

Sztoczasztikus rendszerek matematikája

4. gyakorlat

2017. október 24. kedd: 2-4; 4-6 és október 26. csütörtök: 2-4

[A] Főkomponenanalízis

[B] Idősorelemzés

[A] Főkomponenanalízis

A főkomponens analízis esetén a p dimenziós megfigyeléseket az első q score alapján közelítjük. Az ortogonális *score mátrixot* a változónként standardizált adatokból a megfigyelések korreláció mátrixának egység hosszú sajátvektoraiból alkotott *loading mátrixszal* transzformálva kaphatjuk meg. A szkórok alapján vett közelítés jóságát a felhasznált sajátértékek aránya méri.

A főkomponens analízis lépései

- a minta legyen adott az $n \times p$ méretű X adatmátrix
- legyen a p dimenziós a vektor az adatok változónkénti átlaga
- legyen X_0 az adatok centrált változata, ekkor az X_0 minden oszlopának az átlaga 0
- állapítsuk meg a minta kovariancia mátrixát: $V = X_0^T X_0 / n$
- a kovariancia mátrix alapján az adatok variancia vektora $s^2 = \text{diag}(V)$
- vegyük az adatok korreláció mátrixát $R = \text{diag}(s^{-1}) V \text{diag}(s^{-1})$
 - legyen a p dimenziós λ vektor csökkenő sorrendben a korreláció mátrix sajátértékei, és $L = (L_1, \dots, L_p)$ a megfelelő $n \times p$ méretű, egység hosszú sajátvektorokból álló mátrix.
- az $R = \sum_{k=1}^p \lambda_k L_k L_k^T$, az $L^T L = L L^T = I$ és az $\|R\|^2 = \|\lambda\|^2$,
- az $R_{(1, \dots, q)} = \sum_{k=1}^q \lambda_k L_k L_k^T$ az R közelítése: $\|R - R_q\| = \sum_{k=q+1}^p \lambda_k^2$
- a $n \times p$ méretű $S = X_0 \cdot \text{diag}(1/s) \cdot L$ mátrix a p ortogonális főkomponens szkór
- szkórok 0 átlagúak, ortogonálisak: $X_0^T X_0 = I$, a varianciáikból álló vektor a λ
- a szkórokból az $S \cdot L^T \cdot \text{diag}(s) = X_0$ transzformációval adódik az X_0 centrált adatmátrix
- ha $S_{(1, \dots, q)}$ az S -nek, $L_{(1, \dots, q)}$ pedig az L -nek az első q oszlopa,
 - akkor az $n \times p$ méretű $X_{(1, \dots, q)} = S_{(1, \dots, q)} \cdot L_{(1, \dots, q)}^T \cdot \text{diag}(s)$ az X_0 közelítése, ahol a közelítés hibája $\|(X_0 - X_{(1, \dots, q)}) \cdot \text{diag}(1/s)\|^2 / n = \sum_{k=q+1}^p \lambda_k$
- vagyis az $X_{(1, \dots, q)}$ közelítés jóságát a $\sum_{k=1}^q \lambda_k / \sum_{k=1}^p \lambda_k$ arány méri

[B] Idősorelemzés

Legyenek x_1, \dots, x_T a ξ_1, \dots, ξ_T megfigyelt változósorozat értékei.

Tételezzük fel, hogy az adatok a

$$x_t = (a + bt) \cdot s_t \cdot e_t \quad t = 1, \dots, T$$

három komponensű multiplikatív modellnek megfelelően épülnek fel, ahol az e_t a független 1 várhatóértékű, azonos szórású ε_t , $t = 1, \dots, T$ zajsorozat értékei. A modellben a és b két fix, ismeretlen valós szám, ezek határozzák meg a folyamat lineáris trendjét. Az s_t szezonális komponens p darab, szintén ismeretlen, c_1, \dots, c_p valós szám periódikus ismétlődése.

Vagyis a modell szerint a folyamat értékei az $a + bt$ lineáris trendtől

determinisztikusan a p periódushosszú multiplikatív s_t szezonális trend szerint

véletlenszerűen pedig szintén multiplikatíven a független ε_t folyamat szerint

térnek el. A modell additív változata szerint: $x_t = (a + bt) + s_t + e_t$, és az ε_t várhatóértéke 0.

A multiplikatív modell paramétereinek becslés módszere

A modell elemeit a következő sorrendben becsüljük meg:

először készítünk hosszú simítással egy nyers becslést az adatok $a + bt$ trendjére;

a nyers trend alapján előbecslést kapunk az s_t szezonális trendre;

az s_t szezonális trend fázisonkénti értékét az előbecslés fázisonkénti átlagával becsüljük;

az így nyert fázisátlagok periódikus ismétlése az s_t szezonális trend végső becslése: \hat{s}_t ;

az \hat{s}_t alapján előbecslést készítünk a folyamat lineáris trendjének értékeire;

az előbecsült trendértékek idő szerinti lineáris regressziója adja a folyamat lineáris trendjét;

a $\hat{a} + \hat{b}t$ lineáris és \hat{s}_t szezonális trend alapján becslés adódik a folyamat hibatagjára;

a becsült hibatagok alapján a véletlen hiba szórását becsülhetjük.

A modell illesztés és előrejelzés műveletei és paramétere

Összesen 16 negyedéves adat áll rendelkezésre.

A folyamat periódushossza 4 és 4 havi előrejelzést kell készíteni.

A nyers trendet egy $\text{MA}(2) \otimes \text{MA}(4) = (1, 2, 2, 2, 1)/8$ simítás állítja elő.

A megfigyelések és a nyers trend hányadosa a szezonális trend előbecslése.

A szezonális trend előbecslésének fázisonkénti átlagai adják a ciklikus trend periódusát.

Az eredeti megfigyelések és a ciklikus trend hányadosa a lineáris trend előbecslése.

A lineáris trend a lineáris trend előbecslésének az időpontok szerinti lineáris regressziója.

A folyamat előrejelzése a becsült lineáris trend és ciklikus komponens adott időpontbeli értéke.