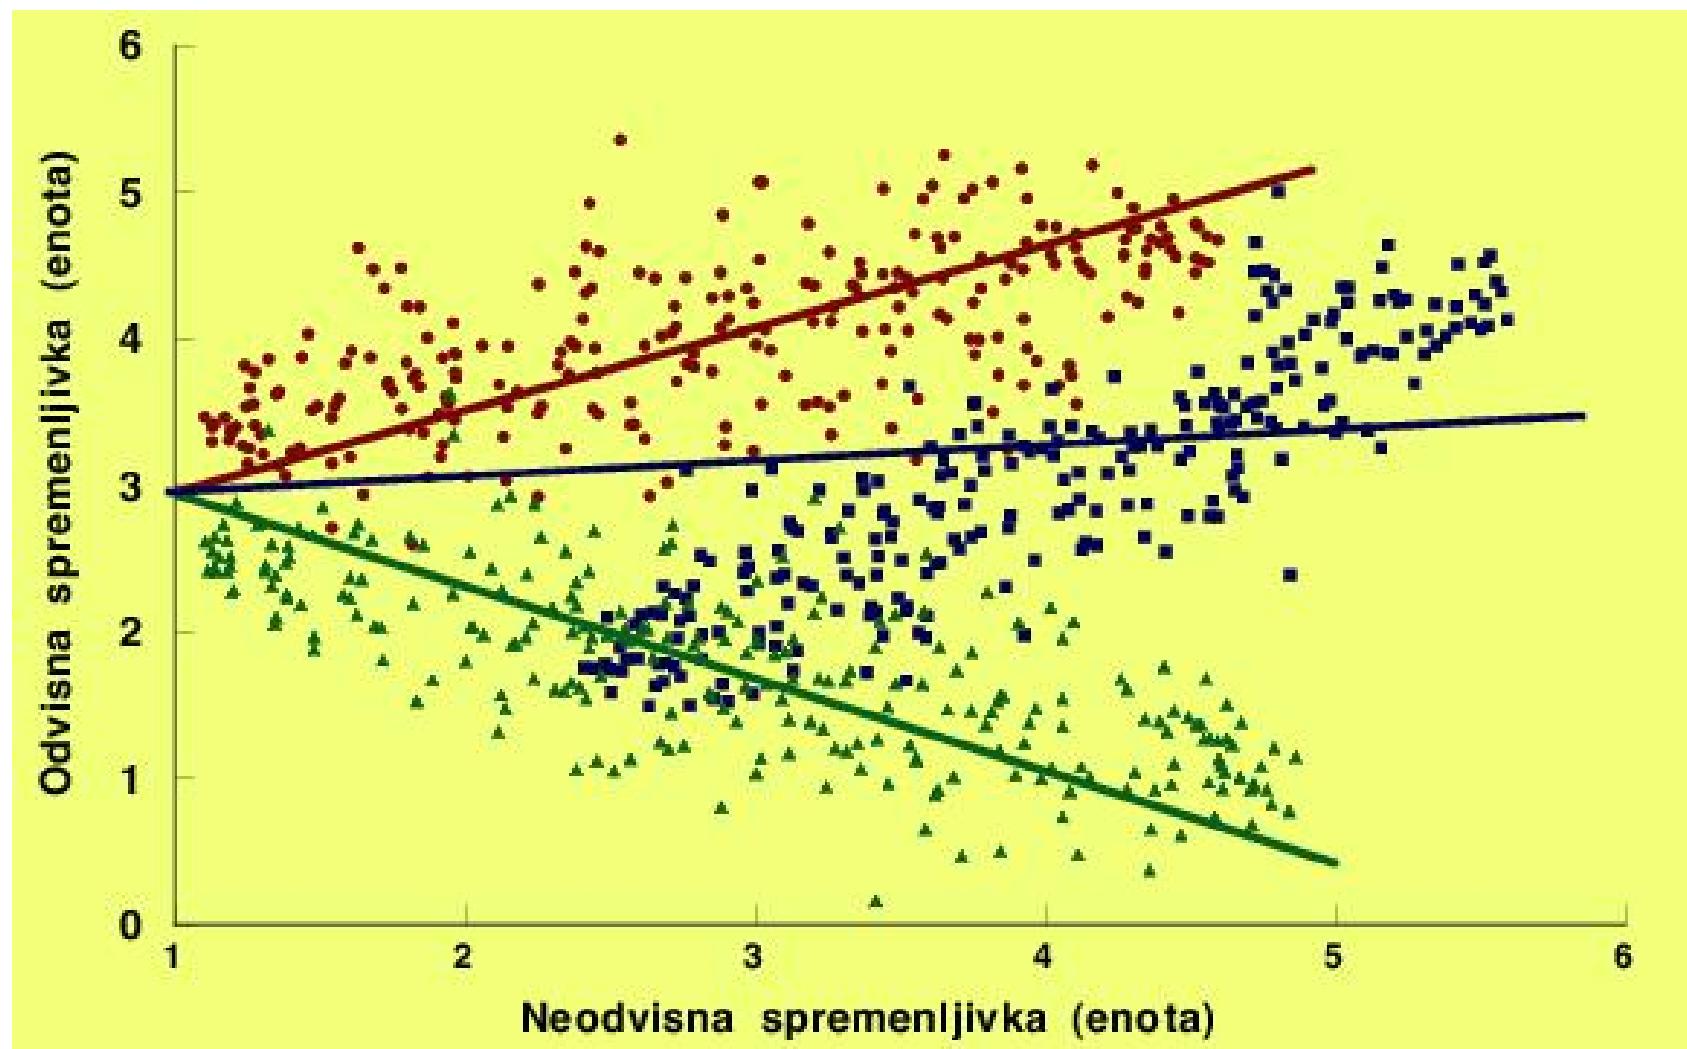
## Primer 1

$$\cdots + M_j + b_j(x_{ijklm} - 1) + \cdots$$



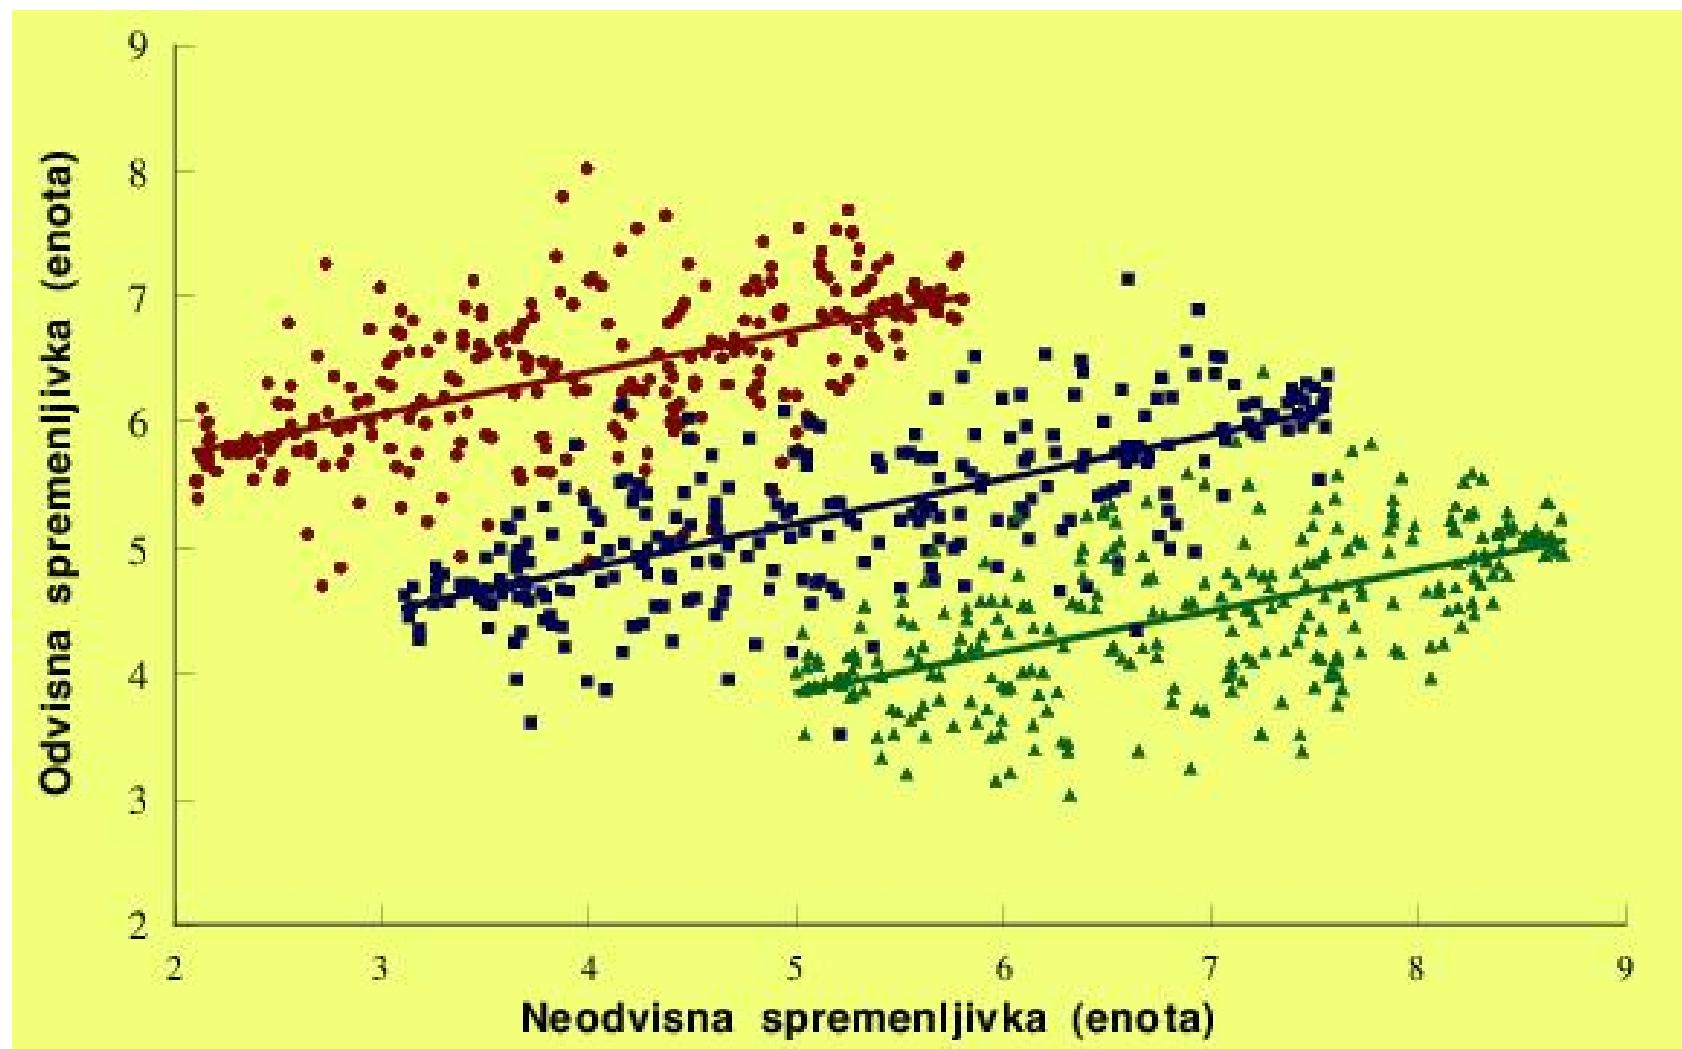
