

Τετάρτη 03/03/2018

Έλεγχος κριτής προσαρμογής:

Έστω δείγματα X_1, \dots, X_n από κάποια (γνωστή) κατανομή $f(x)$.
Το ερώτημα που θέλουμε να απαντησουμε είναι αν το δείγμα προέρχεται από την δοθείσα κατανομή $f(x, \theta)$.

Έλεγχος της υπόθεσης: $H_0: f(x) = f(x, \theta)$ έναντι $H_1: f(x) \neq f(x, \theta)$.
• Μετράμε την απόσταση μεταξύ $f(x)$ και $f(x, \theta)$ και εστιάσαμε ένα κριτήριο με το οποίο θα αποφασίσουμε την σύγκριση με $f(x, \theta)$ στην περίπτωση $f(x)$.

Η $f(x, \theta)$ θεωρείται δεδομένη, στο H_0 είναι $f(x)$ γνωστή, ενώ είναι στο H_1 ως $f(x)$ προσδιορίζεται από εκτίμησή μας.

[η χρήση διασποράς εκτίμησή μας σε διασπορικό στατιστικό test.]
[Είρων μπορούμε να προσδιορίσουμε διασπορικές μετρήσεις για την απόσταση μεταξύ $f(x)$ και $f(x, \theta)$.]

Οι κρίσιμες του εκτίμησή μας χρησιμοποιούμε και ο τύπος της μετρικής που χρησιμοποιούμε καθορίζει τις στατιστικές κρίσιμες του test:

Το σημαντικότερο είναι η στατιστική συνάρτηση συνάρτηση να είναι πάντα χ^2 όπως πάντα φέρνεται από τα δεδομένα.

Συν χ^2 η στατ. συνάρτηση έχει κατανομή η οποία είναι διασπορική ανάλογα με τον αριθμό μετρήσεων, εκτίμησή μας $f(x)$ και της $f(x, \theta)$.

Η κατανομή μας χρησιμοποιείται για να θεσπίσουμε το κριτήριο απόδοσης της υπόθεσης.

Άλλοι τύποι με σ.σ. αντιστοιχούν ανώτερη απόδοσης με $f(x)$ με $f(x, \theta)$.
Όταν θα ισχύει χ^2 μικρότερη υπόθεση περιλαμβάνεται η τιμή του στατιστικού να είναι κοντά στο 0.

Πιο σίγουρα απορρίπτει ότι η τιμή του στατιστικού που μπορεί να είναι του δοθέντος δείκτητος προέρχεται όπως από την κατανομή του χαρακτηριστικού υπό την H_0 αν είναι μέγα στο $(1-\alpha)\%$ της τιμής της κατανομής των τιμών του στατιστικού.

Το α καθορίζει τα εξής όρια:

- όταν η τιμή του στατιστικού ανήκει στο $(1-\alpha)\%$ των άριων τιμών της κατανομής του στατιστικού τότε δεν απορρ. την H_0 .
- αντίθετα αν παίρνει τιμή εκτός των $(1-\alpha)\%$ απορρ. την H_0 .

Στην γενική περίπτωση αν η κατανομή της $\sigma-\sigma$ $T(x)$ υπό την H_0 έχει ποσοστιαία σημεία $-q_\alpha, q_\alpha$, δηλαδή στο διάστημα $(-q_\alpha, q_\alpha)$ περιλαμβάνει το $100(1-\alpha)\%$ των τιμών της $T(x)$ τότε ισχύει: $1-\alpha = P(-q_\alpha < T(x) < q_\alpha)$ (1)

Το επίπεδο σημαντικότητας: όπως ορίζεται από τον (1) είναι η πιθανότητα να παρατηρηθεί τιμή του στατιστικού μεγαλύτερη από αυτή που έχουμε το δείγμα των παρατηρήσεων.
'Η ισοδυναμεί το α καθορίζει το μέγεθος του πλίκου που είναι αρκετά διαφορετικοί να δεχτούμε για απορρ. ή αποδοχή της H_0 .

Έλεγχος Καλής Προσαρμογής: Kolmogorov-Smirnov

Βασίζεται στην μέτρηση της απόστασης μεταξύ $F(x)$ και $F(x, \theta)$
λέγεται της μετρικής $D = \sup_{x \in \mathbb{R}} |F(x) - F(x, \theta)|$

Βασικά Χαρακτηριστικά Tests

- $F(x, \theta)$ είναι πλήρως προσδιορισμένη συν. η τιμή της παρατηρούμενης
- Δεν έχει προκύψει από εκτίμηση μέσω του δείγματος, συν. είναι η ίδια ανεξάρτητα με το δείγμα που έχουμε για να αναλύσουμε τα δεδομένα.

Δ Η $F(x)$ εκτιμάται από την εμπειρική της α.σ.κ.

