

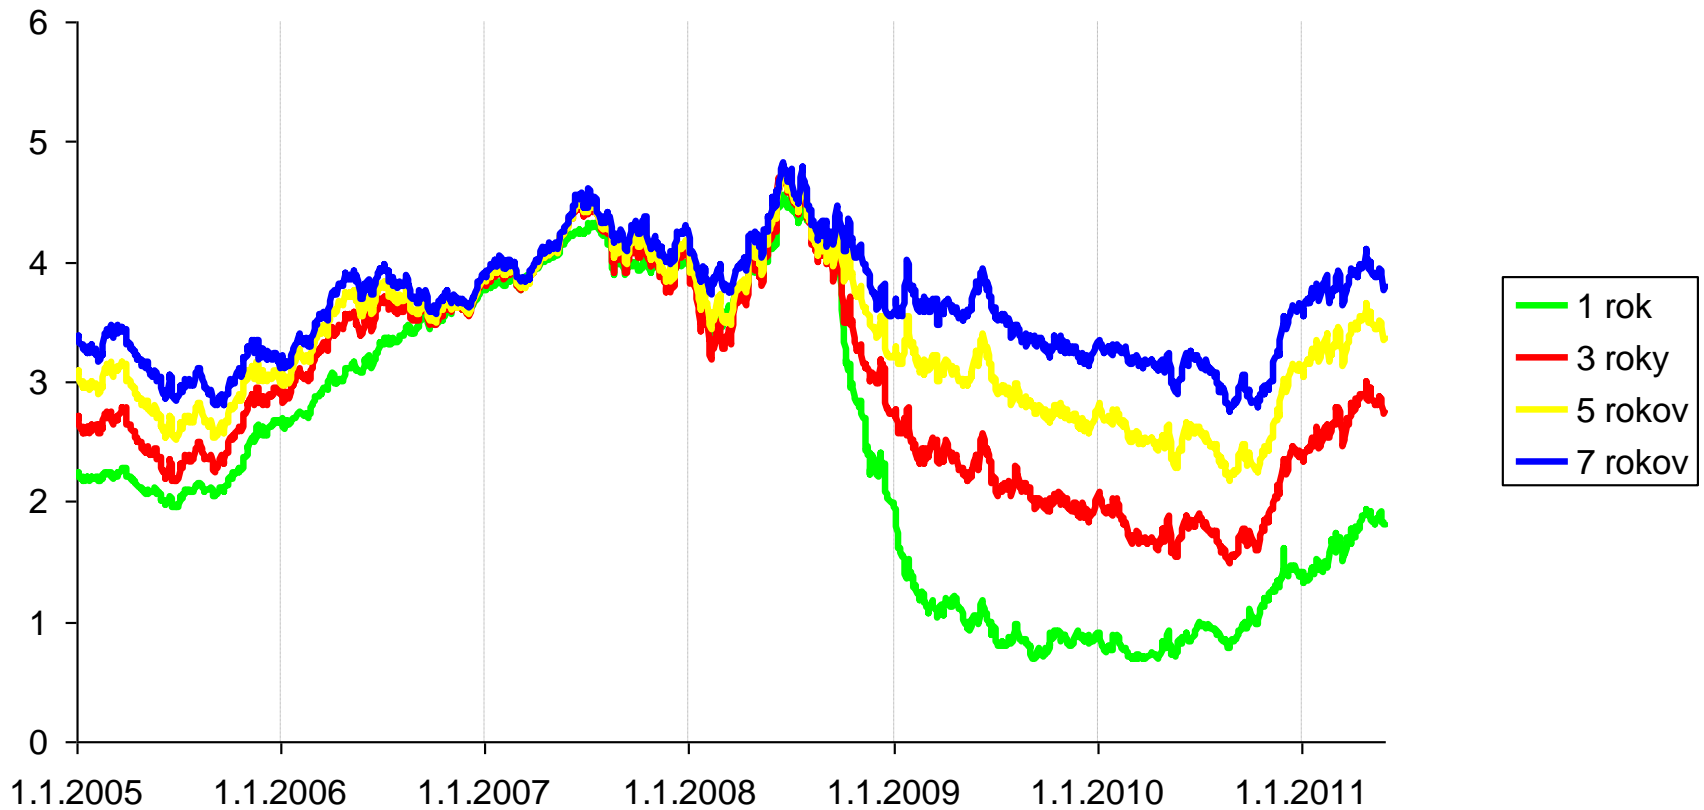
Analýza hlavných komponentov

Motivácia

- Úloha: Navrhnite scenáre zmien výnosovej krivky pre účely stresového testovania v dlhopisovom portfóliu
- Problém: Výnosová krivka sa skladá z väčšieho počtu bodov, v ktorých je vývoj čiastočne korelovaný

