

Základy lineární regrese

12. 1. 2012

Úvodní nastavení. Budeme pracovat s daty `ojetiny.dat` (stáhněte si je z internetu). Spusťte si R Commander (`Packages→Load Package→Rcmdr`), změňte si svůj pracovní adresář (`File→Change working directory`) a načtěte si do R data `ojetiny.dat` (`Data→Import Data→from text file, clipboard or URL`).

Popis dat: Soubor obsahuje data o cenách náhodně vybraných ojetých automobilů. Pro každý automobil máme k dispozici informaci o ceně, počtu najetých kilometrů a stáří. Proměnné v datech:

`cena` cena v tis. Kč,
`stari` stáří automobilu (v měsících)
`najeto` počet najetých km (v tis.)

1. Pomocí vhodných charakteristik a obrázků popište zkoumaná data.
2. Popište vztah mezi cenou automobilu a počtem najetých kilometrů pomocí vhodného obrázku. Interpretujte tvar závislosti. Spočtěte také vhodnou číselnou charakteristiku.
3. Popište vztah mezi cenou automobilu a jeho stářím pomocí vhodného obrázku. Interpretujte tvar závislosti. Spočtěte také vhodnou číselnou charakteristiku.
4. Uvažujte model lineární závislosti ceny vozu na počtu najetých kilometrů, tj. model regresní přímky.
 - (a) Napište rovnici modelu a vysvětlete jej.
 - (b) Odhadněte parametry uvažovaného modelu.

`Statistics→Fit models →Linear regression`. Zde vhodně zvolte závislou a nezávislou proměnnou.

- (c) Prohlédněte si dobře výstup z R. Napište rovnici odhadnutého modelu. Diskutujte statistickou významnost jednotlivých parametrů. Interpretujte.
- (d) Jaké je koeficient determinace R^2 tohoto modelu? Co nám tato hodnota vyjadřuje?
- (e) Jaké jsou předpoklady lineární regrese? Jsou v našem případě splněny (ověřte graficky)?

`Models →Graphs →Basic diagnostic plots`

Je lineární závislost (přímka) dostačující pro popsání studovaného vztahu?

5. Rozšířme předchozí model o kvadratický člen, tj. uvažujme kvadratickou závislost ceny na počtu najetých kilometrů.
 - (a) Napište rovnici modelu.

- (b) Odhadněte parametry tohoto modelu.

Statistics→**Fit models** →**Linear model**. Zde zadejte model
 $cena \sim najeto + I(najeto^2)$

- (c) Napište rovnici odhadnutého modelu.
(d) Podívejte se na statistickou významnost jednotlivých parametrů. Speciálně se zaměřte na koeficient kvadratického členu. Interpretujte.
(e) Jak se změnilo R^2 ? Dala se tato změna očekávat?
(f) Posudte splnění předpokladů pomocí vhodných obrázků.
(g) Který z uvažovaných dvou modelů je „lepší“ a proč?
Odhadněte na základě toho lepšího typickou cenu automobilu s 30 000 najetými km.

6. Uvažujme navíc v modelu i lineární závislost ceny na stáří vozu.

- (a) Napište rovnici modelu.
(b) Opět odhadněte koeficienty v tomto modelu.

Statistics→**Fit models** →**Linear model**. Zde zadejte model
 $cena \sim najeto + I(najeto^2) + stari$

- (c) Závisí cena automobilu na jeho stáří (uvažujeme-li kvadratickou závislost na najetých km)?
(d) Na základě uvažovaného modelu odhadněte cenu 1 rok starého automobilu s 30tis najetými km.