



Funkcionální podmíněné kvantily rizikově neutrálních hustot

Zdeněk Hlávka

Univerzita Karlova v Praze, KPMS MFF UK, Sokolovská 83, Praha



Kupní cenu $C_t(T)$ opce evropského typu v čase t s maturitou $T = t + \tau$, $\tau > 0$, lze zapsat jako střední hodnotu zisku $z(S_T)$, závisejícího na budoucí ceně S_T podkladového instrumentu v čase T , opravenou o bezrizikovou úrokovou míru r : $C_t(T) = \exp\{-r\tau\}Ez(S_T) = \exp\{-r\tau\}\int_0^{+\infty} z(S_T)f_t(S_T)dS_T$, kde rizikově neutrální hustotu $f_t(\cdot)$ lze interpretovat jako pravděpodobnostní hustotu náhodné veličiny S_T . Odhad rizikově neutrální hustoty bývá obvykle odvozen od cen opcí [5]. Cílem příspěvku je porovnání skutečných budoucích cen $S_{t+\nu}$, $\nu > 0$, s různými předpověďmi založenými na funkcionální neparametrické regresi i na podmíněných funkcionálních kvantilech.

1 Rizikově neutrální hustota (RNH)

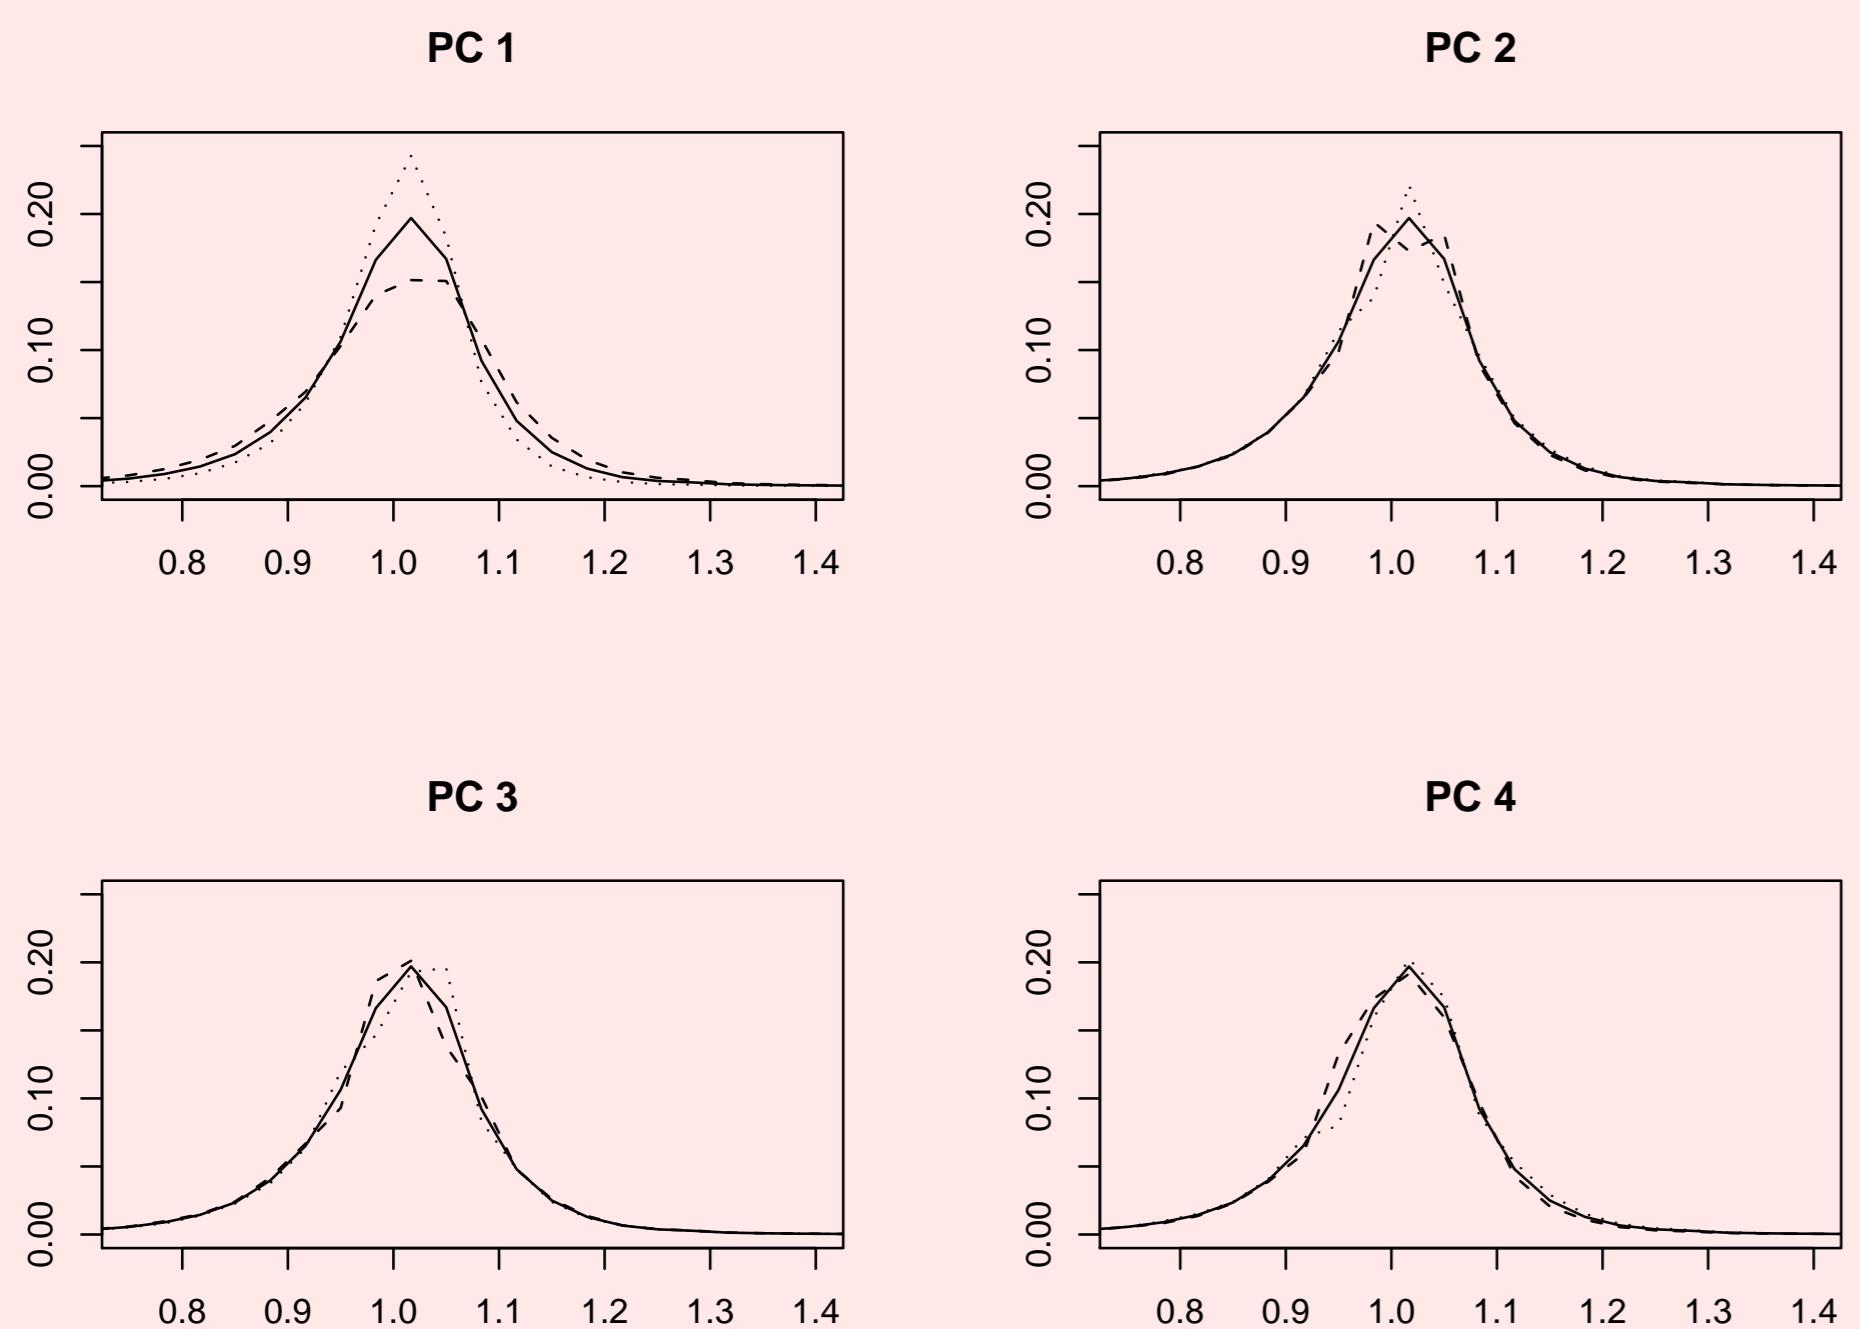
Majitel kupní opce evropského typu získá v čase T částku $z(S_T) = (S_T - K)_+ = \max(S_T - K, 0)$. Cena této opce v čase t je:

