

## Aufgaben zur Kreuzvalidierung

- Wiederholen Sie die Modellselektion aus dem Beispiel mit leave-one-out Kreuzvalidierung!
- Überlegen Sie hierzu, wie systematisch die nötigen Trainings- und Testdatensätze erzeugt werden können.
- Für jede Aufteilung muss das Modell neu geschätzt werden und für den jeweils ausgelassenen Punkt eine Prognose erstellt werden.
- Schließlich müssen die so gewonnenen Prognosefehler gemittelt werden.
- Lösung hier.

## Modellselektion mittels leave-one-out CV und Prognosefehler

```
prognosefehler <- rep(NA, length(xdata))
for (leftout in 1:length(xdata))
{
  training <- seq(1,length(xdata))[-leftout]
  x <- xdata[training]
  y <- ydata[training]
  test <- leftout
  prognosefehler[leftout] <-
    (predict(lm(y ~ x), data.frame(x=xdata[test])) -
     ydata[test])^2
}
cat("Mittlerer quadratischer Prognosefehler",
    mean(prognosefehler))
```

```
## linear lm(y ~ x)
Mittlerer quadratischer Prognosefehler 7.454557
### quadratisch lm(y ~ x + I(x^2))
Mittlerer quadratischer Prognosefehler 6.947941
### kubisch lm(y ~ x + I(x^2) + I(x^3))
Mittlerer quadratischer Prognosefehler 6.468842
### 4. Grades lm(y ~ x + I(x^2) + I(x^3) + I(x^4))
Mittlerer quadratischer Prognosefehler 18.53203
```

## Resampling und Hypothesentests

- Literatur: Introduction to the Bootstrap World, D.D. Boos, Statistical Science , 2003, Vol 18, No 2, 168-174
- Sowohl der Bootstrap als auch der Jackknife sind verteilungsunabhängige Verfahren.
- Mit beiden können über die Resampling Stichproben prinzipiell beliebige Statistiken und ihre Standardfehler geschätzt werden.
- Ein Spezialfall ist allerdings das Testen von Hypothesen und damit verbunden das Herleiten von empirischen p-Werten über Resampling.
- Der Fallstrick beim Resampling von p-Werten liegt in der entscheidenden Voraussetzung des Testens: Die Stichproben müssen unter der Nullhypothese  $H_0$  gezogen werden!

## Beispiel Bootstrap-Test

- Angenommen man hat zwei unabhängige Stichproben  $X_1, \dots, X_m$  und  $Y_1, \dots, Y_n$  und möchte die Differenz der Mittelwerte der beiden Stichproben  $\mu_X - \mu_Y$  gegen Gleichheit testen.
- Für ein nicht-parametrisches Konfidenzintervall zöge man einfach Stichproben mit Zurücklegen gemäß der empirischen Verteilungsfunktionen von  $X$  und  $Y$ .
- Testet man aber die Hypothese  $H_0 : \mu_X - \mu_y = 0$  aus Bootstrap-Stichproben, z.B. über die gepoolte t-Statistik

$$t_p = \frac{(\bar{X} - \bar{Y})}{\sqrt{s_p^2 \left( \frac{1}{m} + \frac{1}{n} \right)}}$$

wobei

$$s_p^2 = \frac{(m-1)s_X^2 + (n-1)s_Y^2}{m+n-2}$$

und  $S_X^2, S_Y^2$  die üblichen erwartungstreuen Varianzschätzer der beiden Stichproben  $X$  und  $Y$ , so wird die Bedingung der Nullhypothese, nämlich übereinstimmende Mittelwerte, in der Regel nicht eingehalten!

- Um eine zulässige Resampling-Methode für Hypothesentests zu erhalten, muss also eine Methode gefunden werden, um Stichproben unter der gültigen Nullhypothese zu generieren.
- Eine Möglichkeit wäre ein Bootstrapping von Stichproben  $X^*$  vom Umfang  $m$  und  $Y^*$  vom Umfang  $n$  aus der gepoolten Stichprobe  $(X_1, \dots, X_m, Y_1, \dots, Y_m)$ .
- Das Zusammenfassen der Teilstichproben erzwingt die unabhängig iden-

tische Verteilung aller Beobachtungen der Stichproben  $X^*$  und  $Y^*$ !

