

LINEÁRNÍ REGRESE — POKRAČ.

23.11.2012

ÚVODNÍ NASTAVENÍ.

- Otevřete si R Studio. Z internetu si stáhněte data **olympics.csv** a **blood.csv**.

POLYNOMIÁLNÍ REGRESE

1. Načtěte si data **olympics.csv**. Datový soubor obsahuje výsledky zlatých medialistů z letních olympiád od roku 1896 ve skoku do výšky, do dálky a hod diskem.

Year rok (počítáno od 1900)
Long.Jump skok daleký (v inch)
High.Jump skok vysoký (v inch)
Discus hod diskem (v inch)

Bude nás zajímat, jakým způsobem se výkony na olympiádě mění v čase.

2. Převed'te skok do výšky a skok do dálky na centimetry a hod diskem na metry.
3. Prohlédněte si vývoj každé z disciplín v čase zvlášť. Zdá se být závislost na čase lineární?
4. Podíváme se na skok do výšky.

- (a) Odhadněte model regresní přímky.

```
m1=lm(High.Jump~Year)
summary(m1)
```

- (b) Připomeňte si interpretaci jednotlivých parametrů a koeficientu determinace.
- (c) Proložení přímkou si znázorníme graficky:

```
plot(High.Jump~Year,pch=19)
lines(fitted(m1)~Year,col="red")
```

- (d) Zkusíme uvažovat kvadratickou závislost na čase.

```
m2=lm(High.Jump~Year+I(Year^2))
summary(m2)
```

Přináší zapojení kvadratického členu významné zlepšení? Jak se změnil koeficient determinace?

- (e) Obě proložení si znázorníme do jednoho obrázku:

```
plot(High.Jump~Year,pch=19)
lines(fitted(m1)~Year,col="red")
lines(fitted(m2)~Year,col="blue")
```

Který model bychom zvolili?

- (f) Na základě obou modelů předpovězte výkon ve skoku do výšky na olympiádě v Sydney.

(g) Zkuste se sami podívat, zda by zapojení vyšší mocniny (polynomu třetího stupně) přineslo významné zlepšení.

5. Ještě se podíváme (neformálně) na předpoklady lineární regrese v lineárním i kvadratickém modelu.

```
r=resid(m1)

library(car)
qqPlot(r,dist="norm")

plot(r,type="b")

plot(r~fitted(m1))
```

Proveďte totéž pro kvadratický model.

6. Podívejte se samostatně na skok do dálky: Opět uvažujte lineární a kvadratickou (příp. složitější) závislost a na základě nejlepšího modelu předpovězte výkon na olympiadě v Sydney.

VÍCENÁSOBNÝ REGRESE

1. Načtěte si data **blood.csv**. Datový soubor obsahuje informace o 11 pacientech: výši jejich systolického krevního tlaku, věk a hmotnost.

systolic	systolický krevní tlak
age	věk v letech
weight	hmotnost (v librách)

2. Převeděte hmotnost pacientů na kilogramy.

3. Zajímá nás, jak závisí výše krevního tlaku na věku a hmotnosti.

(a) Prohlédněte si závislost (graf) výše systolického tlaku na věku a hmotnosti zvlášť.

(b) Odhadneme model, ve kterém bude závislost systolického tlaku na obou veličinách:

```
m=lm(systolic~age+weight)
summary(m)
```

Jak budeme interpretovat odhadnuté parametry? Závisí systolický tlak na věku i hmotnosti?

(c) Kdybychom chtěli dostat interpretaci i pro absolutní člen, můžeme si posunout obě proměnné např. do jejich průměrné hodnoty

```
m=lm(systolic~I(age-mean(age))+I(weight-mean(weight)))
summary(m)
```

(d) Předpovězte výši systolického tlaku pro 50 letého pacienta, který váží 90 kg.