$$C_t(K, T) = \exp\{-r(T-t)\} \int_0^{+\infty} (S_T - K) f_t(S_T) dS_T.$$

Pro odhad RNH $f_t(\cdot)$ je důležité, že v tomto případě ji lze vyjádřit jako druhou derivaci ceny vzhledem k realizační ceně K [2]:

$$f_t(K) = \exp\{r(T-t)\} \frac{\partial^2 C_t(K, T)}{\partial K^2}.$$

V článku [4] je ukázáno, že funkcionální hlavní komponenty [6] RNH lze interpretovat jako změny tvaru pozorovaných funkcí:



2 Neparametrická funkcionální regrese

Funkcionální náhodná proměnná X je v [3] obecně zavedena jako měřitelné zobrazení z pravděpodobnostního prostoru $(\Omega, \mathcal{A}, \mathcal{P})$ do nekonečně rozměrného měřitelného prostoru (G, \mathcal{G}) .

Za závislosti proměnnou zvolme náhodnou proměnnou $S_{t+\nu}$, $\nu > 0$, a za vysvětlující funkcionální proměnnou odhad RNH $\hat{f}_t(\cdot)$, kde $t = 1, \dots, n$.

Funkcionální jádrové neparametrické odhady zavedeme jako vážené lokální průměry závislosti proměnné, zde vyjádřené pro předpověď ceny odpovídající $\hat{f}_{n+1}(\cdot)$:

$$\hat{S}_{n+1+\nu} = r\{\hat{f}_{n+1}(\cdot)\} = \frac{\sum_{t=1}^n S_{t+\nu} K_h[d\{\hat{f}_{n+1}(\cdot), \hat{f}_t(\cdot)\}]}{\sum_{t=1}^n K_h[d\{\hat{f}_{n+1}(\cdot), \hat{f}_t(\cdot)\}]}, \quad (1)$$

kde $K_h(\cdot)$ je asymetrická jádrová funkce s parametrem h a $d(\cdot)$ je vhodná míra vzdálenosti dvou funkcionálních pozorování [3].

Volba jádrové funkce ve vzorci (1) je obdobná jako u obyčejné jádrové regrese a rozdíl je pouze v tom, že kvůli použití vzdálenosti uvnitř jádrové funkce se ve vzorci (1) musí používat asymetrické jádrové funkce, tj. jádrové funkce, které jsou nenulové pouze pro nezáporné hodnoty vzdálenosti. Volba parametru h jádrové funkce je v praxi obvykle vyřešena pomocí tzv. krížového ověřování (cross-validation), podrobnejší viz sekce 3.

Mnohem komplikovanější je při analýze funkcionálních dat volba vzdálenosti. V práci [3] se místo s Euklidovskou vzdáleností pracuje s tzv. semimetrikou: $d(\cdot)$ je semimetrika na prostoru G , pokud pro každé $x \in G$ platí $d(x, x) = 0$ a zároveň pro každou trojici $(x, y, z) \in G^3$ platí $d(x, y) \leq d(x, z) + d(z, y)$. V praxi se doporučují semimetry založené na hlavních komponentách (PCA), partial least squares nebo na derivacích. Volba semimetry záleží na situaci a na typu a vlastnostech analyzovaných funkcionálních dat. My navážeme na analýzu funkcionálních hlavních komponent z článku [4] a budeme používat semimetrku založenou na hlavních komponentách.