## Primer 2

$$\cdots + M_j + b_j(x_{ijklm} - 1) + \cdots$$



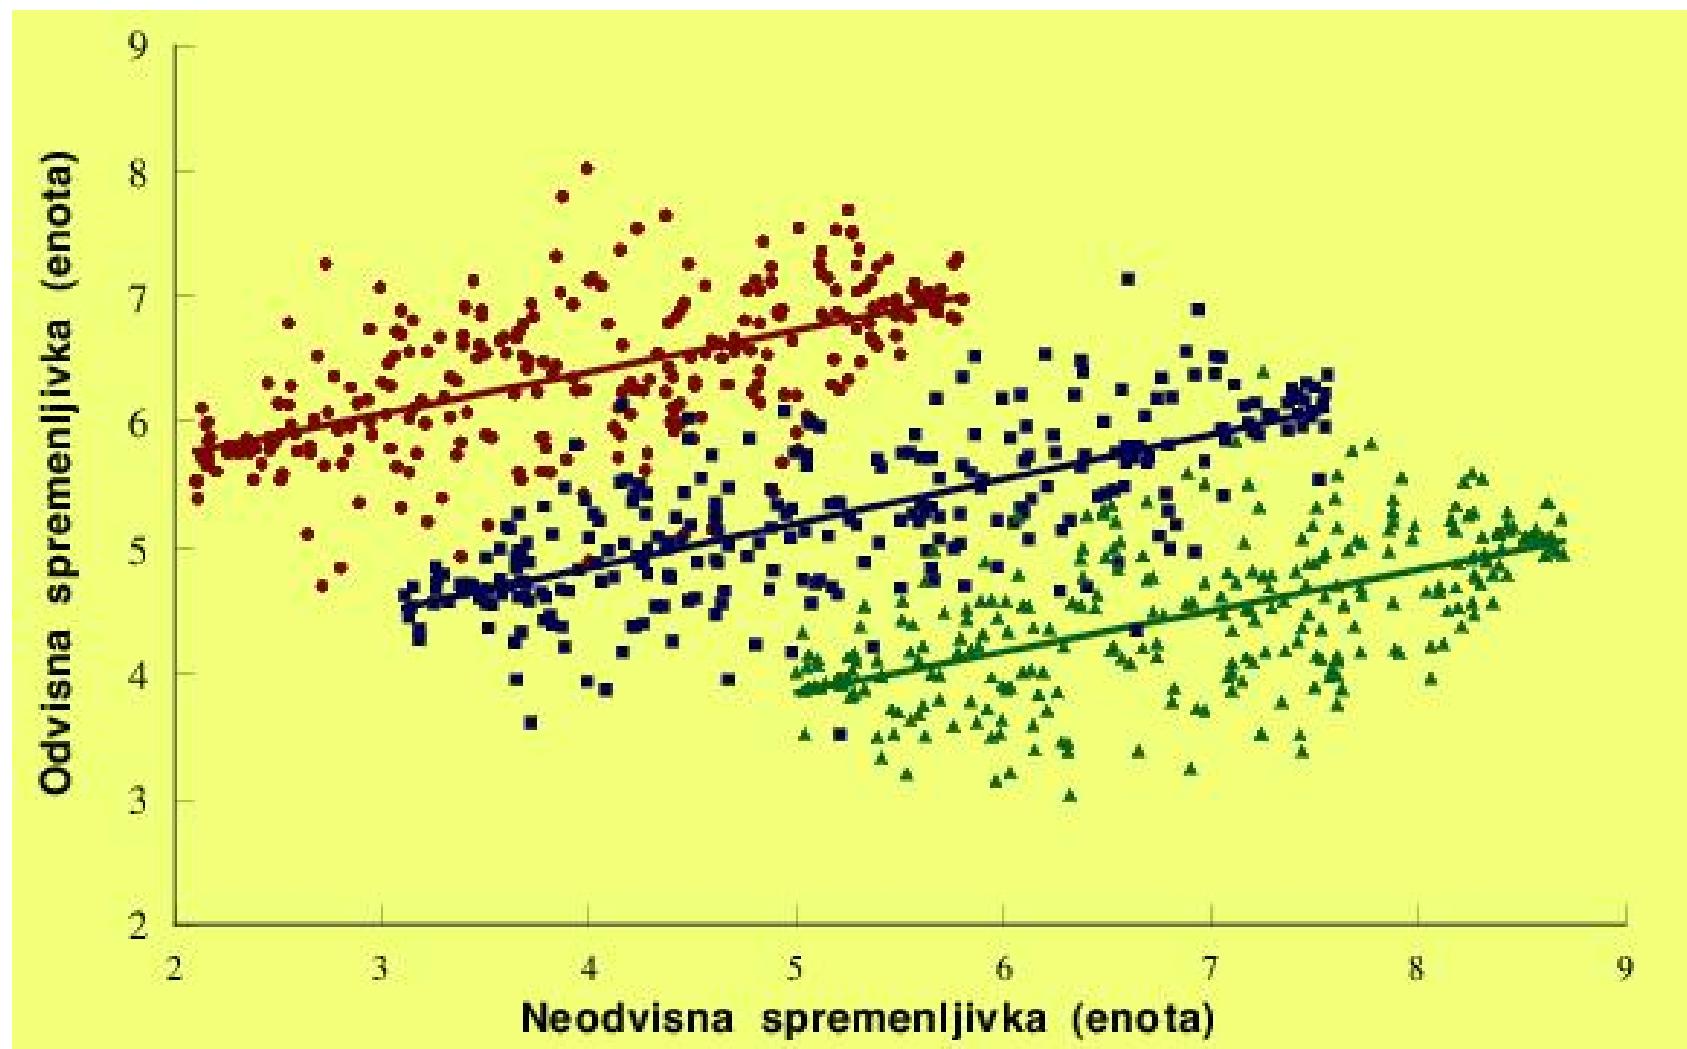
## Primer 3

$$\cdots + M_j + b_j(x_{ijklm} - 2) + \cdots$$



