

Abstrakt

První kapitola se zaměřuje na vyhodnocení přesnosti předpovědí časových řad. Je běžnou praxí rozdělit časovou řadu na in-sample a pseudo out-of-sample segmenty a odhadnout out-of-sample ztrátu daného statistického modelu vyhodnocením přesnosti předpovědí v pseudo out-of-sample segmentu. V této kapitole navrhuji alternativní estimátor out-of-sample ztráty, který, na rozdíl od konvenčního estimátoru, využívá kritéria měřená jak v in-sample, tak out-of-sample prostřednictvím pečlivě konstruovaného systému afinních vah. Za předpokladu, že časová řada je stacionární, navržený estimátor je nejlepším lineárně nezkresleným estimátorem out-of-sample ztráty a předčí konvenční estimátor z hlediska vzorkové variability. Použití tohoto optimálního estimátoru pro statistické testy prediktivní schopnosti typu Diebold-Mariano vede k podstatnému zvýšení statistické síly bez zvýšení zkreslení v malých vzorcích. Rozsáhlé vyhodnocení na reálných časových řadách ze soutěže M4 potvrzuje nižší vzorkovou variabilitu navrženého estimátoru a také prokazuje značnou odolnost vůči porušení základního předpokladu stacionarity.

Ve druhé kapitole zkoumáme různé specifikace BEKK multivariačních modelů volatility pro střední počet aktiv s důrazem na to, jak stupeň parametrizace ovlivňuje kvalitu předpovědí. Vzhledem k tomu, že neomezená specifikace může být příliš štědře parametrizována, často se ukládají omezení na koeficientové matice, omezující je na diagonální nebo dokonce skalární strukturu. Všechny tři varianty modelů (plný, diagonální, skalární) formulujeme jako speciální případy estimátoru s regulací typu ridge, kde jsou prvky mimo diagonálu penalizovány směrem k nule a prvky na diagonále penalizovány směrem k homogenitě. Naše experimenty s modely typu CAW (Conditional Autoregressive Wishart) pro realizovanou volatilitu potvrzují vhodnost restriktivnějších variant modelu v podobě skalární a diagonální specifikace. Dále naše výsledky zdůrazňují klíčový význam časté re-estimace modelu pro zvýšení přesnosti předpovědí a paradoxně také mírnou výhodu kratších estimačních oken ve srovnání s delšími okny.

Ve třetí kapitole navrhuji nový meta-learning model, který využívá neuronové hyper sítě k návrhu parametrického modelu přizpůsobeného konkrétní skupině predikčních úkolů. Trénink modelu lze provádět přímo pomocí zpětné propagace, což eliminuje potřebu spoléhat se na derivace vyšších řádů, a je ekvivalentní simultánnímu prohledávání prostoru parametrických funkcí a optimálních hodnot jejich parametrů. To poskytuje alternativu k ručnímu návrhu parametrického modelu pro skupinu podobných predikčních úkolů, což obvykle vyžaduje značné statistické a doménové znalosti. Schopnosti modelu jsou demonstrovány na dvou aplikacích. Při aplikaci na problém sinusové regrese, navržený model předčí všechny alternativní přístupy a dokáže téměř dokonale obnovit původní parametrický model. V rámci druhé aplikace je model používán v soutěži M6 Financial Forecasting Competition k predikci kvintilů výnosů aktiv. Zde model dosáhl přesnosti 0.15689 RPS, což zajistilo 4. místo v předpovědní výzvě a 1. místo v celkovém pořadí duatlonu.