Semimetrka typu PCA: Jsou-li pozorované funkce definovány svými hodnotami na mřížce u_1, \dots, u_m , je metoda funkcionálních hlavních komponent [6] ekvivalentní obyčejné metodě hlavních komponent: pomocí spektrálního rozkladu $V_n = \Gamma \Lambda \Gamma^\top$ varianční matice V_n vektoru $\hat{f}_t = (\hat{f}_t(u_1), \dots, \hat{f}_t(u_m))^\top$, $t = 1, \dots, n$, získáme funkcionální hlavní komponenty $\xi_t = \hat{f}_t \Gamma$ a datovou matici $F(n \times m)$ s řádky \hat{f}_t , $t = 1, \dots, n$, můžeme zapsat jako $F = (FT)\Gamma^\top$. Označíme-li symbolem Γ_q matici obsahující prvních q sloupců matici Γ , získáme v jistém smyslu optimální approximaci $F_q = (FT\Gamma_q)\Gamma_q^\top$, kterou použijeme k zavedení semimetry (vzdálenosti) typu PCA mezi diskretizovanými funkcionálními pozorováními $x = (x(u_1), \dots, x(u_m))^\top$ a $y = (y(u_1), \dots, y(u_m))^\top$:

$$d_q^{PCA}(x, y) = \|x - y\|_q = \sqrt{(x - y)^\top \Gamma_q \Gamma_q^\top (x - y)} = \sqrt{\sum_{k=1}^q \{(x - y)^\top \gamma_k\}^2} = \sqrt{\sum_{k=1}^q \left[\sum_{i=1}^m \{x(u_i) - y(u_i)\} \gamma_{ik} \right]^2}.$$

Pro funkcionální pozorování $x(\cdot)$ a $y(\cdot)$ můžeme semimetrku typu PCA zapsat jako:

$$d_q^{PCA}\{x(\cdot), y(\cdot)\} = \sqrt{\sum_{k=1}^q \left[\int \{x(t) - y(t)\} \gamma_k(t) dt \right]^2},$$

kde $\gamma_k(\cdot)$ jsou příslušné vlastní funkce.

3 Implementace v R

specifické parametry	
<code>funopare.kernel()</code>	<code>bandwidth</code> (nemá defaultní nastavení)
<code>funopare.kernel.cv()</code>	
<code>funopare.knn()</code>	<code>neighbour</code> (nemá defaultní nastavení)
<code>funopare.knn.gcv()</code>	
<code>funopare.knn.lcv()</code>	
<code>funopare.mode.lcv()</code>	<code>Knearest=NULL</code>
<code>funopare.quantile.lcv()</code>	<code>Knearest=NULL, alpha=c(.05, .5, .95)</code>

Všechny výše uvedené funkce pro neparametrickou funkcionální regresi ([3], <http://www.lsp.ups-tlse.fr/staph/npfda/>) požadují závisle proměnnou (`Response`), nezávisle proměnnou (`CURVES`) a funkce, pro které se mají spočítat předpovězené hodnoty (`PRED`). Všechny funkce umožňují zvolit jádrovou funkci (`kind.of.kernel`) a semimetrku (`semimetric`).

Následující funkce počítají odhad (1) a liší se pouze volbou parametru `h`:

`funopare.kernel()` Hodnota h je nastavena parametrem `bandwidth`.

`funopare.kernel.cv()` Hodnota h je určena pomocí krížového ověřování.

`funopare.knn()` Parametr `neighbour` určuje počet nejbližších pozorování, která budou použita k výpočtu v každém bodě. Hodnota parametru h_t , $t = 1, \dots, n$, je pak pro každé pozorování zvolena tak, aby do tohoto okolí padl právě zadaný počet "nejblížších sousedů".

`funopare.knn.gcv()` Počet nejbližších sousedů určující lokální síru okénka h_t je určen globálně pomocí krížového ověřování.

