

FINANCIJSKI VREMENSKI NIZOVI

INDEXI BURZE, CIJENE ZLATA, TEČAJNE LISTE

DNEVNO ZAPISIVANJE CIJENA

skupljanjem npr. dnevnih cijena — vremenski niz

iz niza odredimo proces

KARAKTERISTIKA — napredvidljivost (nedeterminiranost)

Problem: da li promatranjem cijena možemo predvidjeti buduće cijene?

ODREDJIVANJE DINAMIKE: primjenom statistike

JEDINO MOŽEMO GOVORITI U TERMINIMA VJEROJATNOSTI

process: linearan — nelinearan proces ???

RIZIK — ST. DEVIJACIJA — VAŽNOST PREDVIDJANJA ST DEV.

ZNAČAJKE DINAMIKE CIJENA DIONICA

postojanje trendova

precizno predviđanje nemoguće

dva se pitanja nameću

1) da li je cijena sutra današnja + ocjena dnevног porasta?

2) da li izmjenom pozicije na tržištu možemo zaraditi — neprestano kupujući i prodajući isti proizvod??

hipoteza slučajnog koraka i efikasnog tržišta

1) da li trebamo poznavati prošle cijene?

koliko daleko u prošlost?

hipoteza slučajnog koraka tvrdi da su promjene cijena nepredvidljive poput slučajnog šetača.

statističko tumačenje: Bachelier (1900) — ΔS su neovisne i identične normalne PDF

Fama (1965) odbacuje normalnost distribucije

Granger (1970) odbacuje i identičnost distribucija

HIPOTEZA PODRAZUMJEVA CONST. ΔS I NEKORELIRANOST: VRIJEDI ZA VELIKA TRŽIŠTA

2) TRENUȚNA VRIJEDNOST SADRŽI SVE INFORMACIJE O PROŠLOSTI
ANALIZOM OBЛИКА KRETANJA DIONICA NE MOŽEMO SE OBOGATITI

DNEVNI PRINOSI

analiza cijene dionica S — nestacionarnost i umjetna koreliranost. ΔS se analiziraju, e.g. closing prices

$$x_t = S_t + d_t - S_{t-1} \quad (1)$$

$$R_t = \log(S_t + d_t) - \log(S_{t-1}) \quad (2)$$

$$R'_t = (S_t + d_t - S_{t-1})/S_{t-1} \quad (3)$$

1) varijance rastu

2) i 3) praktički ekvivalentni

razlike:

$$R_{2t} = R_t + R_{t+1} \quad (4)$$

$$R'_{2t} = R'_t + R'_{t+1} + R'_t * R'_{t+1} \quad (5)$$

KARAKTERISTIKE MODELAA

VREMENSKI NIZOVI MODELAA I CIJENE IDENTIČNI

STATISTIČKA SVOJSTVA CIJENA (VARIJANCA ...)

JEDNOSTAVAN (BROJ PARAMETARA)

POSTOJANJE DISTRIBUCIJE U ANALITIČKOM OBLIKU

PRIMJER: WIENER PROCES (BLACK SCHOLES)

MODELII ZA OPIS DINAMIKE CIJENA DIONICA

stohastički proces, diskretan (kontinuiran) u vremenu, diskretna (kontinuirana) varijabla

Markovljev proces – samo danas određuje sutra

predikcije u terminima vjerojatnosti

Markovljev proces u suglasju sa slabom formom tzv. tržišne učinkovitosti — nemoguće je iz kre-tanja cijene zaključiti o cijeni sutra

WIENEROV PROCES ili Brownovo gibanje:

svojstvo 1)

$$\Delta S = \epsilon \sqrt{\Delta t} \quad (6)$$

svojstvo 2)