Δ Η εμπειρική και γραμμικοποιούμε για την αντιστοίχια μετρήσι του $F(x)$.
και $F(x, \theta)$ είναι η sup norm

$D_n = \sup_{x \in \mathcal{X}} |F_n(x) - F(x, \theta)|$, τ.λ. \exists $\epsilon > 0$ υπάρχει n_0 τέτοιο ώστε για κάθε $n > n_0$ υπάρχει θ_n τέτοιο ώστε $D_n(\theta_n) < \epsilon$.
Σε δεξιό, θ_n αλλάζει κάθε φορά που λες n αλλά θ_n $\rightarrow \theta$.

Για να προσεγγίσουμε να γραμμικοποιούμε την D_n πρέπει να προσεγγίσουμε την κατανομή της.

αν $\theta \in \mathbb{R}^p, p \geq 1$ τ.λ. η κατανομή του test αλλάζει θ $\rightarrow \theta + \delta$.

Ένας απλός τρόπος για να εκτιμήσουμε την κατανομή του test είναι να υπολογίσουμε τις n τιμές του test και να προσεγγίσουμε το ισόγραμμα για να εκτιμήσουμε την α.σ.κ.

π.χ) $\theta = 0$ από αστική κανονική κατανομή.

```
require(graphics)
```

```
n <- 1000
```

```
TestVals <- vector(length=n, mode="numeric")
```

```
set.seed(4)
```

```
for(i in 1:n)
```

```
{
```

```
  x <- rnorm(100)
```

```
  TestVals[i] <- ks.test(x, "pnorm")$statistic
```

```
}
```

```
hist(TestVals, freq=F)
```

```
lines(density(TestVals), col=2)
```

"ΝΕΝ ΠΡΕΠΕΙ ΝΑ ΠΑΡΑΒΙΑΖΟΥΜΕ ΤΟΝ ΚΑΝΟΝΑ ΟΤΙ ΟΙ ΠΑΡΑΜΕΤΡΟΙ ΤΗΣ ΚΑΤΑΝΟΜΗΣ ΠΡΕΠΕΙ ΝΑ ΕΙΝΑΙ ΣΤΑΘΕΡΟΙ ΑΡΙΘΜΟΙ!!"

Test Cramer-von Mises:

Αν ορίζουμε $F(x)$ ως την συνάρτηση κατανομής της X και $F(x; \theta)$ ως την θεωρητική συνάρτηση κατανομής της X τότε η συνάρτηση W ορίζεται ως:

$$W = \int \{F(x) - F(x; \theta)\}^2 dF(x)$$

Η τιμή του W είναι πάντα μη αρνητική και η τιμή της W είναι μικρότερη όταν η θεωρητική συνάρτηση κατανομής $F(x; \theta)$ ταιριάζει καλύτερα με την πραγματική συνάρτηση κατανομής $F(x)$.

Αν $F(x)$ είναι η πραγματική συνάρτηση κατανομής και $F(x; \theta)$ είναι η θεωρητική συνάρτηση κατανομής τότε η τιμή του W είναι:

$$\hat{W} = \int \{F(x) - F(x; \theta)\}^2 dF(x; \theta)$$

Η τιμή του \hat{W} είναι πάντα μη αρνητική και η τιμή της \hat{W} είναι μικρότερη όταν η θεωρητική συνάρτηση κατανομής $F(x; \theta)$ ταιριάζει καλύτερα με την πραγματική συνάρτηση κατανομής $F(x)$.

Αν X_1, X_2, \dots, X_n είναι n ανεξάρτητα και ομοειδή τυχαία μεγέθη με κατανομή $F(x)$ τότε η τιμή του \hat{W} είναι:

$$\hat{F}(X_i) = \frac{i}{n}, \quad i=1, \dots, n$$

$$\hat{W} = \sum_{i=1}^n \left\{ \frac{2i-1}{2n} - F(X_i; \theta) \right\}^2 \cdot \frac{1}{2n}$$

Test Anderson-Darling

βασίζεται στην ελαφρώς τροποποιημένη μετρική L₂.

$$A = n \int \{F(x) - F(x|\theta)\}^2 w(x) dF(x)$$

H $w(x)$ είναι μια δεικτική συνάρτηση βάρους στατιστική από την $f(x)$
αν $w(x) = 1$ έχουμε το test: Gramer-von Mises.

Το test του Anderson-Darling προκύπτει από την A θέτοντας
 $w(x) = (F(x)(1-F(x)))^{-1}$.

$$A = n \int \frac{\{F(x) - F(x|\theta)\}^2}{F(x)(1-F(x))} dF(x).$$

Αντισymmetrically το $w(x)$ δίνει μεγαλύτερο βάρος στις παρατηρήσεις
στις άκρες (όπως της κατανομής).

H A δεν μπορεί να προσκομιστεί στο πρόβλημα γιατί απαιτείται την
γνωστή $F(x)$ εκτός αν προσκομιστούμε την $\hat{F}(x)$ προκύπτει
η εκτίμηση \hat{A} , της A

$$\hat{A} = \sum_{i=1}^n \frac{2i-1}{n} \left[\ln(F(x_i, \theta)) + \ln\{1 - F(x_{n+1-i}, \theta)\} \right]$$