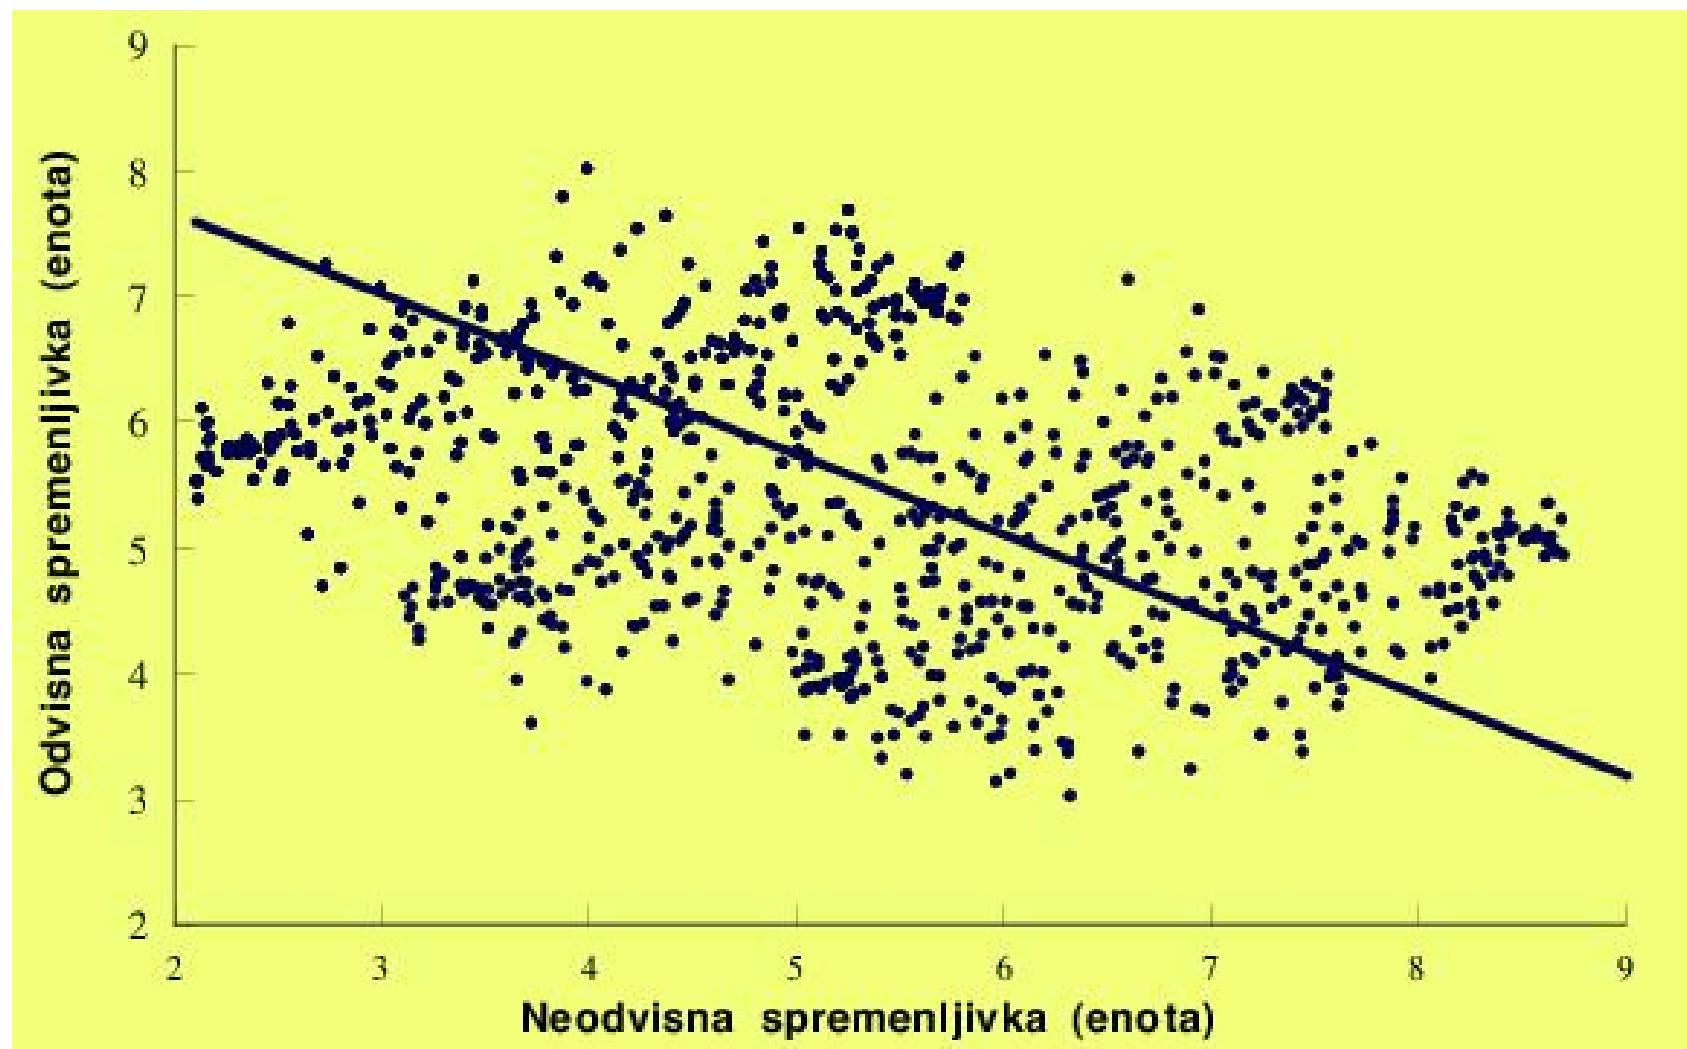
## Primer 4

$$\cdots + M_j + b(x_{ijklm} - 2) + \cdots$$



## Primer 5

$$\mu + \dots + b(x_{ijklm} - 2) + \dots$$



## Primer 6: mladice

Žival	Gnezdo	Pasma	Mesec	Farma	Masa(kg)	DP (g/dan)	DHS(mm)
1	1	SL	JAN	A	102	540	13
2	2	SL	JAN	B	98	550	16
3	1	SL	FEB	C	105	550	16
4	2	SL	FEB	D	102	580	15
5	4	LW	JAN	A	95	520	20
6	5	LW	FEB	B	101	500	24
7	4	LW	FEB	C	101	490	27
8	5	NL	JAN	A	97	560	26
9	4	NL	JAN	B	100	550	22
10	6	NL	FEB	C	97	600	23
11	7	NL	FEB	D	102	610	24

## Poreklo živali

Žival	Oče	Mati	Žival	Oče	Mati
1	15	—	2	15	10
3	15	—	4	15	10
5	14	10	6	14	12
7	14	10	8	13	12
9	—	10	10	15	12
11	—	—	12	—	—
13	14	—	14	16	—
15	16	—	16	—	—