ΔS za različita vremena neovisna

za Δt slijedi

$$\langle \Delta S = 0 \rangle \quad \sigma^2 = \Delta t \quad (7)$$

Nakon vremena $T = N\Delta t$

$$S(T) - S(0) = \sum_{n=1}^N \epsilon_i \sqrt{\Delta t} \quad (8)$$

Varijanca, očekivanje $S(T) - S(0) = \text{????}$

ZA NORMALNE PROCESE VARIJANCE ADITIVNE

POOPĆENI WIENEROV PROCES (DETERMINIZAM + STOHASTIKA):

$$\Delta S = a dt + b \epsilon \sqrt{\Delta t} \quad (9)$$

a i b — očekivanje i varijanca u jedinici vremena

$$\Delta S = a dt \quad (10)$$

$$S = S_0 + a t \quad (11)$$

Varijanca, očekivanje $\Delta S = \text{??????}$

Varijanca, očekivanje $S(T) - S(0) = \text{????}$

ITOV PROCES:

$$dS = a(S, t) dt + b(S, t) \epsilon \sqrt{\Delta t} \quad (12)$$

PROBLEMI:

OČEKIVANI PRIRAST I RIZIK OVISE O TRENUOTNOJ VRIJEDNOSTI CIJENE

$$\Delta S/S_0 = a \Delta t/S_0 \quad (13)$$

NAJKORIŠTENIJI MODEL ZA OPIS DINAMIKE CIJENA:

$$\Delta S = \mu S \Delta t + \sigma S \epsilon \sqrt{\Delta t} \quad (14)$$

MONTE CARLO SIMULACIJE:

STACIONARNI ARMA PROCESI

OČEKIVANJA $\{y_1, y_2, y_3, \dots, y_T\}$

i.i.d.

$$\{\epsilon_1, \epsilon_2, \dots, \epsilon_T\}$$

$$\epsilon_t \sim iN(0, \sigma^2)$$

$$\{y_t\}_{t=-\infty}^{\infty} = \{\dots, y_{-1}, y_0, y_1, y_2, \dots\}$$

I KOMPJUTORA

$$\{y_t^{(1)}, y_t^{(2)}, \dots, y_t^{(I)}\}$$

uzorak I realizacija varijable Y

bezuvjetna gustoća $f(y_t)$

OČEKIVANJE (SREDNJA VRIJEDNOST) VARIJABLE Y_t

$$E(Y_t) = \int_{-\infty}^{\infty} y_t f(y_t) dy_t \quad (15)$$

$$E(Y_t) = \lim_{I \rightarrow \infty} \frac{1}{I} \sum_{i=1}^I Y_t^{(i)} \quad (16)$$

primjer

a)

$$Y_t = \mu + \epsilon_t \quad (17)$$

$$E(Y_t) = \mu \quad (18)$$

b)

$$Y_t = \beta t + \epsilon_t \quad (19)$$

$$E(Y_t) = \beta t \quad (20)$$

$$\sigma^2 = \gamma_{0t} = E(Y_t - \mu_t)^2 = \int (y_t - \mu_t)^2 f(y_t) dy_t \quad (21)$$

AUTOKOVARIJANCA

(drugi moment varijable Y)

$$\gamma_{j,t} = E(Y_t - \mu_t)(Y_{t-j} - \mu_{t-j}) \quad (22)$$

struktura autokovarijance kao u kovarijance

$$Cov(X, Y) = E(X - \mu_X)(Y - \mu_Y) \quad (23)$$

$$\gamma_{j-t} = \lim_{I \rightarrow \infty} \frac{1}{I} \sum_{i=1}^I (Y_t^{(i)} - \mu_t)(Y_{t-j}^{(i)} - \mu_{t-j}) \quad (24)$$

KOVARIJANTNA STACIONARNOST ILI SLABA KOVARIJANTNOST

slabo STACIONARAN — ni μ_t ni γ_{j-t} ne ovise o vremenu

$$E(Y_t) = \mu \quad (25)$$

$$E(Y_t - \mu)(Y_{t-j} - \mu) = \gamma_j \quad (26)$$

slijedi $\gamma_j = \gamma_{-j}$

STRIKTNA STACIONARNOST,
JOINT DISTRIBUCIJA OD $(Y_t, Y_{t+j_1}, \dots, Y_{t+j_n})$ NE OVISI O VREMENU
T

ERGODIČNOST

srednja vrijednost (vremenskog) uzorka

$$\bar{y} = \frac{1}{T} \sum_{i=1}^T y_t^1 \quad (27)$$

veza s srednjom vrijednošću uzorka preko pojma ergodičnosti prvog momenta

Ako je Y_t stacionaran Gaussov process uvjet ergodičnosti za sve momente je

$$\sum_{j=0}^{\infty} |\gamma_j| < \infty \quad (28)$$

Kovarijantno stacionaran proces je ergodičan u prvom momentu ako vrijeđa jednačina

$$E(Y_t) = \lim_{T \rightarrow \infty} 1/T \sum_i y_t \quad (29)$$

BIJELI ŠUM

$$E(\epsilon_t) = 0 \quad (30)$$

$$E(\epsilon_t^2) = \sigma^2 \quad (31)$$

$$E(\epsilon_t \epsilon_\tau) = 0 \quad (32)$$

striktni bijeli šum — ϵ_t i ϵ_τ neovisni.

