

Detekce více změn v sezónním chování průtokových řad



HANA HORÁKOVÁ
DANIELA JARUŠKOVÁ

Úvod



- Cílem naší práce je detekce změn v sezónním chování průtokových řad. Předpokládejme, že data jsou **denní průměrné průtoky** a **roční chod** je tedy dán vektorem, jehož složky odpovídají denním průměrným průtokům v jednotlivých kalendářních dnech. Změna v sezónním chování odpovídá změně střední hodnoty **vektoru o 365 souřadnicích**. Detekce takovéto změny je však velmi obtížná, neboť bychom pro její odhalení potřebovali data z období pokrývající mnoho let.
- *Naší snahou bylo sezónní chování charakterizovat vektory s výrazně méně souřadnicemi.*

Úvod



- Navrhli jsme použít tři metody. První metoda spočívá v charakterizaci sezónního chování pomocí **měsíčních průměrných průtoků**. Druhá metoda je založena na proložení řady lineární kombinací sinů a kosinů s **nejmenšími Fourierovými frekvencemi**. Sezónní chování je pak charakterizováno Fourierovými koeficienty. Třetí metoda spočívá v nahrazení vektoru o 365 souřadnicích vektorem, jehož složky jsou lineární kombinací složek původních vektorů s největšími rozptyly. Tato metoda je známá pod názvem **metoda hlavních komponent**.

Úvod



- V druhé a třetí metodě je třeba subjektivně volit délku studovaných vektorů. Pro srovnání s metodou průměrných měsíčních průtoků jsme obvykle volili délku vektoru 12.
- Popsaným způsobem je úloha detekování změny v sezónním chování řady převedena na statistickou úlohu **detekce změny střední hodnoty vektoru o p souřadnicích**.

TEST PRO DETEKCI JEDNÉ ZMĚNY VE STŘEDNÍ HODNOTĚ NÁHODNÉHO VEKTORU



- Předpokládáme-li, že v řadě došlo maximálně k jedné změně, pak můžeme definovat nulovou hypotézu a odpovídající alternativu A následovně:

$$\begin{aligned} H_0: \mu_1 = \dots = \mu_N, i = 1, \dots, N \\ A: \exists k^* \in \{1, \dots, N - 1\} \text{ takové, že} \\ \mu_1 = \dots = \mu_{k^*}, \\ \mu_{k^*+1} = \dots = \mu_N, \text{ kde } \mu_{k^*} \neq \mu_{k^*+1}. \end{aligned}$$

Testová statistika



$$U(\beta) = \max_{|\beta N| \leq k \leq N - |\beta N|} \frac{k(N-k)}{N} (\bar{\mathbf{X}}_k^* - \bar{\mathbf{X}}_k^{**})^T \hat{\Sigma}^{-1} (\bar{\mathbf{X}}_k^* - \bar{\mathbf{X}}_k^{**}), \text{ kde}$$


$$\bar{\mathbf{X}}_k^* = \frac{1}{k} \sum_{i=1}^k \mathbf{X}_i, \quad \bar{\mathbf{X}}_k^{**} = \frac{1}{(N-k)} \sum_{i=k+1}^N \mathbf{X}_i,$$

$$\hat{\Sigma} = \frac{1}{N} \left\{ \sum_{i=1}^N (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})^T \right\}.$$




- Pokud došlo ke změně ve střední hodnotě náhodného vektoru, pak statistika $U(\beta)$ nabývá velkých hodnot. Najít přesnou $\alpha \cdot 100\%$ kritickou hodnotu je však velmi obtížné. K nalezení přibližné kritické hodnoty se používá:
- *Bonferroniho nerovnost,*
- *asymptotické rozdělení,*
- *permutační princip.*

*Obr. 1: Průběh statistik pro změny Fourierových koeficientů
(Dunaj)*



Obr. 2: Průběh statistik pro změny koeficientů v metodě hlavních komponent (Dunaj)



TEST PRO DETEKCI DVOU ZMĚN VE STŘEDNÍ HODNOTĚ NÁHODNÉHO VEKTORU



- Pokud máme představu, ke kolika změnám v posloupnosti došlo, změníme testovací problém následovně

$$H_0: \mu_1 = \dots = \mu_N, i = 1, \dots, N$$

$$A: \exists k_1^* < k_2^* < \dots < k_d^* \text{ takové, že}$$

$$\mu_1 = \dots = \mu_{k_1^*},$$

$$\mu_{k_1^*+1} = \dots = \mu_{k_2^*},$$

...

$$\mu_{k_d^*+1} = \dots = \mu_N,$$

$$\text{kde } \mu_{k_1^*} \neq \mu_{k_1^*+1}, \mu_{k_2^*} \neq \mu_{k_2^*+1}, \dots, \mu_{k_d^*} \neq \mu_{k_d^*+1}$$

Testová statistika



Zavedeme-li částečné součty souřadnic jednotlivých vektorů

$$S_{ij} = \sum_{m=1}^i X_{mj}, \quad i = 1, \dots, N; j = 1, \dots, p,$$
$$U_j(k_1, k_2) = \frac{1}{\sqrt{k_1 k_2 (k_2 - k_1)}} (k_1 S_{k_2 j} - k_2 S_{k_1 j}),$$
$$U_j(k_2, N) = \frac{1}{\sqrt{k_2 N (N - k_2)}} (k_2 S_{N j} - N S_{k_2 j}),$$


pak testová statistika bude mít tvar maxima následující sumy, kde je maximum počítáno pro $k_1 \geq [\beta N]$, $k_2 - k_1 \geq [\beta N]$, $N - k_2 \geq [\beta N]$:

$$U_1^2(k_1, k_2) + U_2^2(k_2, N) + \dots + U_p^2(k_1, k_2) + U_p^2(k_2, N).$$




- Přibližné kritické hodnoty můžeme opět nalézt pomocí asymptotického rozdělení. Přibližné asymptotické kritické hodnoty lze odvodit pomocí postupu navrženého v článku (Antoch, Jarušková, 2013).
- Postup lze zobecnit i pro d změn.

Obr. 3: Průměrné měsíční průtoky Dunaje – 1901-1938(modrá čára),1939-2009 (červená čára).



Obr. 4: Průměrné měsíční průtoky Dunaje – 1901-1979(modrá čára),1980-2009 (červená čára).



Závěr



- Velmi často se stává, že se ve studované řadě vyskytuje více než jedna změna. V takovém případě se obvykle postupuje tak, že se řada rozštěpí v místě detekované změny a další změny se hledají v první a druhé části řady odděleně. Nicméně je zřejmé, že metody, které byly navrženy pro případ nejvýše jedné změny, ztrácejí sílu, a tedy schopnost detekce v případě, že je v řadě více změn. Z tohoto důvodu byly také navrženy metody pro detekci vícenásobných změn, které lze použít i při detekci změn sezónního chování řady. Samozřejmě s rostoucím počtem očekávaných změn roste i počet odhadovaných parametrů, což opět snižuje sílu testu. Zdá se tedy, že tyto metody je vhodné aplikovat pouze v případě velmi dlouhých řad.



- **DĚKUJI VÁM ZA POZORNOST**