Motivácia

- Čo hovoria údaje:

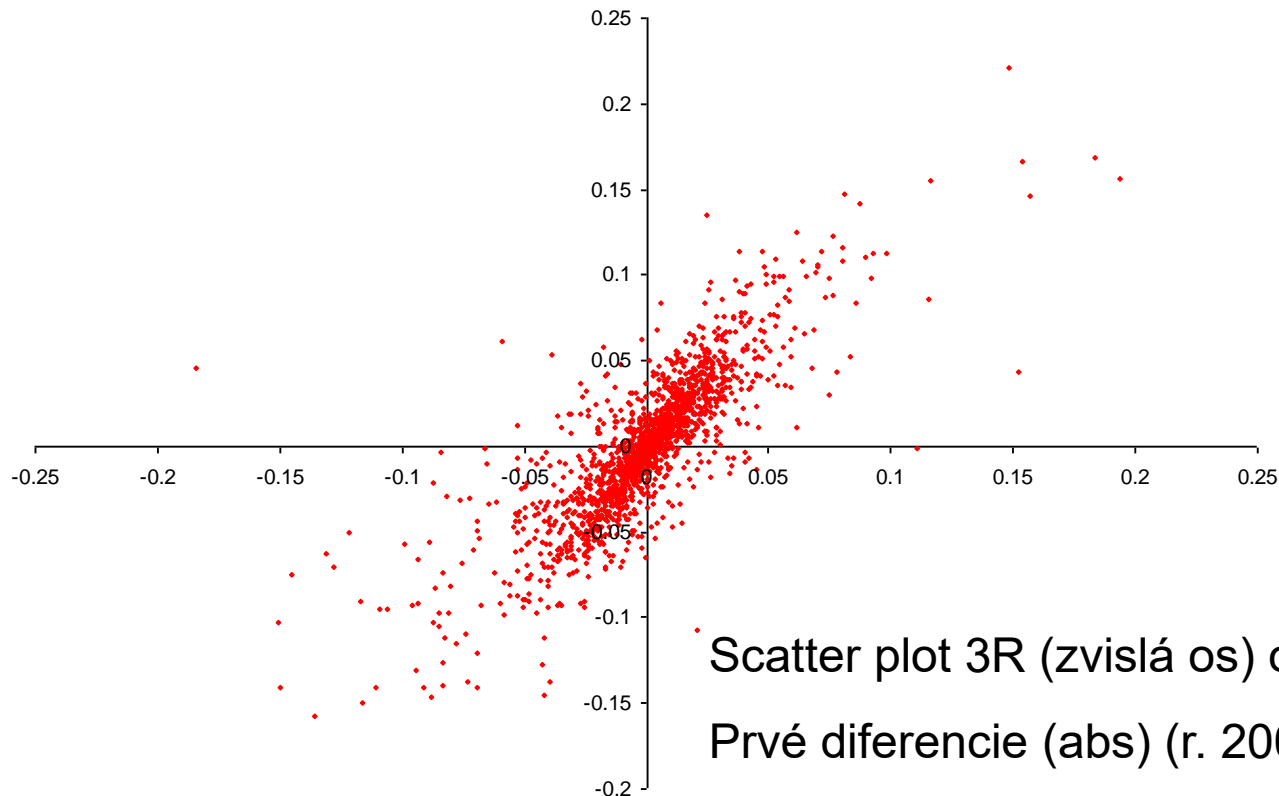


Motivácia

- Čo hovorí regulácia:
 - Zákon o bankách (§ 33f):
 - Ekonomická hodnota banky nesmie klesnúť o viac než 20 % z hodnoty vlastných zdrojov banky následkom náhlej a neočakávanej zmeny úrokových mier na trhu.
 - Opatrenie NBS o rizikách a systéme riadenia rizík (§ 5):
 - Náhlou a neočakávanou zmenou úrokových mier na trhu sa rozumie paralelný posun výnosovej krivky smerom nahor o 200 bázických bodov.