KORELACIJSKI PROCESI — AR i MA

MOVING AVERAGE (MA) PROCESS

MA(1)

$$Y_t = \mu + \epsilon_t + \theta \epsilon_{t-1} \quad (33)$$

očekivanje i varijanca Y_t

$$E(Y_t) = \mu \quad (34)$$

$$E(Y_t - \mu)^2 = (1 + \theta^2)\sigma^2 \quad (35)$$

$$E(Y_t - \mu)(Y_{t-1} - \mu) = \theta\sigma^2 \quad (36)$$

Ako je ϵ Gaussov bijeli šum, MA(1) je ergodičan za sve momente (konačan broj kovarijanci)

j-ta autokorelacija $\rho_j = \gamma_j/\gamma_0$

AUTOKORELACIJA ρ_j je mjera korelacije ili veze izmedju Y_t i Y_{t-j} — koliko dugo se utjecaju pamte

za MA(1)

$$\rho_1 = \frac{\theta\sigma^2}{(1 + \theta^2)\sigma^2} \quad (37)$$

MA(q) proces

$$Y_t = \mu + \epsilon_t + \theta_1\epsilon_{t-1} + \dots + \theta_q\epsilon_{t-q}$$

MA(2)

neičezavajuće autokovarijance

$$\gamma_1 = (\theta_1 + \theta_1\theta_2)\sigma^2 \quad (38)$$

$$\gamma_2 = \theta_2\sigma^2 \quad (39)$$

ergodičan u prvom momentu
 ako je ϵ Gaussov process MA(2) ergodičan u svim momentima

AUTOREGRESIVNI PROCES

AR(1)

$$Y_t = c + \phi Y_{t-1} + \epsilon_t \quad (40)$$

iteracija
 uvjet za slabu stacionarnost $|\phi| < 1$

iteracijom kao $MA(\infty)$

$$Y_t = c(1 + \phi + \phi^2 + \dots) + \epsilon_t + \phi\epsilon_{t-1} + \phi^2\epsilon_{t-2} + \dots \quad (41)$$

$$E(Y_t) = c + \phi E(Y_{t-1}) \rightarrow \mu = c + \phi\mu \quad (42)$$

varijanca

$$\gamma_0 = E(Y_t - \mu)^2 = \sigma^2 / (1 - \phi^2) \quad (43)$$

j-ta autokovarijanca

$$\gamma_j = E(Y_t - \mu)(Y_{t-j} - \mu) = \phi^j(1 + \phi^2 + \phi^4 + \dots)\sigma^2 \quad (44)$$

$$\rho_j = \gamma_j / \gamma_0 = \phi^j \quad (45)$$

geometrijski red za autokorelacijsku funkciju

utjecaj parametra ϕ na korelaciju

ARMA PROCESI

LAG OPERATORI — operator vremenskog pomaka?

OPERATOR VREMENSKOG NIZA — preslikava jedan niz u drugi
multiplikativni operator — $y_t = \beta x_t$

operator zbrajanja — $y_t = x_t + z_t$

OPERATOR POMAKA U VREMENU

$$y_t = x_{t-1}$$

$$Lx_t = x_{t-1}$$

$$L^k x_t = x_{t-k}$$

zadovoljava ista algebarska pravila kao multiplikativni operator

$$y_t = (aL + bL)Lx_t$$

$$y_t = ax_{t-1} + bx_{t-2}$$

$aL + bL^2$ — operatorski polinom

PRIMJENA:

AR(2) process

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \epsilon_t$$

$$(1 - \phi_1 L - \phi_2 L^2)y_t = c + \epsilon_t$$

uvjet stabilnosti jednadžbe diferencija:

$$(1 - \phi_1 z - \phi_2 z^2) = 0$$

korijeni izvan jedinične kružnice

AR(2) — proces kovarijantno stacionaran

$$(1 - \lambda_1 L)^{-1} = 1 + \lambda_1^1 L + \lambda_1^2 L^2 + \dots$$

$$(1 - \lambda_1 L)(1 - \lambda_2 L)y_t = \epsilon_t$$

$$y_t = (1 - \lambda_1 L)^{-1}(1 - \lambda_2 L)^{-1}\epsilon_t$$

$$(\lambda_1 - \lambda_2)^{-1} \left\{ \frac{\lambda_1}{1-\lambda_1 L} - \frac{\lambda_2}{1-\lambda_2 L} \right\}$$

$$y_t = \left\{ \frac{\lambda_1}{\lambda_1 - \lambda_2} (1 + \lambda_1 L + \dots) - \frac{\lambda_2}{\lambda_1 - \lambda_2} (1 + \lambda_2 L + \dots) \right\} \epsilon_t$$

računanje očekivanja

pretpostavimo stacionarnost

$$E(Y_t) = c + \phi_1 E(Y_{t-1}) + \phi_2 E(Y_{t-2}) + E(\epsilon_t)$$

$$\mu = c + \phi_1 \mu + \phi_2 \mu$$

$$(Y_t - \mu) = \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \epsilon_t$$

pomnožimo s Y_{t-j}

$$\gamma_j = \phi_1 \gamma_{j-1} + \phi_2 \gamma_{j-2}, \quad j = 1, 2, \dots$$

struktura jednadžbe kao u procesa AR(2)

autokorelacije

$$\rho_j = \phi_1 \rho_{j-1} + \rho_{j-2} \quad j = 1, 2, \dots$$

$$j = 1 \quad \rho_1 = \phi_1 + \phi_2 \rho_1$$

$$j = 2 \quad \rho_2 = \phi_1 \rho_1 + \phi_2$$

varijanca:

$$E(Y_t - \mu)^2 = \phi_1 E(Y_{t-1} - \mu)(Y_t - \mu) + \phi_2 E(Y_{t-2} - \mu)(Y_t - \mu) + E(\epsilon_t)(Y_t - \mu)$$

$$\gamma_0 = \phi_1 \gamma_1 + \phi_2 \gamma_2 + \sigma^2$$

$$\gamma_0 = \phi_1 \rho_1 \gamma_0 + \phi_2 \rho_2 \gamma_0 + \sigma^2$$

$$\gamma_0 = \frac{(1-\phi_2)\sigma^2}{(1-\phi_2)((1-\phi_2)^2 - \phi_1^2)}$$

svani process Y_t prati niz autokovarijanci $\{\gamma_j\}$

ako je $\sum_j |\gamma_j| < \infty$

$$g_Y(z) = \sum_{j=-\infty}^{\infty} \gamma_j z^j \quad (46)$$

ako z leži na jediničnoj kružnici

POPULACIJSKI SPEKTAR PROCESA Y

$$s_Y(\omega) = \frac{1}{2\pi} \sum_i \gamma_j \exp(-i\omega j) \quad (47)$$

MA(1) proces:

$$Y_t = \mu + \epsilon_t + \theta \epsilon_{t-1} = c + (1 + \theta L)\epsilon$$

$$g_Y(z) = \theta \sigma^2 z^{-1} + ((1 + \theta^2)\sigma^2)z^0 + \theta \sigma^2 z^1 = \sigma^2(1 + \theta z)(1 + \theta z^{-1})$$

MA(q) proces:

$$Y_t = \mu + (1 + \theta_1 L + \dots + \theta_q L^q)\epsilon_t$$

$$g_Y(z) = \sigma^2(1 + \theta_1 L + \dots + \theta_q L^q)(1 + \theta_1 z^{-1} + \dots + \theta_q z^{-q})$$

MA(∞) proces:

$$Y_t = \mu + \psi(L)\epsilon_t$$

$$g_Y(z) = \sigma^2 \psi(z) \psi(z^{-1})$$

AR(1)

$$Y_t - \mu = (1 - \phi L)^{-1}\epsilon_t$$

METODA MAKSIMALNE VJERODOSTOJNOSTI

služi za procjenu parametara procesa

1. korak: određivanje funkcije vjerodostojnosti.

