

V současné době existuje řada metod predikce a prognostici čelí mnoha výzvám při výběru optimální metody pro predikci volatility. Tato diplomová práce testuje několik metod kombinací predikce, aby bylo možné využít široké škály prognóz. Bez ohledu na to, že existuje spousta literatury o kombinaci prognóz, kombinace tradičních metod s metodami machine learning je relativně vzácná. V této práci implementujeme následující kombinované metody: (1) simple mean forecast combination, (2) OLS combination, (3) ARIMA on OLS combined fit, (4) NNAR on OLS combined fit a (5) KNN regression on OLS combined fit. Na základě námi dostupných informací nejsou poslední dvě kombinované metody doposud zkoumány v akademické literatuře. Tato práce by navíc měla pomoci prognostici se třemi možnými komplikacemi: (1) výběr volatility proxy, (2) výběr měřítka přesnosti predikce a (3) výběr délky zkušebního vzorku. Zjistili jsme, že squared a absolute return proxy jsou mnohem méně účinné než Parkinson a Garman-Klass volatility proxy. Dále ukazujeme, že metriky přesnosti prognózy (RMSE, MAE nebo MAPE) ovlivňují pořadí optimálních prognóz. Dalším zjištěním je, že přestože kvalita predikce nezáleží na délce zkušebního vzorku, je vidět, že metody kombinace predikcí překonávají samostatné metody na delších zkušebních vzorcích. Na závěr jsme zjistili, že Garman-Klass volatility proxy, KNN regression on OLS combined fit na střední délce zkušebního vzorku překonává jiné metody pro estimaci Garman- Klass volatility.