Základná myšlienka

- Ak by boli úrokové sadzby iba dve:
 - elipsu možno reprezentovať jej hlavnou osou



Základná myšlienka

- Ak by boli úrokové sadzby tri:
 - Elipsoid možno stlačiť do elipsy



3D scatter: 1R, 3R, 7R

PCA: hrubý náčrt

- PCA = analýza hlavných komponentov (principal component analysis)
- V manažmente rizík máme často problém s veľkým počtom rizikových faktorov
 - akciové portfólio s veľkým počtom akcií
 - výnosová krivka daná veľkým počtom bodov
 - pozície v rôznych menách
- Cieľom je identifikovať najvýznamnejšie typické pohyby rizikových faktorov
 - systémový pohľad na riziko
 - využitie pri návrhu stresových scenárov
- Základná myšlienka: Znížiť dimenziu!
- Cieľom je nájsť malý počet lineárnych kombinácií pôvodných časových radov
 - mali by vysvetľovať čo najväčšiu časť variability pôvodných údajov
 - mali by byť navzájom nekorelované

Teoretické východiská

- Predpoklad: X je $N \times T$ matica zmien rizikových faktorov (časové rady sú v riadkoch)
- Východisko: Spektrálna dekompozícia matice:

Každú symetrickú maticu A možno zapísať v tvare

$$A = P \Lambda P^T,$$

kde Λ je diagonálna matica vlastných hodnôt matice A a

P je ortonormálna matica štandardizovaných vlastných vektorov matice A (stĺpce matice P).

- Aplikácia dekompozície na kovariančnú maticu Σ pôvodných údajov: $\Sigma = P \Lambda P^T$
- Výpočet $N \times T$ matice hlavných komponentov:

$$Y = P^T (X - \mu)$$

Vlastnosti HK

- Platí
 - $E(Y) = 0$
 - $\text{cov}(Y) = P^T \Sigma P = P^T P \Lambda P^T P = \Lambda$
- Dôsledok: HK sú nekorelované a ich variancie sú rovné vlastným číslam
- Transformácia na HK predstavuje centrovanie a rotáciu
- Keďže celková variabilita pôvodných premenných je

$$\sum_{i=1}^n \text{var}(X_i) = \text{trace}(\Sigma) = \sum_{i=1}^n \lambda_i$$

tak časť celkovej variancie vysvetlená j-tým HK je $\frac{\lambda_j}{\sum_{i=1}^n \lambda_i}$

Vlastnosti HK

- Prvý HK je štandardizovaná lineárna kombinácia X , ktorá má maximálnu varianciu spomedzi všetkých takýchto kombinácií
 - Smer najväčšej variance N -rozmerného oblaku pôvodných údajov
- Výberové hlavné komponenty:
 - Ak X má normálne rozdelenie a $\text{cov}(X)$ má všetky vlastné čísla rôzne, tak výberové HK sú odhadmi skutočných HK náhodného vektora X , ak sa na odhad $\text{cov}(X)$ použije ML.
- Získané HK nie sú invariantné na zmenu škálovania premenných
 - PCA sa aplikuje na štandardizované premenné, resp. na korelačnú maticu
- Výpočet kovariancie X a Y : $\text{Cov}(X_i, Y_j) = \rho_{ij} \lambda_j$. Odvodenie?
- Ako vypočítať koreláciu?

Určenie počtu HK


- Vlastné hodnoty vyššie ako priemer (Kaiser)
- Stanoviť limit na percento vysvetlenej variácie
- Zlom v grafe vlastných čísiel (scree plot)

Interpretácia PCA

- Komponentové váhy (component loadings):
 - Ide o štandardizované vlastné vektory
 - Koeficienty predstavujú váhu pôvodných premenných pri tvorbe HK
 - Možno ich získať aj pomocou OLS
- Komponentové skóre (component scores)
 - Súradnice objektov v priestore HK
- Biplot = zobrazenie objektov v priestore HK
- Čo by sa stalo, ak by sme pôvodné premenné necentrovali?

