



Aalto-yliopisto
Perustieteiden
korkeakoulu

Estimating the parameters of a geometric Brownian motion with MCMC

Matias Linnankoski

12.06.2020

Ohjaaja: DI. Niko Lietzén

Valvoja: Apulaisprofessori Pauliina Ilmonen

Työn saa tallentaa ja julkistaa Aalto-yliopiston avoimilla verkkosivuilla. Muilta osin kaikki oikeudet pidätetään.

Tausta

- Markov Chain Monte Carlo (MCMC)
 - Algoritmeja otosten generoimiseen
 - Mahdollistavat otosten generoinnin vaikeista todennäköisyysjakaumista
 - Ideana suorittaa Monte Carlo simulointi Markov ketjulle, jotta saadaan se konvergoimaan haluttuun jakaumaan
 - Voidaan käyttää esimerkiksi laskennallisten inversio-ongelmien ratkomiseen
 - Tunnetuin algoritmi on Metropolis-Hastings algoritmi

Tausta

- Geometrinen Brownin liike (GBM): prosessi jolla voidaan mallintaa osakkeen hintaa

$$dS_t = \mu S_t dt + \sigma S_t dX_t$$

↗
Deterministinen
komponentti

↖
Stokastinen
komponentti

- Stokastisella differentiaaliyhtälöllä ratkaisu:

$$S_t = S_0 e^{(\mu - \frac{1}{2}\sigma^2)t + \sigma X_t}$$

Tavoitteet

- Simuloidaan GBM, siten että, μ on normaalijakautunut ja σ^2 vakio
- Estimoidaan μ :n posteriorijakauma simuloidusta aineistosta, kun σ^2 tunnetaan
- Käytetään estimoimiseen Metropolis algoritmia
- Validoidaan tulokset tarkastelemalla estimoidun jakauman normalisuutta, odotusarvoa ja varianssia.
 - Normalisuutta tarkastellaan visuaalisesti
 - Odotusarvo ja varianssi estimoidaan MCMC otoksesta
 - Odotusarvoa ja varianssia verrataan todellisiin arvoihin

Aineisto

- GBM simuloitiin seuraavin parametrein:

- $\mu \sim N(0.3, 0.05)$


- $\sigma^2 = 0.1$

- $T = 10$

- $n = 2550$

- $dt = \frac{T}{n} = \frac{1}{255}$

Työssä käytetty GBM polku



Menetelmät

- Käytetään estimoimiseen S lisäyksiä
- S lisäykset ovat lognormaalisti jakautuneita

$$Y_i = \ln \frac{S_i}{S_{i-1}} \sim N(\hat{\mu}, \hat{\sigma}^2) ,$$

missä $\hat{\mu} = \left(\mu - \frac{1}{2}\sigma^2 \right) dt$ ja $\hat{\sigma}^2 = \sigma^2 dt$.


- Estimoidaan ensin $\hat{\mu}$, minkä avulla voidaan selvittää μ .

MCMC algoritmi


- Tehdään alkuarvaus $\hat{\mu}_i$
- Iteroidaan $i = 1 \dots m$
 - $\hat{\mu}_p = N(\hat{\mu}_i, \hat{\sigma}_0)$
 - $a = \min\left(\frac{p(Y|\hat{\mu}_p, \hat{\sigma})}{p(Y|\hat{\mu}_i, \hat{\sigma})}, 1\right)$
 - Todennäköisyydellä a :
 - $\hat{\mu}_{i+1} = \hat{\mu}_p$
 - Muuten:
 - $\hat{\mu}_{i+1} = \hat{\mu}_i$
- Palautetaan $\hat{\mu} = (\hat{\mu}_1, \dots, \hat{\mu}_m)$
- Lopuksi tehdään muunnos $\mu = \frac{\hat{\mu}}{dt} + \frac{1}{2}\sigma^2$

Tulokset

- Kuvaajat MCMC algoritmin generoimasta otoksesta



Otos iteraation funktiona. Punainen viiva kuvaa burn-in aikaa.



Histogrammi otoksesta. Punainen viiva kuvaa otokselle sovitettua normaalijakaumaa $N(0.30, 0.10)$.

Tulokset

- Tulokset taulukoituna: Lihavoitu sarake kuvaa parametrin todellisia arvoja.

	Keskiarvo	Keskihajonta	Mediaani
μ	0.302	0.102	0.303
μ	0.300	0.05	0.3

- Estimaatin keskiarvo poikkeaa vain 1% todellisesta arvosta
- Estimaatin keskihajonta kaksinkertainen todelliseen arvoon verrattuna

Johtopäätökset

- Keskiarvon estimoiminen toimi hyvin, mutta keskihajonnan ennuste poikkesi merkittävästi todellisesta
- Syy keskihajonnan poikkeamaan mahdollisesti otoskoossa tai mallissa
- Oikeaan dataan sovittaminen voi olla hankalampaa
 - Hintojen dynamiikka muuttuu ajan kuluessa
- Luonnollisin tapa jatkaa tutkimusta olisi lisätä malliin varianssin estimointi
- Lisäksi GBM voitaisiin korvata jollain hienostuneemmalla mallilla.

Lähteet

- Chib, S., & Greenberg, E. (1995). Understanding the metropolis-hastings algorithm. *The American Statistician*, 49(4), pp. 327-335.
- Johannes, M., & Polson, N. (2010). MCMC methods for continuous-time financial econometrics. In *Handbook of Financial Econometrics: Applications*, pp. 1-72. Elsevier.