- vsaki živali s podatki pripišemo starša
- nove starše vpišemo na konec seznama in jim poiščemo starše
- ponavljamo, dokler ne pridemo do neznanih prednikov
- žival ima samo eno vrstico

## Število parametrov, stopinje prostosti in rang sistema

- Ponovimo osnovni model za dnevni prirast v preizkusu z mladicami.
- V preizkusu smo imeli skupno 11 meritev, vsaka žival je imela natanko eno meritev.

$$y_{ijklm} = \mu + P_i + M_j + F_k + g_{ijkl} + a_{ijklm} + e_{ijklm}$$

- Lokacijski parametri (ocene za sistematske vplive)
- Parametri disperzije (variance in kovariance za naključne vplive)

## Število parametrov

Poskusimo najprej našteti vse parametre!

- Srednja vrednost  $\mu$
- Parametri za vpliv pasme: SL ( $P_1$ ), LW ( $P_2$ ) in NL ( $P_3$ )
- Parametri za vpliv sezone: januar ( $M_1$ ), februar ( $M_2$ )
- Parametri za vpliv farme: A ( $F_1$ ), B ( $F_2$ ), C ( $F_3$ ) in D ( $F_4$ )
- Parametri disperzije za naključne vplive:
  - varianca  $\sigma_g^2$  za skupno okolje v gnezdu
  - genetska varianca  $\sigma_a^2$  za vpliv živali

## Seznam parametrov v modelu

Vpliv	Seznam parametrov	Obrazložitev
Srednja vrednost	$\mu$	
Pasma	$P_1, P_2, P_3$	tri pasme
Mesec / sezona	$M_1, M_2$	dva meseca
Farma	$F_1, F_2, F_3, F_4$	štiri farme
Gnezdo	$\sigma_g^2$	varianca
Žival	$\sigma_a^2$	varianca

- Pri vplivu skupnega okolja v gnezdu napovemo napovedi za vse nivoje
- Pri vplivu živali napovemo napovedi plemenskih vrednosti za vsako žival
- Pri naključnih vplivih ne štejemo lokacijskih parametrov (= število nivojev)

## Število parametrov in stopinj prostosti

Vplivi	Število parametrov	Število stopinj prostosti
$\mu$	1	1
Pasma	3	$3-1 = 2$
Mesec	2	$2-1 = 1$
Farma	4	$4-1 = 3$
Gnezdo	(7)	polni rang
Žival	(11 + 5)	polni rang
Za model	10	7
Za ostanek	—	$11 - 7 = 4$
Red	$10 + 7 + 16$	
Rang		$7 + 7 + 16$

- **Red sistema** = število enačb za sistematske in naključne vplive
- **Rang sistema** = s.p. za model + število nivojev pri naključnih vplivih

## Stopinje prostosti v možnem modelu - I

$$y_{ijklm} = \mu + P_i + M_j + F_k + \\ + PM_{ij} + PF_{ik} + MF_{jk} + PMF_{ijk} + g_{ijkl} + a_{ijklm} + e_{ijklm}$$

- ocenimo interakcijo, glavne vplive izpeljemo (kasneje izračunamo)
- Izpeljane parametre smo nakazali s kljukico

Parametri	A	B	C	D	Pasma
SL	$PF_{11}$	$PF_{12}$	$PF_{13}$	$PF_{14}$	✓
LW	$PF_{21}$	$PF_{22}$	$PF_{23}$	$PF_{24}$	✓
NL	$PF_{31}$	$PF_{32}$	$PF_{33}$	$PF_{34}$	✓
Farma	✓	✓	✓	✓	✓

$$P_i = \frac{PF_{i1} + PF_{i2} + PF_{i3} + PF_{i4}}{4}$$

## Stopinje prostosti v možnem modelu - II

- Ocenimo lahko tudi srednjo vrednost, glavne vplive in interakcije
- Zadnji nivo pri glavnih vplivih in interakcijah izpeljemo
- Izpeljane parametre smo nakazali s kljukico