2.korak: traženje parametara za koje je vjerojatnost najveća

$$L = L(\theta, X_1, X_2, \dots, X_n)$$

MLE od θ je θ koji maksimizira L

DISKRETN VARIJABLA:

geometrijska distribucija $p = (1 - \theta)\theta^X$

$$L = P(X_1)P(X_2)P(X_n)$$

$$\log(L) = n\ln(1 - \theta) + \ln(\theta)\sum X_i$$

$$\log(L)' = 0$$

$$\tilde{\theta} = \frac{\hat{X}}{1+\hat{X}}$$

KONTINUIRANA VARIJABLA

Gaussova:

$$\ln(L) = \sum_i \ln(P(X_i))$$

$$\ln(L) = -0.5n\ln(2\pi) - 0.5n\sigma^2$$

$$- 0.5(1/\sigma^2)\sum_i (X_i - \mu)^2$$

$$\frac{\partial \ln(L)}{\partial \mu} = 0, \quad \frac{\partial \ln(L)}{\partial \sigma^2} = 0$$

$$\tilde{\mu} = \sum X_i / n$$

$$\tilde{\sigma}^2 = 1/n \sum_i (X_i - \tilde{\mu})^2$$

problem: nelinearnosti, vezane jednadžbe, numeričke metode

ARMA(p,q)

$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t + \dots + \phi_q \epsilon_{t-q}$ ϵ je bijeli šum

Neka je $\theta \equiv (c, \phi_i, \theta_i, \sigma^2)'$ vektor populacijskih parametara

uzorak T elemenata (y_1, \dots, y_T)

AR(1)

$$\theta \equiv (c, \phi, \sigma^2)$$

kolika je vjerojatnost prvog elementa?

pogledajmo očekivanja AR(1) procesa

ako je ϵ_t Gaussova i Y_t je Gaussova

gustoća vjerojatnosti prve varijable:

$$f_{Y_1}(y_1; \theta) \propto \frac{1}{E(Y_1 - \mu)^2} \exp\left(-\frac{[y_1 - E(Y_1)]^2}{2E(Y_1 - \mu)^2}\right)$$

distribucija druge varijable? kondicijalno na prvu

$$Y_2 = c + \phi Y_1 + \epsilon_2$$

$$Y_2 \text{ iz } N(c + \phi y_1, \sigma^2)$$

zajednička gustoća distribucije za uzorak od T elemenata

$$f(y_i; \theta) = f(y_1, \theta) \prod_{i=1}^T f(y_t | y_{t-1}; \theta)$$

$$\mathcal{L} = \ln f(y_1; \theta) + \sum_i \ln f(y_t | y_{t-1}; \theta)$$

KONDICIJALNA PROCJENA MAKSIMALNE VJERODOSTOJNOSTI

pojednostavljenje

prva se varijabla tretira kao deterministička

$$\ln f(y_t, \dots, y_2 | y_1; \theta) = \quad (48)$$

$$-((T-1)/2)(\ln(2\pi) + \ln\sigma^2) - \quad (49)$$

$$\sum_{t=2}^T \frac{(y_t - c - \phi y_{t-1})^2}{2\sigma^2} \quad (50)$$

maksimizacija c i ϕ ekvivalentna minimizaciji

$$\sum_{t=2}^T (y_t - c - \phi y_{t-1})^2$$

procjena varijance

$$\tilde{\sigma}^2 = \sum_{t=2}^T \frac{(y_t - \tilde{c} - \tilde{\phi} y_{t-1})^2}{T-1}$$

PROCJENA MAKSIMALNE VJERODOSTOJNOSTI

MA(1) kao i kod AR(1), izračun jednostavniji za MA(1) ako uvjetujemo početne vrijednosti ϵ

$$Y_t = \mu + \epsilon_t + \theta \epsilon_{t-1}$$

$$\epsilon_t \text{ iz } N(0, \sigma^2)$$

Neka $\theta = (\mu, \theta, \sigma^2)$ označuje populacijske parametre koje procjenjujemo. Ako ϵ_{t-1} poznajemo (nije slučajan)

$$Y_t | \epsilon_{t-1} \sim N((\mu + \theta \epsilon_{t-1}), \sigma^2)$$

$$f(y_t | \epsilon_{t-1}; \theta) = \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left(\frac{-(y_t - \mu - \theta \epsilon_{t-1})^2}{2\sigma^2}\right)$$