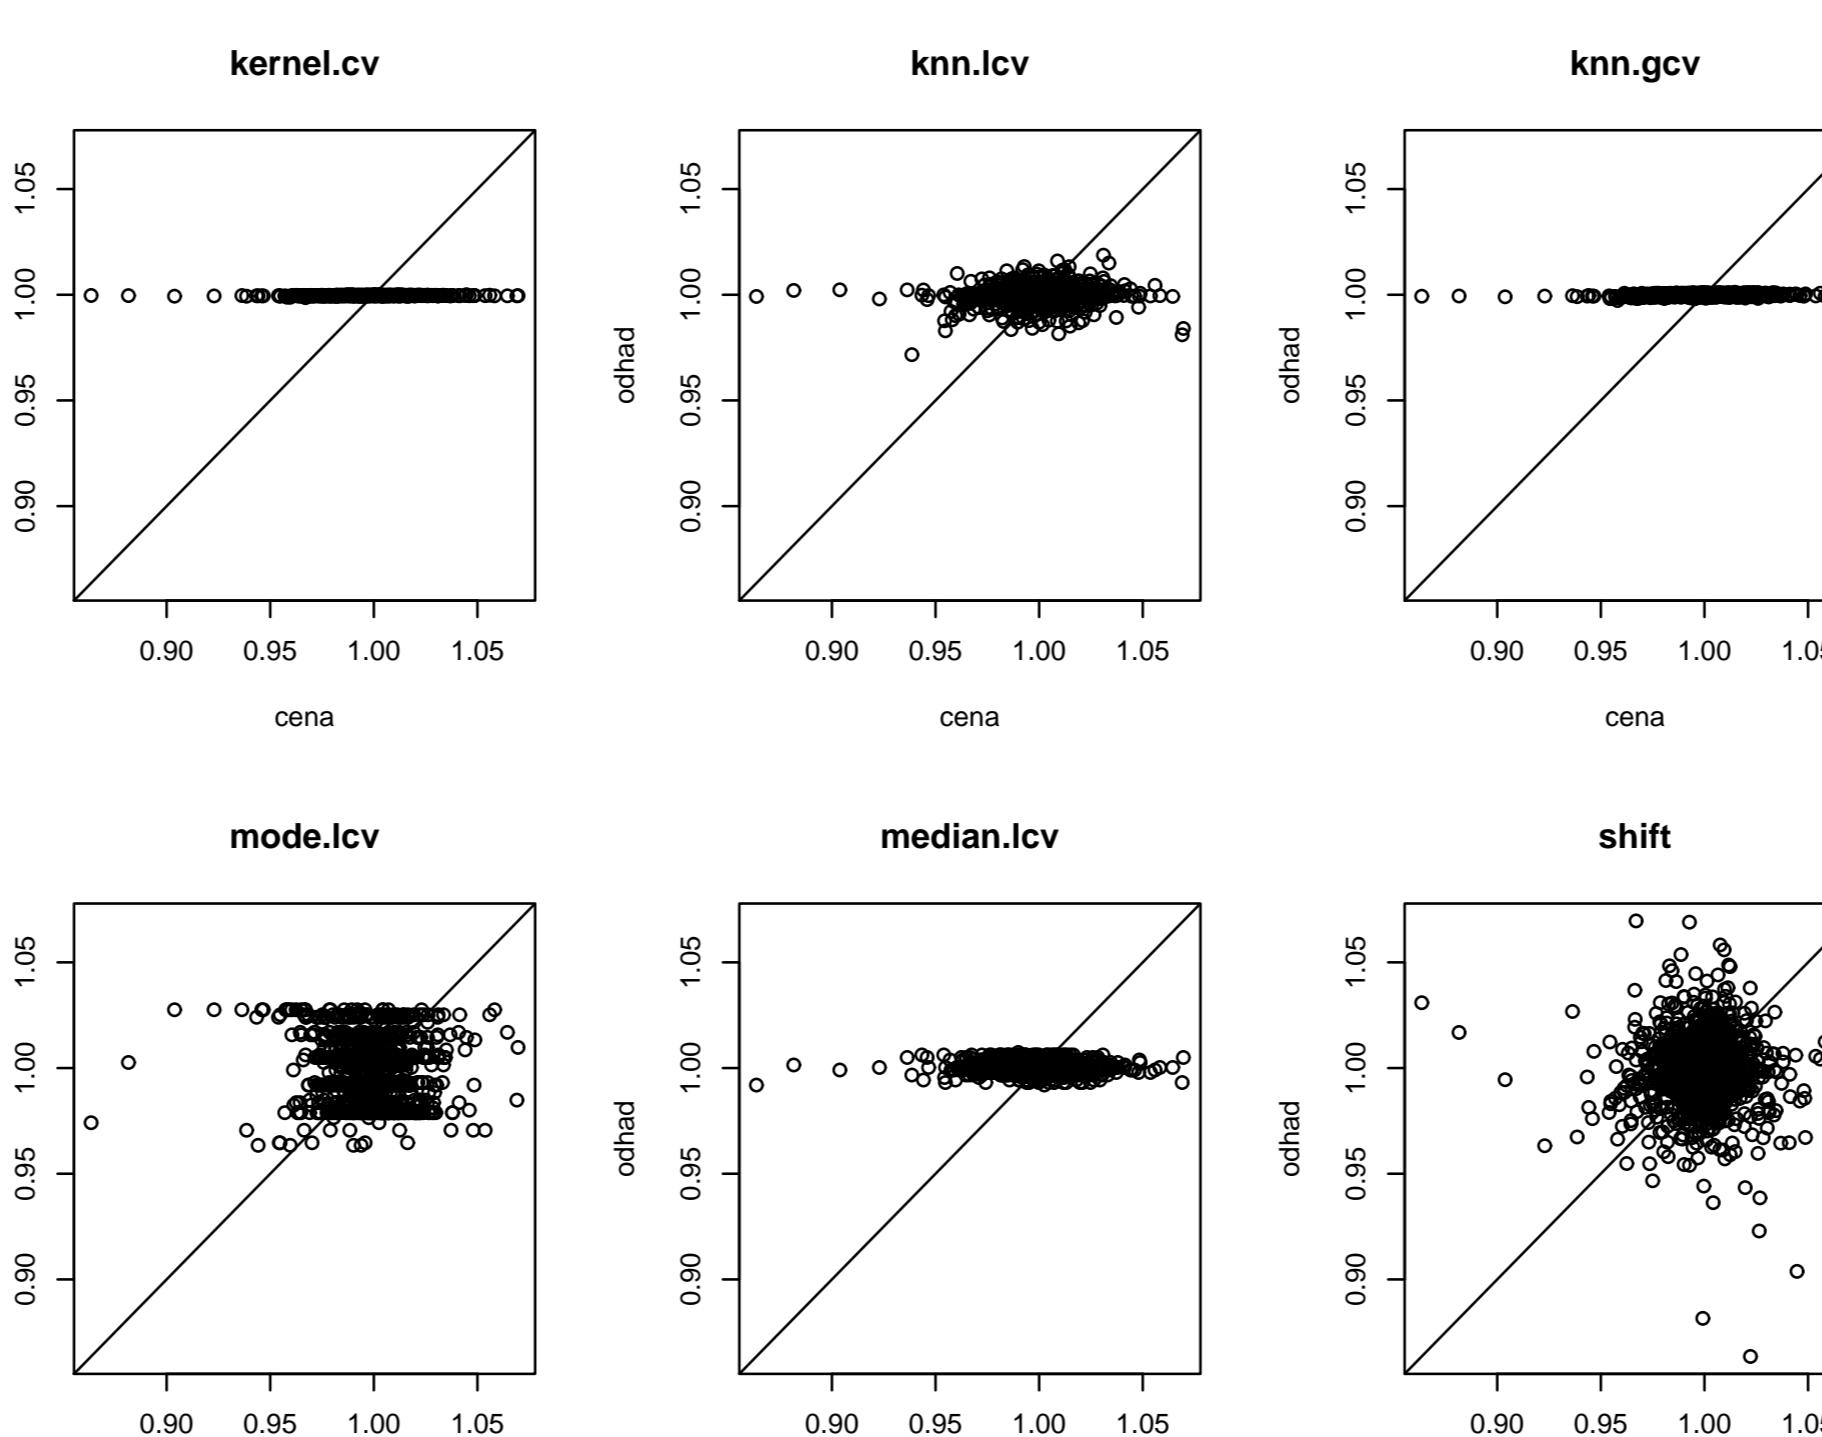
`funopare.knn.lcv()` Počet nejbližších sousedů je v každém bodě určen zvlášť pomocí krížového ověřování.