Parametri	A	B	C	D	Pasma
SL	$PF_{11}$	$PF_{12}$	$PF_{13}$	✓	$P_1$
LW	$PF_{21}$	$PF_{22}$	$PF_{23}$	✓	$P_2$
NL	✓	✓	✓	✓	✓
Farma	$F_1$	$F_2$	$F_3$	✓	$\mu$

$$P_i = \frac{PF_{i1} + PF_{i2} + PF_{i3} + PF_{i4}}{4}$$

$$4P_i = PF_{i1} + PF_{i2} + PF_{i3} + PF_{i4}$$

$$PF_{i4} = 4P_i - (PF_{i1} + PF_{i2} + PF_{i3})$$

## Seznam parametrov in število stopinj prostosti v modelu Pasma, mesec, farma

Seznam parametrov	Število parametrov	Število stopinj prostosti
$\mu$	1	1
$P_1, P_2, P_3$	3	$3-1 =$ 2
$M_1, M_2$	2	$2-1 =$ 1
$F_1, F_2, F_3, F_4$	4	$4-1 =$ 3

Interakcije med  $P$  in  $M$ , med  $P$  in  $F$ , med  $M$  in  $F$

Seznam parametrov	Štev. param.	Štev. s. p.
$PM_{11}, PM_{12},$ $PM_{21}, PM_{22},$ $PM_{31}, PM_{32}$	$3 \times 2 = 6$	$2 \times 1 = 2$
$PF_{11}, PF_{12}, PF_{13}, PF_{14},$ $PF_{21}, PF_{22}, PF_{23}, PF_{24},$ $PF_{31}, PF_{32}, PF_{33}, PF_{34}$	$3 \times 4 = 12$	$2 \times 3 = 6$
$MF_{11}, MF_{12}, MF_{13}, MF_{14},$ $MF_{21}, MF_{22}, MF_{23}, MF_{24}$	$2 \times 4 = 8$	$1 \times 3 = 3$

## Interakcija med $P$ , $M$ in $F$ in regresije\*

Seznam parametrov	Štev. parametrov	Število s. p.		
$PMF_{111}, PMF_{112}, PMF_{113}, \dots$ $PMF_{324}$	$3 \times 2 \times 4 = 24$	$2 \times 1$	$\times 3$	$= 6$
$b_{I111}, b_{I112}, b_{I113}, \dots b_{I324}$	$3 \times 2 \times 4 = 24$	$3 \times 2$	$\times 4$	$= 24^*$
$b_{II111}, b_{II112}, b_{II113}, \dots b_{II324}$	$3 \times 2 \times 4 = 24$	$3 \times 2$	$\times 4$	$= 24^*$

\* regresijo (polinom druge stopnje, ugnezden znotraj trojne interakcije) imamo v modelu za debelino hrbtne slanine:

$$\begin{aligned}
 y_{ijklmn} = & \mu + P_i + M_j + F_k + PM_{ij} + PF_{ik} + MF_{jk} + \\
 & + PMF_{ijk} + b_{Iijk}(x_{ijklm} - 100) + b_{IIijk}(x_{ijklm} - 100)^2 + \\
 & g_{ijkl} + a_{ijklm} + e_{ijklmn}
 \end{aligned}$$

## Vpliv skupnega okolja v gnezdu in vpliv živali

Seznam parame-trov	Štev. parametrov	Štev. stopinj prostosti
$\sigma_g^2$	(7)	(7)
$\sigma_a^2$	(16)	(16)

- pri naključnih vplivih ne preverjamo števila stopinj prostosti
- ni linearno odvisnih enačb, razen pri enojajčnih dvojčkih ali klonih
- pričakovano vrednost poznamo ( $= 0$ ) in tako ne porabimo stopinj prostosti

## Povzetek

	Dnevni prirast	Debelina hrbtne slanine
Število opazovanj	11	17
Število parametrov za sistematske vplive	60	108
Število gnezd	7	7
Število živali	16	16
Red sistema	$60+7+16 = 83$	$60+48+7+16 = 131$
Rang sistema	$24+7+16 = 47$	$24+48+7+16 = 95$

- Model ima več parametrov kot opazovanj (overparameterization)
  - zato ni dober za to količino podatkov
  - hočemo vedeti veliko več, kot smo zbrali informacij
  - lokacijskih parametrov mora biti veliko manj kot podatkov, da je model primeren
- Za smiselno obdelavo podatkov potrebujemo veliko več podatkov