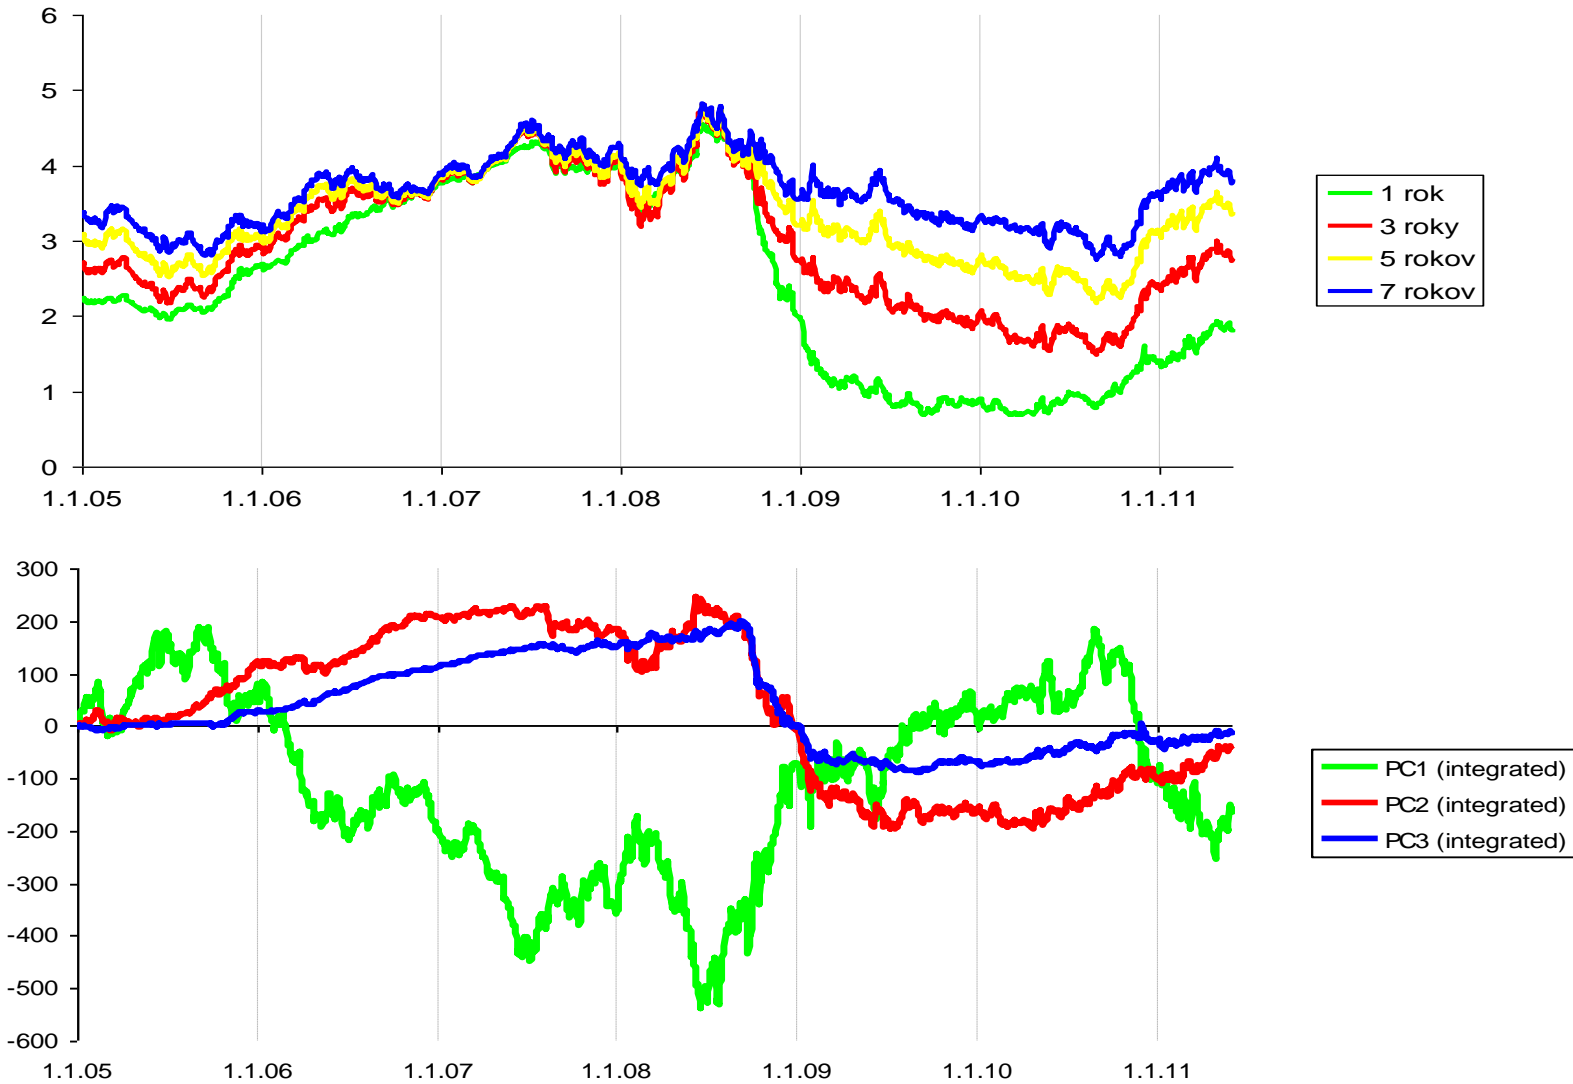
Výsledky

- Časové rady: denné absolútne zmeny (prvé diferencie) úrokových sadziieb
- Component loadings – prvé 3 HK (97,7%)




Výsledky

- Component scores



Výsledky

- Ako identifikovať, ktorý typ posunu prevažoval v jednotlivé dni?



- Scatter plot – zobrazenie v priestore (PC1, PC2)

Veľkosť scenárov

- Poznáme kvalitatívny opis „najreprezentatívnejších“ pohybov úrokovej krivky
- Ako určíme veľkosť príslušných scenárov?

Veľkosť scenárov

Príklad pre 1. HK

- Podmienené normálne rozdelenie k danému dňu: $N(\mu_{HK}, \sigma^2_{HK})$

- Zvolíme $y = (\mu_{HK} - u_\alpha \sigma_{HK}, 0, \dots, 0)^T$

- Prenesenie zmeny spätnou transformáciou:

$$x = Py + \mu$$

- Využívame, že

- $P^T = P^{-1}$, kde stĺpce P tvoria vlastné vektory matice Σ
- HK sú navzájom lineárne nezávislé


- Po zjednodušení:

$$x = P_1 (\mu_{HK} - u_\alpha \sigma_{HK}) + \mu,$$

kde P_1 je vlastný vektor prislúchajúci najvyššej vlastnej hodnote.