- Tatsächlich würden so sogar Stichproben unter der viel strengeren Nullhypothese  $F_X = F_Y$  gezogen!
- Eine elegante Formulierung für Tests unter dieser Nullhypothese bilden die sogenannten Permutationstests, die im weiteren Verlauf der Veranstaltung vorgestellt werden.
- Tatsächlich lässt sich aber auch ein Bootstrap-Test formulieren, der nur auf der deutlich schwächeren Annahme  $H_0 : \mu_X = \mu_Y$  beruht!
- Es ist also immer wichtig, exakt zu überlegen, welche Hypothese und welche Alternative man trennen möchte!

- Der Zweistichproben-Welchtest mit der Teststatistik

$$t_W = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{s_X^2}{m} + \frac{s_Y^2}{n}}}$$

beispielsweise wäre für diese Hypothese angemessen, wenn nichts weiter als die Existenz der zweiten Momente der Stichprobenverteilungen vorausgesetzt wird.

- Das adäquate Bootstrapverfahren unter der Nullhypothese würde dann getrennte (Bootstrap-)Stichproben aus  $(X_1 - \bar{X}, X_2 - \bar{X}, \dots, X_m - \bar{X})$  und  $(Y_1 - \bar{Y}, Y_2 - \bar{Y}, \dots, Y_n - \bar{Y})$  erzeugen und wiederholt die Teststatistik berechnen.
- Aus diesem Prinzip konstruierte Tests heißen auch Monte-Carlo Tests.



## Der Bootstrap p-Wert

- Angenommen  $T_0$  ist der Wert einer Teststatistik aus einer gegebenen Stichprobe. Dann ist  $P(T > T_0 | H_0)$  die Definition des p-Wertes für eine Nullhypothese, bei der große Werte von  $T$  gegen die Hypothese sprechen. (Achtung: Wie bei normalen Tests ist die Formulierung wichtig!)
- Ist die Verteilung von  $T$  eine diskrete Gleichverteilung auf  $k$  möglichen Ausprägungen  $t_1, \dots, t_k$ , so ist der p-Wert genau der Anteil der  $t_i \geq T_0$ .
- Entsprechend, wenn man die diskreten Realisierungen  $T_i^*$  von  $T$  der nicht-parametrischen Bootstrapstichproben unter  $H_0$  betrachtet, kann

man den Bootstrap-p-Wert definieren als

$$p_B = \frac{\text{Anz. } T_i^* \geq T_0}{\text{Anz. Replikationen } (=: B)}.$$

- In der Literatur findet sich manchmal auch die Definition

$$p_B = \frac{\text{Anz. } T_i^* \geq T_0 + 1}{B + 1}.$$

Mit wachsender Replikationszahl verschwinden die Unterschiede der Definitionen.

- Im Falle des parametrischen Bootstrap aus einer stetigen Verteilung ist die Voraussetzung der diskreten Gleichverteilung der  $T_i^*$  sogar exakt erfüllt!

- Der p-Wert  $p_B$  ist in diesem Falle exakt diskret gleichverteilt auf den Werten  $\{0, \frac{1}{B}, \frac{2}{B}, \dots, \frac{B}{B}\}$ , weshalb gilt, dass das Niveau  $\alpha$  des Tests exakt eingehalten wird, wenn  $(B + 1)\alpha \in \mathcal{Z}$  gilt.
- Dies gilt, da unter der Nullhypothese  $T_0, T_1^*, \dots, T_B^*$  i.i.d. sind und deshalb jede der  $(B+1)!$  Permutationen dieser Werte gleichwahrscheinlich ist.
- Aus diesem Grund ist es geschickt  $B$  so zu wählen, dass die Ganzzahligkeit von  $\alpha(B + 1)$  gegen ist.
- Beispiel:  $\alpha = 0.05$ ,  $B = 19, 39$  oder  $99$ .
- Die asymptotische Zulässigkeit dieses Verfahrens auch für den parametrischen Bootstrap wurde ebenfalls untersucht. (Hall 1986)

- Was die Konvergenz der so simulierten p-Werte betrifft, so gibt es Resultate, die unter erträglich strengen Regularitätsbedingungen die asymptotische Gleichverteilung der p-Werte zeigen. Insgesamt scheint die Verwendung von Bootstrap-p-Werten angemessen, wenn man im Hinterkopf behält, dass es sich nicht um exakte p-Werte handelt!