Neka je $\epsilon_0 = 0$. Kako je niz $\{y_t\}$ poznat, vrijedi

$$\epsilon_1 = y_1 - \mu$$

UOČIMO DA U PROCEDURI μ PROCIJENJUJEMO

nastavimo li proceduru, iz $\epsilon_0 = 0$ slijedi iteracijom niz $\{\epsilon_1, \dots, \epsilon_T\}$

$$\epsilon_t = y_t - \mu - \theta \epsilon_{t-1}$$

kondicijalna gustoća za t-observaciju

$$f(y_t | \epsilon_{t-1}; \theta) = \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left(\frac{-\epsilon_t^2}{2\sigma^2}\right)$$

vjerodostojnost uzorka — produkt pojedinačnih gustoća

$$f(y_T, y_{T-1}, \dots, y_1 | \epsilon_0, \theta) = f(y_1 | \epsilon_0 = 0; \theta) * \quad (51)$$

$$\Pi_{t=2}^T f(y_t | y_{t-1}, \dots, y_1, \epsilon_0 = 0; \theta) \quad (52)$$

kondicionalna log vjerodostojnost

$$\mathcal{L} = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log(\sigma^2) - \sum_t \frac{\epsilon_t^2}{2\sigma^2}. \quad (53)$$

\mathcal{L} je nelinearna funkcija μ i θ i observabli y_t NE INOVACIJA ϵ

numerička optimizacija

iteracijom:

$$\epsilon_t = (y_t - \mu) - \theta(y_{t-1} - \mu) + \dots + (-1)^{t-1} \theta^{t-1} (y_t - \mu) + (-\theta)^t \epsilon_0$$

KONDICIJALNA FUNKCIJA VJERODOSTOJNOSTI ZA MA(q) PROCES

$$\epsilon_0 = \dots = \epsilon_{-q+1} = 0$$

iz danih početnih vrijednosti iteracijom:

$$\epsilon_t = y_t - \mu - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q}$$

KONDICIJALNA FUNKCIJA VJERODOSTOJNOSTI ZA ARMA(p,q) PROCES

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t + \dots + \theta_q \epsilon_{t-q}$$

cilj: procjenjitelj $\theta = (c, \phi_i, \theta_j, \sigma^2)'$

aproksimacija je naći funkciju vjerodostojnosti kondicionalno na početne vrijednosti y i ϵ

1.) opcija je za početne vrijednosti y i ϵ uzeti očekivanja: $y_s = c/(1 - \phi_1 - \phi_p)$ za $s = 0, -1, \dots, -p+1$ i $\epsilon_s = 0$ za $s = 0, -1, -q+1$. 2) opcija (Box, Jenkins) za početne vrijednosti y_s uzeti stvarne vrijednosti

NUMERIČKA OPTIMIZACIJA

KAKO ŠTO BRŽR PREBRISATI PARAMETARSKI PROSTOR

GRID SEARCH

AR(1): s 3 na 1 parametar

$$\mathcal{L}(\phi) = \dots 1/2 \log(1 - \phi^2) - 1/2 (1 - \phi^2)y_1^2 - \quad (54)$$

$$1/2 \sum_{t=2}^T (y_t - \phi y_{t-1})^2 \quad (55)$$

recimo $T = 5, y_1 = 0.8, y_2 = 0.2, y_3 = -1.2, y_4 = -0.4, y_5 = 0$

$\phi = 0 \dots \mathcal{L} = -5.73; \phi = 0.1 \dots \mathcal{L} = -5.71$

subintervali

aprox rješenje — uvjet konvergencije

lokalni i globalni maksimumi

STEEPEST ASCENT — tražimo smjer najbržeg rasta

metoda ako imamo više parametara

početni a-parametarski vektor $\theta^{(0)}$

tražimo bolji procjenjitelj $\theta^{(1)}$ u a-dim prostoru unutar "radijusa" k

$$\{\theta^{(1)} - \theta^{(0)}\}' \{\theta^{(1)} - \theta^{(0)}\} = k$$

Lagrangean:

$$J(\theta^{(1)}) =$$

$$\mathcal{L}(\theta^{(1)}) + \lambda(k - \{\theta^{(1)} - \theta^{(0)}\}' \{\theta^{(1)} - \theta^{(0)}\})$$

$$\frac{\partial J(\theta)}{\partial \theta} |_{\theta=\theta^{(1)}} = 0$$

$$\theta^{(1)} = \theta^{(0)} + 1/(2\lambda) g(\theta^{(1)})$$

$$\mathcal{L}(\theta) = -1.5\theta_1^2 - 2\theta_2^2$$

očito je minimum u $\hat{\theta} = (0, 0)'$

što daje metoda??