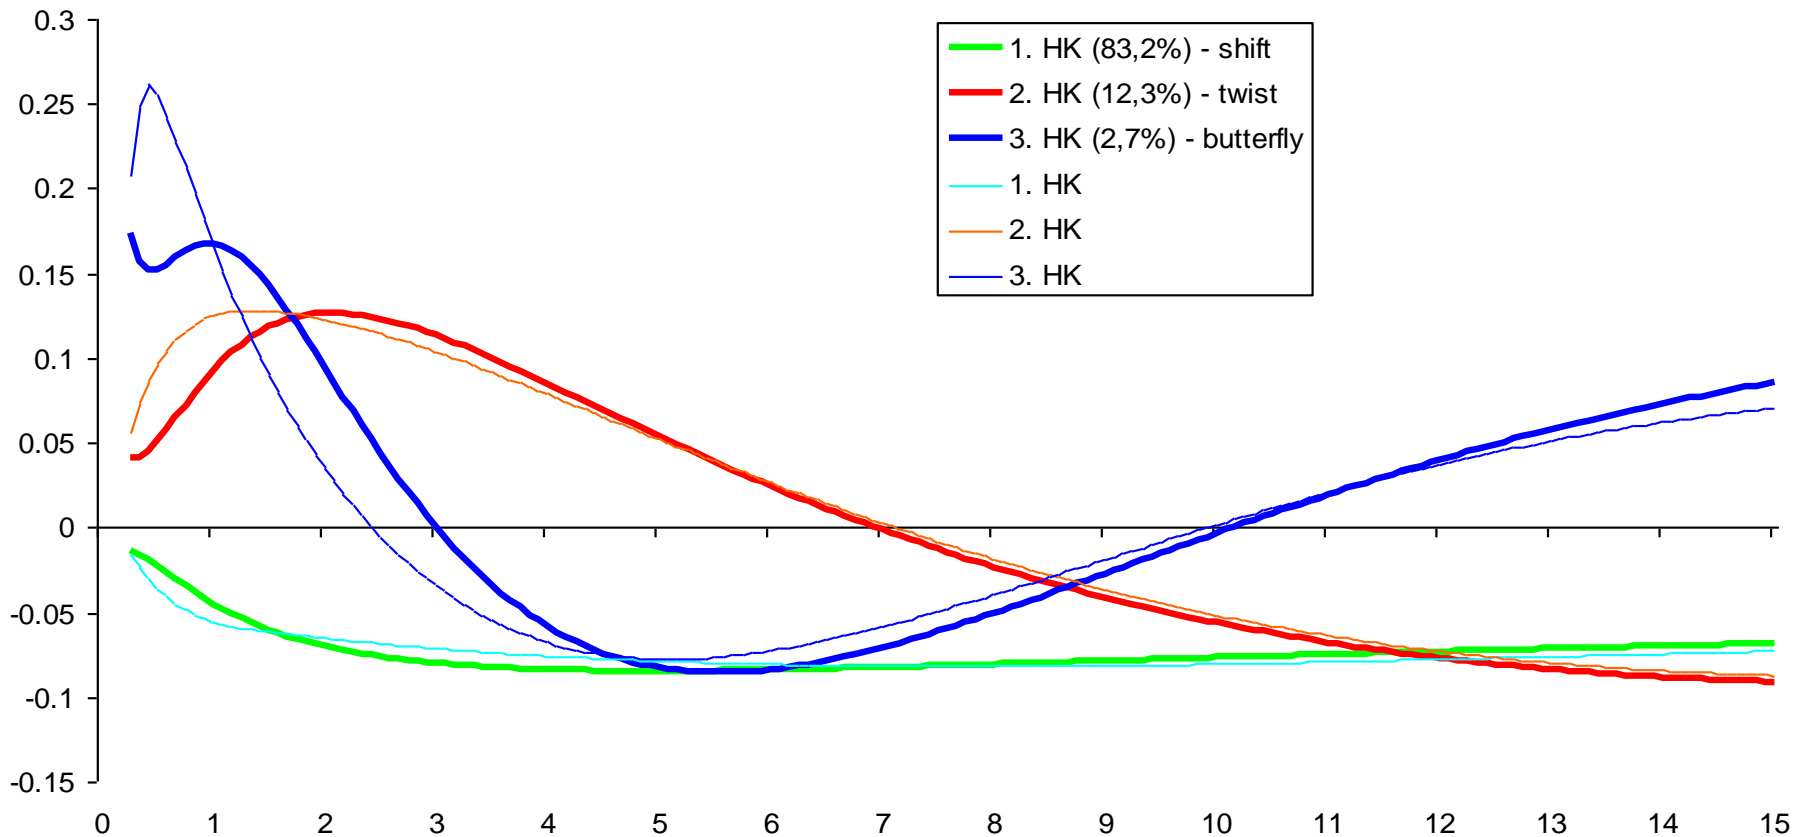
Velikost' scenárov

- Výsledok pre „najtypickejší“ scenár s pravdepodobnosťou 99%:



Prípád kovariančnej matice

- Component loadings – prvé 3 HK (98,3%)



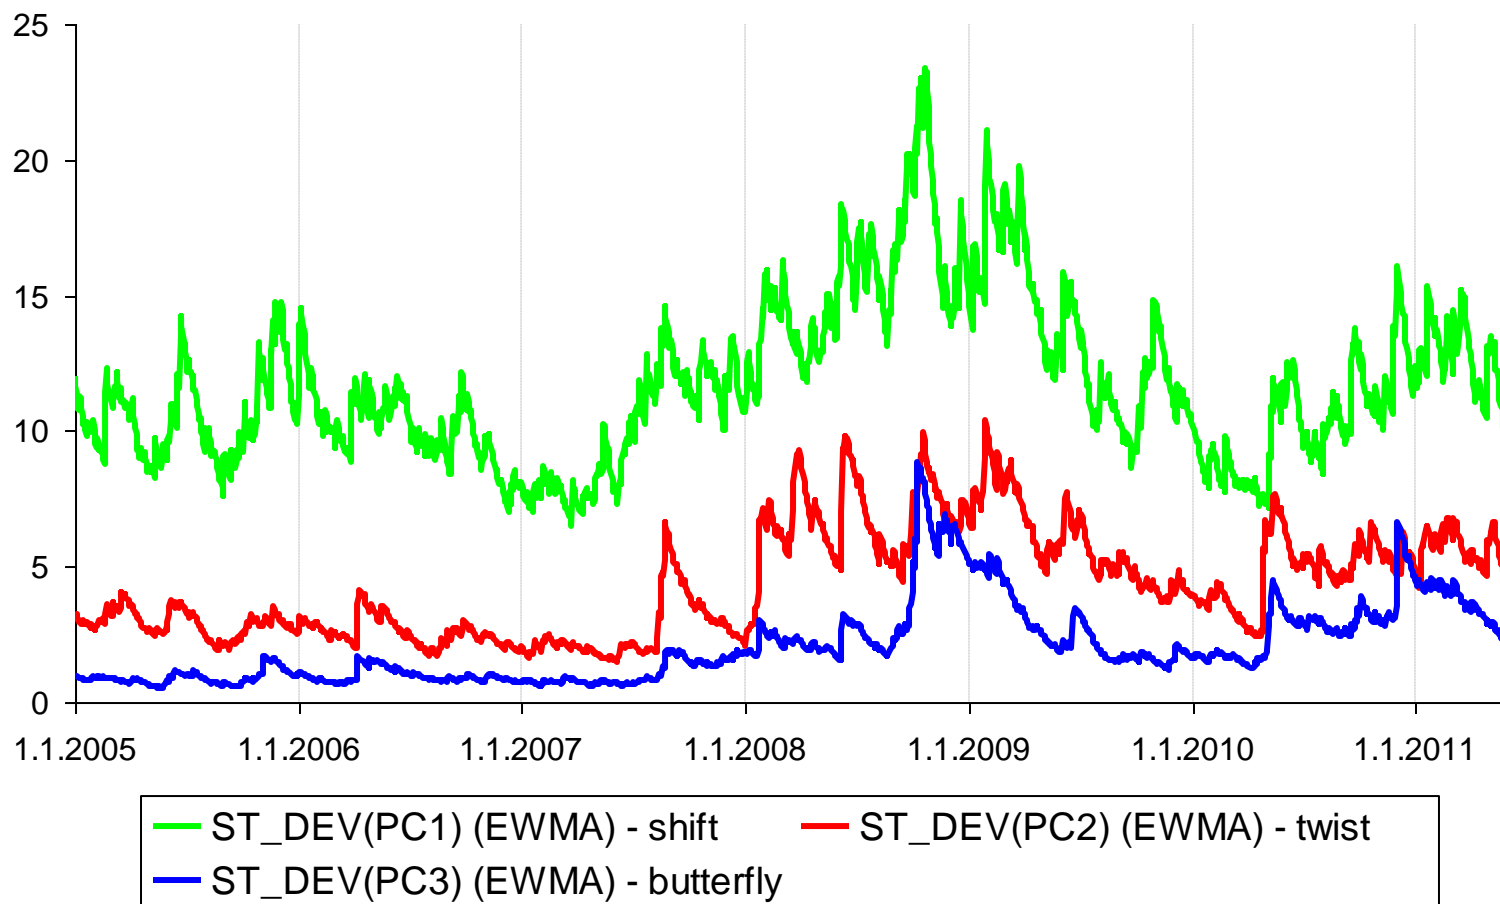
- Slabými čiarami sú zobrazené predchádzajúce výsledky získané z korelačnej matice

Kritika

- Hlavné komponenty často nie sú dobre interpretovateľné
- Pokrytá je iba lineárna závislosť (t.j. korelácia)
 - Nezachytáva fakt, že závislosť môže byť v čase trhových turbulencií vyššia
- Neumožňuje časovo premenlivé váhy pri konštrukcii HK

Kritika

- Ilustrácia, že faktory sú nekorelované, ale istý typ závislosti existuje



Možné rozšírenia

1. Využitie podmienenej kovariančnej / korelačnej matice
2. Orthogonal GARCH
3. PCA ako medzivýpočet v riadení rizík
4. Faktorová analýza – rotácia faktorov s cieľom zvýšiť interpretáciu