Zbývající dvě funkce jsou založené na jádrových odhadech podmíněné distribuční funkce a podmíněné hustoty: funkce `funopare.mode.lcv()` počítá podmíněný modus a `funopare.quantile.lcv()` s parametrem `alpha=0.5` počítá podmíněný medián.

4 Neparametrická funkcionální regrese na odhadech RNH

Neparametrickou funkcionální regresi použijeme na RNH odhadnuté z cen opcí na index DAX od ledna 1995 do března 2003. Pro odstranění závislosti odhadnutých hustot na aktuální hodnotě DAXu jsou odhady RNH spočítány v bodech odpovídajících násobků současné hodnoty DAXu; interval od 0 do 4-násobku současné hodnoty je rovnoměrně rozdělen na 120 částí a každá "funkce" je tak diskretizována pomocí 121 funkčních hodnot. Pomocí neparametrické funkcionální regresy se nyní pokusíme vyšetřit vztah mezi cenami akcií S_{t+1} a odhady rizikově neutrálních hustot $\hat{f}_t(\cdot)$. Parametr semimetrky PCA byl zvolen $q = 20$.

Data jsme rozdělili na dvě části. První část dat slouží pouze pro odhad neparametrické funkcionální regrese a na druhé části dat jsme takto získaný odhad vyzkoušeli. Předpovědi spočítané v testovací části našich dat všemi metodami s automatickou volbou parametru h jsou znázorněny na obrázku (pro srovnání je v pravém dolním rohu i předpověď založená pouze na předešlém pozorování):



V tabulce jsou uvedeny střední čtvercové chyby ($\times 10^4$) v prvním a ve druhém (testovacím) výběru:

	kernel	knn.lcv	knn.gcv	mode	median	shift	constant
první	1.50	1.21	1.50	0.97	1.15	2.79	1.49
druhý	3.17	3.22	3.14	5.52	3.29	6.56	3.17

Je zajímavé, že v prvním rádku je nejlepší odhad založený na modu podmíněné hustoty, který zcela selhává na testovacích datech. Pro srovnání jsou uvedeny i hodnoty střední čtvercové chyby pro odhad založený pouze na předešlém pozorování (shift) a pro konstantní odhad rovný průměrné ceně (constant). Odhad založený na předešlém pozorování je jednoznačně nejhorší, zatímco konstantní odhad patří na testovacích datech k těm lepším. Výsledky této analýzy lze stručně shrnout očekávaným závěrem, že tvar odhadu rizikově neutrální hustoty neumožňuje předpovídat budoucí vývoj ceny podkladového instrumentu. Vhodnější a zajímavější zde budou neparametrické funkcionální kvantily, které místo bodové předpovědi poskytují předpovědní intervaly pro budoucí hodnoty ceny DAXu.