neka je $\theta^{(0)} = (-1, 1)'$

često se u praksi derivacije traže numerički:

$$g_i \approx 1/\Delta \{ \mathcal{L}(\dots, \theta_i^{(0)} + \Delta, \dots) - \mathcal{L}(\dots, \theta_i^{(0)}, \dots) \}$$

lokalni ekstremi

$$\theta^{(m+1)} = \theta^{(m)} + sg(\theta^{(m)})$$

za mali smjer puno iteracija

pronadjimo globalni maksimum

$$s = 1/16, 1/8, 1/4, 1/2, 1, 2, 4, 8 \text{ i } 16$$

kriterij konvergencije, razmak medju susjednim θ

ponovimo proceduru za više inicijalnih $\theta^{(0)}$

metoda NEWTON-RAPHSON

(a) ako postoji druga derivacija $\mathcal{L}(\theta)$ (b) ako -1 pomnožen s matricom drugih derivacija je svugdje pozivno definiran

Neka vrijedi:

$$g(\theta^{(0)}) = \frac{\partial \mathcal{L}(\theta)}{\partial \theta} |_{\theta=\theta^{(0)}}$$

i neka vrijedi

$$H(\theta^{(0)}) = -\frac{\partial^2 \mathcal{L}(\theta)}{\partial \theta \partial \theta'}|_{\theta=\theta^{(0)}}$$

aproksimirajmo $\mathcal{L}(\theta)$ Taylorovim redom do drugog reda u razvoju oko $\theta^{(0)}$

$$\mathcal{L}(\theta) \approx \mathcal{L}(\theta^{(0)}) + [g(\theta^{(0)})]'[\theta - \theta^{(0)}] - \quad (56)$$

$$1/2(\theta - \theta^{(0)})' H(\theta^{(0)})[\theta - \theta^{(0)}] \quad (57)$$

$$g(\theta^{(0)}) = H(\theta^{(0)})(\theta - \theta^{(0)})$$

$$\theta^{(1)} = \theta^{(0)} + [H(\theta^{(0)})]^{-1}g(\theta^{(0)})$$

iteracija

primjer

ASIMPTOTSKE STANDARDNE GREŠKE ZA PROCJENJITELJE

za dovoljno velike uzorke distribucija procjenjitelja $\hat{\theta}$ aproksimativno slijedi distribuciju:

$$N(\theta_0, T^{-1}\mathcal{P}^{-1})$$

gdje je $\theta^{(0)}$ praci parameteraski vektor. Matrica \mathcal{P} se naziva *informacijska matrica* i procjenjuje se.

prvi procjenjitelj:

$$\mathcal{P}_{2D} = -T^{-1}\frac{\partial^2 \mathcal{L}}{\partial \theta \partial \theta'}|_{\theta=\hat{\theta}}$$

matrica varijanci - kovarijanci

$$E(\hat{\theta}_0)(\hat{\theta} - \theta_0)' \approx [-\frac{\partial^2 \mathcal{L}(\theta)}{\partial \theta \partial \theta'}]^{-1}$$

drugi procjenjitelj:

$$\mathcal{P}_{OP} = T^{-1}\Sigma_{t=1}^T[h(\hat{\theta})][h(\hat{\theta})]'$$

$$h(\hat{\theta}) = \frac{\partial \log(f(y_t | y_{t-1}; \theta))}{\partial \theta}|_{\theta=\hat{\theta}}$$

$$E(\hat{\theta} - \theta_0)(\hat{\theta} - \theta_0) \approx [\Sigma[h(\hat{\theta}, \mathcal{Y}_t)][h(\hat{\theta}, \mathcal{Y}_t)]']^{-1}$$

primjer:

REFERENCES