5 Funkcionální podmíněné kvantily

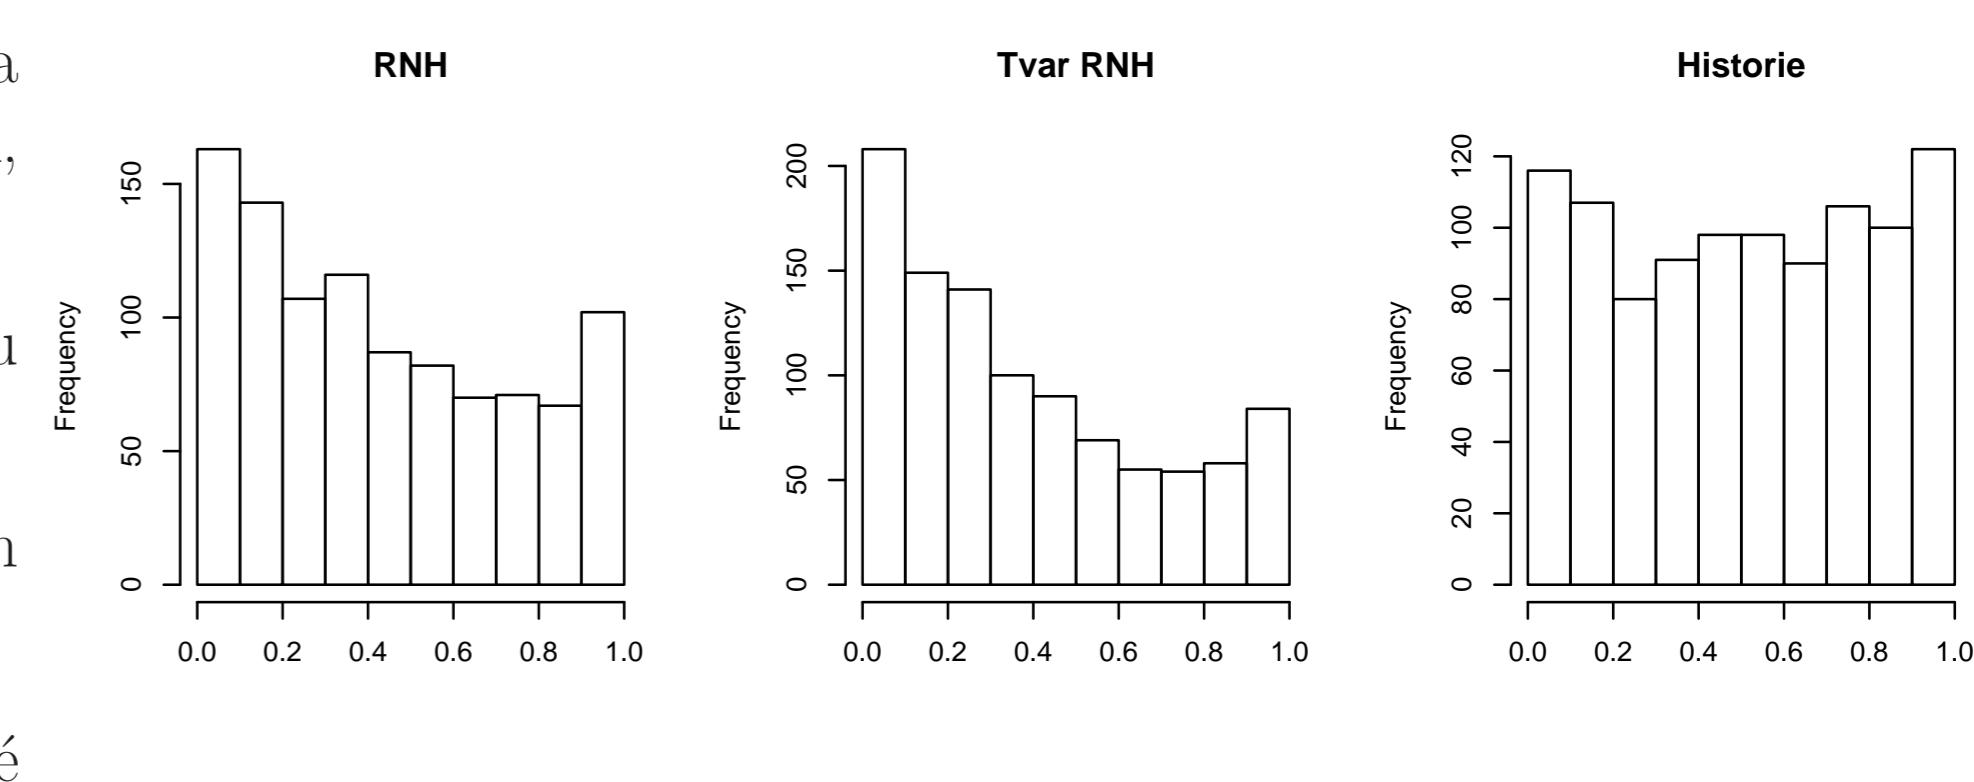
Odhad RNH $\hat{f}_t(\cdot)$ lze za předpokladu rizikové neutrality interpretovat jako odhad pravděpodobnostní hustoty náhodné veličiny $S_{t+\tau} = S_T$. Ve skutečnosti se však v odhadech RNH projevuje averze k riziku, kterou lze jednoduše ukázat např. porovnáním kvantilů $\hat{f}_t(\cdot)$ s pozorovanými hodnotami S_T . V této části srovnáme kvantily odhadu RNH $\hat{f}_t(\cdot)$ s neparametrickými funkcionálními kvantily založenými na tvaru $\hat{f}_t(\cdot)$ a s neparametrickými funkcionálními kvantily založenými na historických pozorováních S_u , $u < t$. Soustředíme se na následující tři odhady kvantilů:

RNH Kvantis u_α^{RNH} je řešením rovnice $\int_{-\infty}^{u_\alpha^{RNH}} \hat{f}_t(x) dx = \alpha$.

Tvar RNH Kvantis u_α^{tvar} je určen z neparametrického funkcionálního odhadu podmíněné distribuční funkce náhodné veličiny S_T . Vysvětlující funkcionální proměnnou je zde odhad RNH $\hat{f}_t(\cdot)$ a volba semimetrky PCA zaručuje, že regresní funkce bude záviset na tvaru RNH.

Historie Neparametrické funkcionální kvantily u_α^{hist} s funkcionálními vysvětlujícími pozorováními danými historickými hodnotami S_u , $u < t$.

Na obrázku jsou nakresleny histogramy hodnot odhadů distribučních funkcí odpovídajících výše uvedeným kvantilům v bodech S_T :



Pro dobře kalibrované předpovědi by tyto histogramy mely být co nejdobřeji rovnoměrnému rozdělení (označíme-li skutečnou distribuční funkci cen S_T jako F_T , pak má náhodná veličina $F_T(S_T)$ rovnoměrné rozdělení). Vidíme tedy, že nejrealističtější předpovědi poskytuje neparametrická funkcionální regrese založená na historických cenách, zatímco u zbylých metod příliš často nastávají události odpovídající nízkým kvantilům.

Následující kvantilové diagramy umožňují přímé srovnání získaných kvantilů:

