

TARTU RIIKLIK ÜLIKOOL
Matemaatilise statistika
ja programmeerimise kateeder

*Subada kaitmisele
18. VI 73.
Laan*

MONINGAID KUSIMUSI REGRESSIOONANALUUSIST

D i p l o m i t ö ö

Töö teostaja: Urve Tellas
V k. üliõpil.

Töö juhendaja: A. Parring

Tartu 1973

SISSEJUHATUS

Käesoleva diplomitöö eesmärgiks on leida sobiv meetod mittelineaarse regressioonanalüüsi ülesande lahendamiseks ja koostada leitud meetodit realiseeriv programm arvutile "MINSK-32" algoritmilises keeles ALGOL.

Olgu antud k argumenti x_1, x_2, \dots, x_k ja neist sõltuv suurus y . Muutujad x_i pole üldiselt juhuslikud, vaid on igas vaatlusseerias täielikult määratud. Suurus y on aga normaaljaotusega juhuslik suurus dispersiooniga σ^2 , mis ei sõltu argumentidest ja keskväertusega Ey , mis avaldub nn. regressioonifunktsioonina

$$Ey = f(x_1, x_2, \dots, x_k; \beta_1, \beta_2, \dots, \beta_m).$$

Olgu tehtud n sõltumatust vaatlusest koosnev katseeria, millele vastavad suurused $y_i, x_{i1}, x_{i2}, \dots, x_{ik}$ ($i = 1, 2, \dots, n$). Ulesannet, mis seisneb funktsiooni $f(\vec{x}, \vec{\beta})$ kuju määramises nimetatakse regressioonanalüüsi ülesandeks. Meil olgu teada selle funktsiooni üldine kuju ja hinnata tuleb tundmatuid parameetreid β_j ($j = 1, 2, \dots, m$).

Töö I peatükk on pühendatud lineaarsele regressioonanalüüsi ülesandele ja selle lahendamisele vähimruutude meetodil. II peatükis vaadatakse mittelineaarse ülesande lahendamist. On ära toodud gradientmeetod ja funktsiooni Tayloriga ritta arendamise meetod ning nendel meetoditel põhinev maksimaalse ümbruse meetod. Töö III peatükis on juttu maksimaalse ümbruse meetodi kohta koostatud programmist.

I. LINEAARSE REGRESSIOONANALUUSI

ULESANDE LAHENDAMINE

§ 1. Regressiooni üldistatud mudel.

Olgu antud teatud argumentidest ja parameetritest sõltuva juhusliku suuruse y väärtused y_i , kus $i = 1, 2, \dots, n$ ning iga i korral väärtusele y_i vastavad argumentide x_1, x_2, \dots, x_k väärtused $x_{i1}, x_{i2}, \dots, x_{ik}$.

Oletame, et y sõltuvus argumentidest ja tundmatutest parameetritest $\beta_1, \beta_2, \dots, \beta_m$ on selline, et

$$E(y) = f(x_1, x_2, \dots, x_k; \beta_1, \beta_2, \dots, \beta_m). \quad (1)$$

Seost (1) nimetatakse regressiooniseoseks ehk regressiooni üldistatud mudeliks.

Regressiooni üldistatud mudelit kirjeldab seega võrrand

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{ik}; \beta_1, \beta_2, \dots, \beta_m) + \epsilon_i$$

ehk lühemalt

$$\vec{y} = \vec{f}(X, \vec{\beta}) + \vec{\epsilon}, \quad (2)$$

kus

$$\vec{y} = \begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{pmatrix}, \quad \vec{\beta} = \begin{pmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_m \end{pmatrix},$$

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nk} \end{pmatrix},$$

$$\vec{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{pmatrix}$$

($\vec{\varepsilon}$ on juhuslike jääkide vektor).

§ 2. Vähimruutude meetod.

Olgu antud lineaarne regressioonanalüüsi ülesanne kujul:

$$E(y_i) = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_r x_{ir}$$

e. lühemalt

$$E(\vec{y}) = X\vec{\beta}.$$

Tuleb leida kordajate β_j ($j = 1, 2, \dots, r$) sellised hinnangud, et hinnang suurusele $E(\vec{y})$ erineks võimalikult vähe suurusest \vec{y} .

Minimiseerime hälvete ruutude summa:

$$\begin{aligned} \varphi^2(\vec{\beta}) &= \varphi^2(\beta_1, \beta_2, \dots, \beta_r) = \\ &= (\vec{y} - X\vec{\beta})'(\vec{y} - X\vec{\beta}) = \\ &= \sum_{i=1}^n (y_i - \beta_1 x_{i1} - \dots - \beta_r x_{ir})^2. \end{aligned}$$

Võrdsustades funktsiooni $\varphi^2(\vec{\beta})$ tuletised β_j järgi nulliga, saame võrrandisüsteemi:

$$\frac{\partial \varphi^2}{\partial \beta_j} = \sum_{i=1}^n [-2 x_{ij} (y_i - \beta_1 x_{i1} - \dots - \beta_p x_{ip})] = 0,$$

$$j = 1, 2, \dots, p.$$

See süsteem on samaväärne järgmisega [3]:

$$\sum_{i=1}^n x_{i1} y_i = \sum_{i=1}^n \sum_{k=1}^p \beta_k x_{i1} x_{ik}$$

.....

$$\sum_{i=1}^n x_{ip} y_i = \sum_{i=1}^n \sum_{k=1}^p \beta_k x_{ip} x_{ik}$$

ehk maatriksikujul:

$$X'X\vec{\beta} = X'\vec{y} \quad (2')$$

Saadud võrrandisüsteemi (2') nimetatakse normaalvõrrandite süsteemiks.

Normaalvõrrandite süsteemi lahendamisel arvestame asjaolu, et $X'X$ on p - järku ruutmaatriks astakuga p ning tal eksisteerib pöördmaatriks tavalises mõttes.

Tähistades

$$C = (X'X)^{-1}$$

ning korrutades süsteemi (2) mõlemat poolt vasakult maatriksiga C , saamegi normaalvõrrandite süsteemi lahendi \vec{b} kujul

$$\vec{b} = CX'\vec{y}.$$

Et juhusliku suuruse y dispersiooni hinnang avaldub antud juhul: ([1], lk.199):

$$s^2 = \frac{\varphi^2(\vec{b})}{n-p}$$

ja kordajate kovariatsioonimaatriksi hinnang saadakse dispersiooni korrutamisel maatriksiga C ([1], lk.198) s.t.

$$\text{cov}(\vec{b}, \vec{b}) = s^2 C,$$

siis avalduvad kordajate kovariatsioonide hinnangud valemiga

$$\text{cov}(b_i, b_j) = s^2 c_{ij}$$

ning dispersioonide hinnangud:

$$V(b_i) = s^2 c_{ii},$$

kus $C = \|c_{ij}\|$ ($i = 1, 2, \dots, \nu,$
 $j = 1, 2, \dots, \nu$).

II. MITTELINEAARSE REGRESSIOONANALUUSI

ULESANDE LAHENDAMINE

Ülesande seade on sama nagu üldisel juhul (vt. I § 1).

Võrrandis

$$\vec{y} = \vec{f}(x, \vec{\beta}) + \vec{\varepsilon} \quad (1)$$

esinev funktsioon $\vec{f}(x, \vec{\beta})$ on mittelineaarse ülesande korral parameetrite $\beta_j (j = 1, 2, \dots, m)$ suhtes mittelineaarne.

Püüame ka seda ülesannet lahendada vähimruutude meetodil. Selleks arvutame hälvete ruutude summa Q , mis avaldub mitmemuutuja funktsioonina β_j järgi:

$$Q = Q(\vec{\beta}) = \sum_{i=1}^n (f_i - y_i)^2 = \sum_{i=1}^n \varepsilon_i^2$$

Vähimruutude meetodi põhjal tuleks võrdsustada nulliga funktsiooni Q tuletised β_j järgi. Et funktsioon $Q(\vec{\beta})$ on aga mittelineaarne β_j suhtes, siis on saadud võrrandisüsteemi lahendamine täpsete meetoditega küllalt komplitseeritud.

Q minimiseerimiseks saab kasutada mitmeid ligikaudseid meetodeid, mis jagunevad kahte põhiklassi:

- 1) gradientmeetodid
- 2) funktsiooni Tayloriga ritta arendamise meetodid.

§ 1. Gradientmeetod.

Gradientmeetodi korral lähenetakse samm-sammult otsitavale funktsiooni Q minimiseerivale vektorile $\vec{\beta}$. Kui λ -ndal sammul on leitud parameetrite vektor $\vec{\beta}^{(\lambda)}$ ja talle vastab hälvete ruutude summa Q_λ , siis tuleb leida uus lähendvektor $\vec{\beta}^{(\lambda+1)}$ nii, et suuruse $Q_{\lambda+1}$ väärtus oleks võimalikult palju väiksem suuruse Q_λ väärtusest.

Liikumise suund lähtepunktist $\vec{\beta}^{(\lambda)}$ määratakse nii, et funktsioon $Q(\vec{\beta})$ kahaneks selles suunas kõige kiiremini s.t. vastassuunas funktsiooni $Q(\vec{\beta})$ gradiendile antud punktis:

$$\vec{g}_\lambda = \left\| \begin{array}{c} \frac{\partial Q}{\partial \beta_1} \\ \dots \\ \frac{\partial Q}{\partial \beta_m} \end{array} \right\|$$

Seega saame uue parameetrite vektori

$$\vec{\beta}^{(\lambda+1)} = \vec{\beta}^{(\lambda)} - \lambda_\lambda \vec{g}_\lambda,$$

kus $\lambda_\lambda > 0$ ja λ_λ -ga on tähistatud sammu pikkus suunas $(-\vec{g}_\lambda)$.

Kordaja λ_λ määramiseks vaatame skalaarfunktsiooni

$$\phi(\lambda) = Q[\vec{\beta}^{(\lambda)} - \lambda \vec{g}_\lambda].$$

Funktsioon ϕ kujutab endast funktsiooni $Q(\vec{\beta})$ väärt-

tust $(s + 1)$ - sel sammul. Kordaja $\lambda = \lambda_s$ tuleb valida selliselt, et funktsioon $\Phi(\lambda)$ saavutaks miinimumi. Leides $\Phi(\lambda)$ tuletise λ järgi ja võrdsustades selle nulliga, saame võrrandi

$$\Phi'(\lambda) = \frac{d}{d\lambda} Q[\vec{\beta}^{(s)} - \lambda \vec{g}_s] = 0. \quad (2)$$

võrrandi (2) väikseim positiivne lahend annabki λ_s väärtuse.

Oletame, et λ on küllalt väike selleks, et võib arvestamata jätta ta ruudud ja kõrgemad astmed. Siis võime arendada funktsiooni $f_i(\vec{\beta}^{(s)} - \lambda \vec{g}_s)$ punkti $\vec{\beta}^{(s)}$ ümbruses lineaarliikme täpsusega astmeritta. Saame:

$$\Phi(\lambda) = \sum_{i=1}^n [f_i(\vec{\beta}^{(s)}) - y_i - \lambda \frac{\partial f_i(\vec{\beta}^{(s)})}{\partial \vec{\beta}} \cdot \vec{g}_s]^2,$$

kus

$$\frac{\partial f_i}{\partial \vec{\beta}} = \left[\frac{\partial f_i}{\partial \beta_1}, \frac{\partial f_i}{\partial \beta_2}, \dots, \frac{\partial f_i}{\partial \beta_m} \right].$$

Siit, leides tuletise, saame:

$$\Phi'(\lambda) = -2 \sum_{i=1}^n [f_i(\vec{\beta}^{(s)}) - y_i - \lambda \frac{\partial f_i(\vec{\beta}^{(s)})}{\partial \vec{\beta}} \cdot \vec{g}_s] \times$$

$$\times \frac{\partial f_i(\vec{\beta}^{(s)})}{\partial \vec{\beta}} \cdot \vec{g}_s = 0.$$

Otsitav kordaja λ_s avaldub seega ([4], lk.487):

$$\lambda_s = \frac{\sum_{i=1}^n (f_i(\vec{\beta}^{(s)}) - y_i) \cdot \frac{\partial f_i(\vec{\beta}^{(s)})}{\partial \vec{\beta}} \cdot \vec{g}_s}{\sum_{i=1}^n \left[\frac{\partial f_i(\vec{\beta}^{(s)})}{\partial \vec{\beta}} \cdot \vec{g}_s \right]^2} =$$

$$\frac{(\vec{f}(\vec{\beta}^{(s)}) - \vec{y}, P(\vec{\beta}^{(s)}) \cdot \vec{g}_s)}{(P(\vec{\beta}^{(s)}) \cdot \vec{g}_s, P(\vec{\beta}^{(s)}) \cdot \vec{g}_s)},$$

kus

$$P(\vec{\beta}) = \frac{\partial \vec{f}}{\partial \vec{\beta}} = \begin{vmatrix} \frac{\partial f_1}{\partial \beta_1} & \frac{\partial f_1}{\partial \beta_2} & \dots & \frac{\partial f_1}{\partial \beta_m} \\ \frac{\partial f_2}{\partial \beta_1} & \frac{\partial f_2}{\partial \beta_2} & \dots & \frac{\partial f_2}{\partial \beta_m} \\ \dots & \dots & \dots & \dots \\ \frac{\partial f_n}{\partial \beta_1} & \frac{\partial f_n}{\partial \beta_2} & \dots & \frac{\partial f_n}{\partial \beta_m} \end{vmatrix}$$

on vektorfunktsiooni $\vec{f}(\vec{\beta})$ jakobiaan.

Kuna

$$\begin{aligned} \frac{\partial Q}{\partial \beta_j} &= \frac{\partial}{\partial \beta_j} \left[\sum_{i=1}^n (f_i(\vec{\beta}) - y_i)^2 \right] = \\ &= 2 \sum_{i=1}^n [f_i(\vec{\beta}) - y_i] \cdot \frac{\partial f_i(\vec{\beta})}{\partial \beta_j}, \end{aligned}$$

siis

$$\begin{aligned} \vec{g} &= 2 \cdot \begin{vmatrix} \sum_{i=1}^n \frac{\partial f_i(\vec{\beta})}{\partial \beta_1} \cdot [f_i(\vec{\beta}) - y_i] \\ \dots \\ \sum_{i=1}^n \frac{\partial f_i(\vec{\beta})}{\partial \beta_m} \cdot [f_i(\vec{\beta}) - y_i] \end{vmatrix} = \\ &= 2 P'(\vec{\beta}) \cdot [\vec{f}(\vec{\beta}) - \vec{y}], \end{aligned}$$

kus $P'(\vec{\beta})$ - ga on tähistatud $P(\vec{\beta})$ transponeeritud maatriks.

Tähistades lühemalt

$$\vec{f}^{(s)} = \vec{f}(\vec{\beta}^{(s)}),$$

$$P_s = P(\vec{\beta}^{(s)}),$$

saame:

$$\lambda_s = \frac{(\vec{f}^{(s)} - \vec{y}, 2P_s \cdot P_s'(\vec{f}^{(s)} - \vec{y}))}{(2P_s \cdot P_s'(\vec{f}^{(s)} - \vec{y}), 2P_s \cdot P_s'(\vec{f}^{(s)} - \vec{y}))}$$

ehk

$$\mu_s = 2\lambda_s = \frac{(\vec{f}^{(s)} - \vec{y}, P_s \cdot P_s'(\vec{f}^{(s)} - \vec{y}))}{(P_s \cdot P_s'(\vec{f}^{(s)} - \vec{y}), P_s \cdot P_s'(\vec{f}^{(s)} - \vec{y}))}$$

ja

$$\vec{\beta}^{(s+1)} = \vec{\beta}^{(s)} - \mu_s P'(\vec{f}^{(s)} - \vec{y}),$$

$$(s = 0, 1, 2, \dots).$$

§ 2. Funktsiooni Tayloriga rittaarendamise meetod.

Rittaarendamise meetodi puhul teostatakse funktsiooni $f(x, \vec{\beta})$ reaksarendus punkti $(\beta_1, \beta_2, \dots, \beta_m)$ ümbruses lineaarliikme täpsusega:

$$\begin{aligned}
 f(x, \vec{\beta}) &= f(x, \vec{\beta}^{(A)}) + \frac{\partial f}{\partial \beta_1^{(A)}} (\beta_1 - \beta_1^{(A)}) + \\
 &\quad + \dots + \frac{\partial f}{\partial \beta_m^{(A)}} (\beta_m - \beta_m^{(A)}) = \\
 &= f(x, \vec{\beta}^{(A)}) + \sum_{j=1}^m \frac{\partial f}{\partial \beta_j^{(A)}} \cdot \delta_j^{(A)},
 \end{aligned}$$

kus

$$\delta_j^{(A)} = \beta_j - \beta_j^{(A)}$$

on parameetri β_j muut.

Regressioonimudeli (1) võib kirjutada nüüd kujul:

$$y_i = f_i(x, \vec{\beta}^{(A)}) + \sum_{j=1}^m \frac{\partial f_i}{\partial \beta_j^{(A)}} \delta_j^{(A)} + \varepsilon_i \quad (3)$$

kus tundmatuteks parameetriteks on suurused $\delta_1^{(A)}$, $\delta_2^{(A)}$, ..., $\delta_m^{(A)}$; Nende parameetrite suhtes on võrrand (3) lineaarne. Seetõttu võib siin kasutada I peatükis kirjeldatud vähimruutude meetodit.

Normaalvõrrandite süsteemi saame ülesande (3) jaoks kujul:

$$P'P\vec{\delta}^{(A)} = -P'(\vec{f} - \vec{y}), \quad (4)$$

kus P-ga on tähistatud $n \times m$ maatriks nagu § 1-s. Võrrandite süsteemist (4) leiame

ehk

$$\vec{\delta}^{(\Delta)} = -A^{-1} P'(\vec{f} - \vec{y}), \quad (5)$$

kus

$$A = \|\alpha_{j_1, j_2}\| = \left\| \sum_{i=1}^n \frac{\partial f_i}{\partial \beta_{j_1}} \cdot \frac{\partial f_i}{\partial \beta_{j_2}} \right\|,$$

($j_1, j_2 = 1, 2, \dots, m$)

ja

$$P'(\vec{f} - \vec{y}) = \left\| \sum_{i=1}^n \frac{\partial f_i}{\partial \beta_j} (f_i - y_i) \right\|.$$

Kasutades leitud parandusvektorit $\vec{\delta}^{(\Delta)}$, saame:

$$\vec{\beta}^{(\Delta+1)} = \vec{\beta}^{(\Delta)} + \vec{\delta}^{(\Delta)}$$

Praktikas on protsessi parema koondumise huvides kasulik leida uus parameetrite vektor nii [2]:

$$\vec{\beta}^{(\Delta+1)} = \vec{\beta}^{(\Delta)} + \kappa \cdot \vec{\delta}^{(\Delta)}$$

kus $\kappa > 0$.

Taylori ritta arendamise meetodi põhiliseks puuduseks on asjaolu, et meetod küllalt sageli ei koonu. Selle põhjuseks on, et võrrand (3) ei approksimeeri küllalt hästi võrrandit (1) või pole alglähend küllalt hästi valitud.

§ 3. Maksimaalse ümbruse meetod.

Gradientmeetod on efektiivsem just esimestel sammu-

del. Taylori ritta arendamise meetod aga küllalt lähedal hälvete ruutude summa otsitavale miinimumile s.t. lõpuosas. Nende meetodite eelised on ära kasutatud nn. maksimaalse ümbruse meetodis, mis algul käitub nagu gradientmeetod, lõpul aga nagu funktsiooni Taylori ritta arendamise meetod. Meetodi põhimõte on niisiis selline, et liigutakse gradientmeetodi poolt soovitud suunas seni, kuni jõutakse funktsiooni $Q(\vec{\beta})$ miinimumile küllalt lähedale, siis minnakse üle rittaarenduse meetodi poolt soovitatud suunale.

Ehitame hälvete ruutude summa mittelineaarse regressioonimudeli (1) jaoks:

$$Q(\vec{\beta}) = \sum_{i=1}^n (f_i - y_i)^2.$$

Selle funktsiooni gradient avaldub kujul:

$$\| \vec{g}_j \| = \left\| \sum_{i=1}^n (f_i - y_i) \frac{\partial f_i}{\partial \beta_j} \right\|,$$

$j = 1, 2, \dots, m.$

Tähistades ümber

$$\vec{g} = -\vec{g},$$

tuleks gradientmeetodi põhjal minna punktist $\vec{\beta}^{(A)}$ suunas $-\vec{g}$, Taylori rea meetodi põhjal aga suunas $\vec{\delta}$. Avaldise (5) põhjal

$$\vec{\delta} = \frac{1}{2} A^{-1} \vec{g}.$$

Vajalik suund peaks olema seega \vec{g} ja $A^{-1} \vec{g}$ vahel.

Selline vahepealne suund saadakse matriksi A diagonaalelementidele mingi positiivse suuruse λ lisamisega.

Lemma. Olgu \vec{x} ja \vec{y} vektorid ning vektor \vec{z} avaldu-
gu nende kaudu järgmiselt:

$$\vec{z} = \vec{y} + \lambda \vec{x}.$$

Siis

$$1) \quad \cos \varphi_1 = \cos (\vec{z}, \vec{x})$$

osutub iga λ korral kasvavaks funktsi-
ooniks,

$$2) \quad \cos \varphi_2 = \cos (\vec{z}, \vec{y})$$

aga $\lambda > 0$ korral kahanevaks ja $\lambda < 0$
korral kasvavaks funktsiooniks.

Tõestus.

1) Kahe vektori vahelise nurga koosinus
leitakse järgneva valemi põhjal¹:

$$\begin{aligned} \cos \varphi_1 &= \cos (\vec{z}, \vec{x}) = \\ &= \frac{(\vec{z}, \vec{x})}{\|\vec{z}\| \cdot \|\vec{x}\|} = \frac{(\vec{y}, \vec{x}) + \lambda (\vec{x}, \vec{x})}{\|\vec{y} + \lambda \vec{x}\|} \end{aligned}$$

Suurus $\|\vec{x}\|$ on konstantne. Esimese väite tõesta-
miseks on vaja näidata, et funktsioon

$$f_1(\lambda) = \frac{(\vec{y}, \vec{x}) + \lambda (\vec{x}, \vec{x})}{\|\vec{y} + \lambda \vec{x}\|}$$

on kasvav.

¹ Tähistame vektori \vec{x} normi $\|\vec{x}\|$ -ga.

Lühiduse mõttes tähistame:

$$(\vec{y}, \vec{x}) = a,$$

$$\|\vec{y}\| = c,$$

$$\|\vec{x}\| = b.$$

Vektori pikkuse definitsiooni põhjal:

$$f_1(\lambda) = \frac{a + \lambda b^2}{\sqrt{c^2 + 2\lambda a + \lambda^2 b^2}}$$

ja

$$\begin{aligned} f_1'(\lambda) &= \frac{b^2 \sqrt{c^2 + 2\lambda a + \lambda^2 b^2} - \frac{(a + \lambda b^2)^2}{\sqrt{c^2 + 2\lambda a + \lambda^2 b^2}}}{c^2 + 2\lambda a + \lambda^2 b^2} = \\ &= \frac{b^2(c^2 + 2\lambda a + \lambda^2 b^2) - (a^2 + 2\lambda a b^2 + \lambda^2 b^4)}{(c^2 + 2\lambda a + \lambda^2 b^2)^{3/2}} = \\ &= \frac{b^2 c^2 + 2\lambda a b^2 + \lambda^2 b^4 - a^2 - 2\lambda a b^2 - \lambda^2 b^4}{(c^2 + 2\lambda a + \lambda^2 b^2)^{3/2}} = \\ &= \frac{b^2 c^2 - a^2}{(c^2 + 2\lambda a + \lambda^2 b^2)^{3/2}}. \end{aligned}$$

Viimase murru lugeja

$$b^2 c^2 - a^2$$

on mittenegatiivne Cauchy-Bunjakovski võrratuse põhjal. Nimetaja kujutab endast normi kuubi:

$$\begin{aligned} & (c^2 + 2\lambda a + \lambda^2 b^2)^{3/2} = \\ & = (\|\vec{y}\|^2 + 2\lambda(\vec{y}, \vec{x}) + \lambda^2 \|\vec{x}\|^2)^{3/2} = \\ & = \|\vec{y} + \lambda\vec{x}\|^3 \end{aligned}$$

ning on seega samuti mittenegatiivne.

Järelikult

$$f_1'(\lambda) \geq 0,$$

millega ongi näidatud, et funktsioon $f_1(\lambda)$, ühtlasi aga ka $\cos \varphi_1$ on kasvav funktsioon iga λ korral.

2) Analoogilist mõttekäiku ning samu tähistusi kasutades saame, et

$$f_2(\lambda) = \frac{\|\vec{y}\|^2 + \lambda(\vec{x}, \vec{y})}{\|\vec{y} + \lambda\vec{x}\|} = \frac{c^2 + \lambda a}{\sqrt{c^2 + 2\lambda a + \lambda^2 b^2}}$$

ja

$$f_2'(\lambda) = \frac{\lambda(a^2 - b^2 c^2)}{(c^2 + 2\lambda a + \lambda^2 b^2)^{3/2}}.$$

Arvestades, et

$$a^2 \leq b^2 c^2,$$

saame, et funktsioon $\cos \varphi_2$ on kasvav $\lambda < 0$ korral ning kahanev $\lambda > 0$ korral.


Tähistame gradientmeetodi poolt soovitatud suuna \vec{g} -ga. Taylori ritta arendamise meetodi poolt soovitatud suuna \vec{d}_t -ga,

$$\vec{\delta}_t = A^{-1}\vec{q}$$

ning maksimaalse ümbruse meetodi poolt soovitatud suuna $\vec{\delta}_m$ -ga,

$$\vec{\delta}_m = (A + \lambda I)^{-1}\vec{q}.$$

Näitame, et suund $\vec{\delta}_m$ jääb alati suundade \vec{q} ja $\vec{\delta}_t$ vahele, kaldudes rohkem kas \vec{q} või $\vec{\delta}_t$ poole, olenevalt λ suurusest.



Teoreem. Positiivse λ korral on

$$1) F_1(\lambda) = \cos \varphi_1 = \cos(\widehat{\vec{\delta}_m, \vec{q}})$$

λ suhtes kasvav ning

$$F_2(\lambda) = \cos \varphi_2 = \cos(\widehat{\vec{\delta}_m, \vec{\delta}_t})$$

λ suhtes kahanev funktsioon ning

$$2) \lambda \rightarrow 0 \text{ korral } \varphi_2 \rightarrow 0 \text{ ja}$$

$\lambda \rightarrow \infty$ korral $\varphi_1 \rightarrow 0$, kusjuures

$$\vec{\delta}_m = (A + \lambda I)^{-1}\vec{q}$$

ja

$$\vec{\delta}_t = A^{-1}\vec{q}.$$

Tõestus:

1) Teoreemi eeldusest järeldub, et

$\vec{g} = (A + \lambda I) \vec{\sigma}_m$ Muutes tähistusi:

$$\begin{aligned}\vec{z} &= \vec{g}, \\ \vec{y} &= A \vec{\sigma}_m, \\ \vec{x} &= \vec{\sigma}_m,\end{aligned}$$

saame lemma põhjal, et $\cos \varphi_1 = \cos(\vec{\sigma}_m, \hat{\vec{g}})$
on kasvav λ suhtes.

Teoreemi eeldusest saame ka, et

$$A \vec{\sigma}_t = \vec{g} = (A + \lambda I) \vec{\sigma}_m = A \vec{\sigma}_m + \lambda \vec{\sigma}_m$$

ja

$$\vec{\sigma}_t = A^{-1} A \vec{\sigma}_m + \lambda A^{-1} \vec{\sigma}_m = \vec{\sigma}_m + \lambda A^{-1} \vec{\sigma}_m.$$

Muutes tähistusi:

$$\begin{aligned}\vec{z} &= \vec{\sigma}_t, \\ \vec{x} &= A^{-1} \vec{\sigma}_m, \\ \vec{y} &= \vec{\sigma}_m.\end{aligned}$$

saame lemma põhjal, et $\cos \varphi_2 = \cos(\vec{\sigma}_m, \hat{\vec{\sigma}}_t)$ on po-
sitiivse λ korral kahanev funktsioon.

2) $F_1(\lambda)$ ja $F_2(\lambda)$ on λ suhtes pidevad funktsioonid
ning neil on üheselt määratud piirväärtused:

$$\lim_{\lambda \rightarrow 0} \cos \varphi_2 = F_2(0) = \frac{(A^{-1} \vec{g}, A^{-1} \vec{g})}{\|A^{-1} \vec{g}\| \cdot \|A^{-1} \vec{g}\|} = 1,$$

$$\lim_{\lambda \rightarrow \infty} \cos \varphi_1 = \lim_{\lambda \rightarrow \infty} \frac{(\vec{g}, (A + \lambda I)^{-1} \vec{g})}{\|\vec{g}\| \cdot \|(A + \lambda I)^{-1} \vec{g}\|} =$$

$$= \frac{(\vec{g}, [\lim_{\lambda \rightarrow \infty} (A + \lambda I)]^{-1} \vec{g})}{\|\vec{g}\| \cdot \|[\lim_{\lambda \rightarrow \infty} (A + \lambda I)]^{-1} \|\cdot \|\vec{g}\|} =$$

$$\frac{[\lim_{\lambda \rightarrow \infty} (A + \lambda I)]^{-1} (\vec{g}, \vec{g})}{[\lim_{\lambda \rightarrow \infty} (A + \lambda I)]^{-1} \cdot \|\vec{g}\| \cdot \|\vec{g}\|} = 1$$

Saime, et

$$\lim_{\lambda \rightarrow 0} \cos \varphi_1 = 1 \quad \text{s.t.} \quad \lim_{\lambda \rightarrow 0} \varphi_1 = 0$$

ja

$$\lim_{\lambda \rightarrow \infty} \cos \varphi_2 = 1 \quad \text{i.t.} \quad \lim_{\lambda \rightarrow \infty} \varphi_2 = 0$$

m. o. t. t.

Teoreemist järeldub, et muutes λ suurust, saab valida suuna $\vec{\sigma}_m = (A + \lambda I)^{-1} \vec{g}$ kas küllalt lähedale gradientmeetodil leitud suunale \vec{g} või suunale $\vec{\sigma}_t = A^{-1} \vec{g}$, mis leitakse funktsiooni Taylori ritta arendamise meetodil. Kui vähendame λ -t, siis läheneme suunale $\vec{\sigma}_t$ ja kui suurendame λ -t, siis läheneme suunale \vec{g} . Piiril, kui $\lambda = 0$, saame $\vec{\sigma}_m = \vec{\sigma}_t$ ja kui $\lambda = \infty$, siis $\vec{\sigma}_m = \vec{g}$.

Praktikas korrigeeritakse maatriksit A siiski mitte λ abil, vaid suuruse λa_{jj} abil, kus a_{jj} on maatriksi A diagonaalelement.

Lahendusalgoritm on järgmine:

1. Mingitel kaalutlustel on eksperimenteerija valinud otsitavate parameetrite vektorile $\vec{\beta}$ alglähendi $\vec{\beta}^{(0)}$. Suurusele λ antakse samuti mingi algväärtus, järgnevalt toodud programmis on võetud $\lambda = 0,01$. Suurendades λ väärtust, lähenetakse gradientmeetodi poolt soovitatud suunale. Alguses pole meil teada, kas me oleme otsitavale funktsiooni $Q(\lambda)$ miinimumile juba küllalt lähedal või ei, sellepärast on sobiv võtta λ algväärtus küllalt väike, et juhul, kui oleme miinimumile lähedal, ei eemalduks sealt enam.

2. s -ndal iteratsioonisammul leitakse parandusvektor $\vec{\sigma}_m^{(s)}$ võrrandist:

$$(A + \lambda_s \cdot a_{jj}) \cdot \vec{\sigma}_m^{(s)} = \vec{g}$$

s.t.

$$\vec{\sigma}_m^{(s)} = (A + \lambda_s \cdot a_{jj})^{-1} \cdot \vec{g}.$$

3. Saadud parandusvektori abil leitakse uus parameetrite vektori lähend:

$$\vec{\beta}^{(s+1)} = \vec{\beta}^{(s)} + \vec{\sigma}_m^{(s)}$$

4. $\vec{\beta}^{(s+1)}$ väärtust arvestades leitakse suurus Q_{s+1} .

5. Nüüd võrreldakse omavahel suurusi Q_s ja Q_{s+1} .

Kui $Q_{s+1} < Q_s$, siis see tähendab, et parameetrite ruumis punkti $\vec{\beta}^{(s+1)}$ liikudes jõuame otsitavale $Q(\vec{\beta})$ miinimumile lähemale. Sellisel juhul võetakse järgmisel sammul $\lambda_{s+1} = \lambda_s$ ja minnakse edasi punktist $\vec{\beta}^{(s+1)}$.

Kui aga $Q_{s+1} > Q$, siis see tähendab, et punkti $\vec{\beta}^{(s+1)}$ viiv suund pole sobiv (viib kaugemale otsitavast $Q(\vec{\beta})$ miinimumist) ja tuleb leida λ_{s+1} selliselt, et $Q_{s+1} < Q_s$.

Selleks, et oleks parem leida uut suurust λ_{s+1} , on otstarbekas võrrelda igal sammul mitut Q väärtust, leides suuruse $Q_1 = Q(\lambda_s)$ kõrval ka suuruse $Q(\lambda_s / 10)$.

6. Protsessi võime lõpetada siis, kui parandusvektor $\vec{\sigma}$ on selline, et $\max_{1 \leq i \leq m} |\sigma_i|$ ei ületa lubatud viga ε .

Suurust λ võib valida näiteks nii [2] :

Igal sammul võrreldakse omavahel kahte või isegi kolme Q väärtust:

$Q(\lambda_s)$, $Q(\lambda_s / 10)$ ja vajaduse korral veel ka $Q(\lambda_s \cdot 10^n)$.

a) Kui

$$Q(\lambda_{s-1} / 10) \leq Q(\lambda_s) ,$$

siis

$$\lambda_s = \lambda_{s-1} / 10 .$$

b) Kui

$$Q(\lambda_{s-1} / 10) > Q(\lambda_s)$$

ja

$$Q(\lambda_{s-1}) \leq Q(\lambda_s) ,$$

siis

$$\lambda_s = \lambda_{s-1} .$$

c) Kui

$$Q(\lambda_{s-1}/10) > Q(\lambda_s),$$

$$Q(\lambda_{s-1}) > Q(\lambda_s),$$

siis tuleb λ -t suurendada 10-ga korrutamisel kuni
mingi n korral

$$Q(10^n \cdot \lambda_{s-1}) \leq Q(\lambda_s)$$

ja

$$\lambda_s = 10^n \cdot \lambda_{s-1}.$$

III. MAKSIMAALSE ÜMBRUSE MEETODIT
REALISEERIV PROGRAMM

Maksimaalse ümbruse meetodi rakendamine on seotud suure arvutustööde mahuga, mistõttu on otstarbekas koostada selle meetodi kohta programm arvutusmasinale. Käesoleval juhul on kirjutatud programm arvutile "MINSK-32" algoritmilises keeles MALGOL.

§ 1. Probleemi seade.

Eeldame, et regressioonifunktsioon $\vec{f}(\vec{x}, \vec{\beta})$ omab kuju:

$$f(\vec{x}, \vec{\beta}) = \prod_{l=1}^k R_l(\vec{x}, \vec{\beta}_l)$$

kus $R_l(\vec{x}, \vec{\beta}_l)$ kujutab endast teatud summat:

$$R_l(\vec{x}, \vec{\beta}_l) = \beta_{l0} + \beta_{l1}x_1 + \dots + \beta_{lp}x_p.$$

Olgu meil antud väljavõtte sõltumatute argumentide väärtustest.

$$\left\| \begin{array}{cccc} x_{10} & x_{11} & \dots & x_{1p} \\ x_{20} & x_{21} & \dots & x_{2p} \\ \dots & \dots & \dots & \dots \\ x_{n0} & x_{n1} & \dots & x_{np} \end{array} \right\| = X$$

(siin $x_{i0} = 1$; $i = 1, 2, \dots, n$)

ja vastavatest sõltuva juhusliku suuruse väärtustest

$$\begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{pmatrix} = \vec{y}.$$

Tundmatud parameetrid moodustagu maatriksi:

$$\begin{pmatrix} \beta_{10} & \beta_{11} & \dots & \beta_{1\mu} \\ \beta_{20} & \beta_{21} & \dots & \beta_{2\mu} \\ \dots & \dots & \dots & \dots \\ \beta_{s0} & \beta_{s1} & \dots & \beta_{s\mu} \end{pmatrix} = B.$$

Praktikas on huvipakkuvaks juht, kus osa parameet-
reid võrduvad nulliga (olgu ette teada, millised nimelt).
Edaspidi opereerime vaid nullist erinevate parameetri-
tega, arvestades nende asukohta maatriksis B . Olgu
nullist erinevate parameetrite arv maatriksi B esime-
ses reas k_1 , teises reas k_2 jne. kuni s -ndas reas
 k_s . Olgu $k_1 + k_2 + \dots + k_s = k$, kusjuures $k < n$.
Tähistame nullist erinevad parameetrid edaspidi nii:

$$(\beta_1, \beta_2, \dots, \beta_k) = \vec{\beta}.$$

Lähtudes väljavõtetest X ja \vec{y} ning avaldisest

$$E(y_i) = f_i(X, B) = \prod_{l=1}^s \sum_{j=0}^{\mu} \beta_{lj} x_{lj},$$

kus $x_{i0} = 1$, tuleb leida tundmatute parameetrite β_j
($j = 1, 2, \dots, k$) hinnangud, nii et suurus $E(y_i)$ oleks
küllalt lähedane suurusele y_i .

§ 2. Lahendusalgoritm.

1. Olgu mingitel kaalutlustel valitud parameetrite vektori algühend

$$\vec{\beta} = (\beta_1, \dots, \beta_{k_1}, \beta_{k_1+1}, \dots, \beta_{k_1+k_2}, \dots, \beta_{k_1+k_2+\dots+k_{s-1}+1}, \dots, \beta_{k_1+k_2+\dots+k_s}),$$

kus

$$\beta_{k_1+k_2+\dots+k_s} = \beta_k.$$

Vastavalt nendele nullist erinevatele parameetritele olgu antud parameetrite rea- ja veeruindeksite vektorid

$$\vec{R} = (\underbrace{1, \dots, 1}_{k_1}, \underbrace{2, \dots, 2}_{k_2}, \dots, \underbrace{\Delta, \dots, \Delta}_{k_s})$$

ja

$$\vec{V} = (j_{11}, \dots, j_{1k_1}, j_{21}, \dots, j_{2k_2}, \dots, j_{s1}, \dots, j_{sk_s})$$

selliselt, et β_1 -le vastab element¹ $\beta_{1j_{11}}$, β_{k_1} -le $\beta_{1j_{1k_1}}$ jne. kuni β_k -le element $\beta_{sj_{sk_s}}$ matriksist B .

Olgu antud ka suuruse λ algväärtus (antud juhul $\lambda = 0, 01$).

2. Leiame funktsiooni f_i ($i = 1, 2, \dots, n$) väärtused valemist

$$f_i(x, \vec{\beta}) = \prod_{l=1}^s \sum_{m=1}^{k_s} \beta_{l, (j_{lm})} \cdot x_{i, (j_{lm})}$$

¹ Siin ja järgmistes valemities on mitmekordsed veeruindeksid asetatud sulgudesse.

3. Leiame hälvete ruutude summa Q väärtuse valemist

$$Q = \sum_{i=1}^n (f_i - y_i)^2$$

ning trükime välja alglähendi $\vec{\beta}$ elementide ning suuruse Q väärtused.

4. Omistame suurusele λ väärtuse $\lambda/10$.

5. Funktsiooni f_i ($i = 1, 2, \dots, n$) tuletised $\beta_{\ell j}$ ($\ell = 1, 2, \dots, s$; $j = 0, 1, \dots, p$) järgi avalduvad valemiga

$$\frac{\partial f_i}{\partial \beta_{\ell j}} = x_{ij} \prod_{\substack{h=1 \\ h \neq j}}^s \sum_{m=0}^p \beta_{hm} x_{im}$$

Arvestades ainult nullist erinevaid parameetreid, leiame tuletised valemist

$$\frac{\partial f_i}{\partial \beta_{\ell, (j\ell p)}} = x_{i, (j\ell p)} \cdot \prod_{\substack{h=1 \\ h \neq \ell}}^s \sum_{m=0}^k \beta_{h, (j\ell m)} \cdot x_{i, (j\ell m)}$$

6. Leiame vektori \vec{g} ning maatriksi A elementide väärtused vastavalt valemitest:

$$g_j = 2 \cdot \sum_{i=1}^n (y_i - f_i) \frac{\partial f_i}{\partial \beta_j},$$

$$a_{j_1, j_2} = \sum_{i=1}^n \frac{\partial f_i}{\partial \beta_{j_1}} \cdot \frac{\partial f_i}{\partial \beta_{j_2}},$$

kus $j, j_1, j_2 = 1, 2, \dots, k$.

Liites nüüd maatriksi A diagonaalelementidele vastavalt suurused $\lambda \cdot a_{jj}$ ja $\lambda^1 \cdot a_{jj}$, kus a_{jj} on maatriksi A diagonaalelement, saame maatriksid AP ja AP^1 .

Parandusvektorid $\vec{\sigma}$ ja $\vec{\sigma}^1$ leiame järgmiselt:

$$\vec{\sigma} = (AP)^{-1} \vec{g},$$

$$\vec{\sigma}^1 = (AP^1)^{-1} \vec{g}.$$

7. Liites parandusvektorid lähendvektorile $\vec{\beta}$, saame uued lähendid $\vec{\beta}^0$ ja $\vec{\beta}^1$, millest lähtudes leiame suuruse Q uued väärtused T ja T^1 .

8. Võrdleme Q esialgset väärtust uute väärtustega T ja T^1 . Kui

$$1) Q < T \text{ ja } Q < T^1,$$

siis suurendame λ -t, korrutades seda 10^r -ga, kuni mingi $r = 1, 2, \dots$ korral uue λ abil leitud suuruse Q väärtus TT saab väiksemaks Q esialgsest väärtusest.

Kui $Q \leq TT$, siis võrdleme viimase λ abil leitud lähendvektorit $\vec{\beta}^i$ eelmise lähendiga $\vec{\beta}$. Kui $i = 1, 2, \dots, k$ korral kehtib võrratus

$$\left| \frac{\beta_i}{(\beta\beta)_i} - 1 \right| \leq \varepsilon, \quad (1)$$

kus ε on lubatud viga, siis trükime välja lahendi $\vec{\beta}^i$ ja talle vastava hälvete ruutude summa TT väärtuse ning lõpetame protsessi.

Kui võrratus (1) ei kehti, siis võtame uueks lähendvektoriks $\vec{\beta}$ vektori $\vec{\beta}^i$ ning alustame uuesti punktist 4.

2) $Q \geq T$ või $Q \geq T_1$ ning $T < T_1$, siis, kui $i = 1, 2, \dots, k$ korral kehtib võrratus

$$\left| \frac{\beta_i}{(\beta_0)_i} - 1 \right| \leq \varepsilon, \quad (2)$$

trükime välja lahendi $\vec{\beta}_0$ ja talle vastava hälvete ruutude summa T väärtuse ning lõpetame protsessi.

Kui võrratus (2) ei kehti, siis võtame uueks lähendvektoriks $\vec{\beta}$ vektori $\vec{\beta}_0$ ning alustame uuesti punktist 4.

3) $Q \geq T$ või $Q \geq T_1$ ning $T_1 \leq T$, siis, kui $i = 1, 2, \dots, k$ korral kehtib võrratus

$$\left| \frac{\beta_i}{(\beta_1)_i} - 1 \right| \leq \varepsilon, \quad (3)$$

siis trükime välja lahendi $\vec{\beta}_1$ ning talle vastava hälvete ruutude summa väärtuse T_1 ning lõpetame protsessi.

Kui võrratus (3) ei kehti, siis võtame λ uueks väärtuseks λ_1 endise väärtuse, uueks lähendvektoriks $\vec{\beta}$ võtame vektori $\vec{\beta}_1$ ning alustame uuesti punktist 4.

§ 3. Programmi kasutamise juhend.

Algandmed tuleb perforeerida 6 massiivina. Nendest esimese moodustavad lihtmuutujad n, p, s, k, ε ; kus n on väljavõtete arv, p on matriksi B veergude ja s matriksi B ridade arv, k on nullist erinevate parameetrite arv ning ε on lubatud viga.

Teiseks massiiviks perforeeritakse vektori \vec{y} elemendid, kolmandaks maatriks X ridade kaupa, neljandaks parameetrite vektori alglähend $\vec{\beta}^{(0)}$, viiendaks reaindeksite vektor \vec{R} ja kuundaks veeruindeksite vektor \vec{V} . Programm trükib välja alglähendi $\vec{\beta}^{(0)}$ elemendid ja hälvete ruutude summa alglähendi korral Q_0 ning programmi töö tulemusena leitud parameetrite vektori $\vec{\beta}$ elemendid ja neile vastava hälvete ruutude summa Q .

Kui funktsiooni $f(x, \vec{\beta})$ kuju erineb § 1-s kirjeldatust, siis tuleb asendada protseduurid FUNKTS ja TULETIS uuega, arvestades $f(x, \vec{\beta})$ kuju.

KIRJANDUS.

1. Рао С.Р., Линейные статистические методы и их применения. Москва, 1968.
2. Демиденко Е.З., Оценка параметров в нелинейной регрессии. Математические методы в экономике и международных отношениях. Москва, 1972, 75 - 98.
3. Tallas, U., Lisatingimusega regressioonanalüüsi ülesande lahendamise. Kursusetöö. Tartu, 1972.
4. Демидович Б.П., Марон И. А., Основы вычислительной математики. Москва, 1966.

Некоторые вопросы о регрессии.

Теллас У.

Резюме.

Целью данной дипломной работы является нахождение подходящего метода для оценки параметров в нелинейной регрессии и составление программы, реализующей этот метод.

В первой главе решена линейная задача регрессии по методу наименьших квадратов.

Во второй главе рассматривается нелинейная задача регрессии. Даны три метода решения этой задачи: градиентный метод; разложение функции в ряд Тейлора и метод максимальной окрестности.

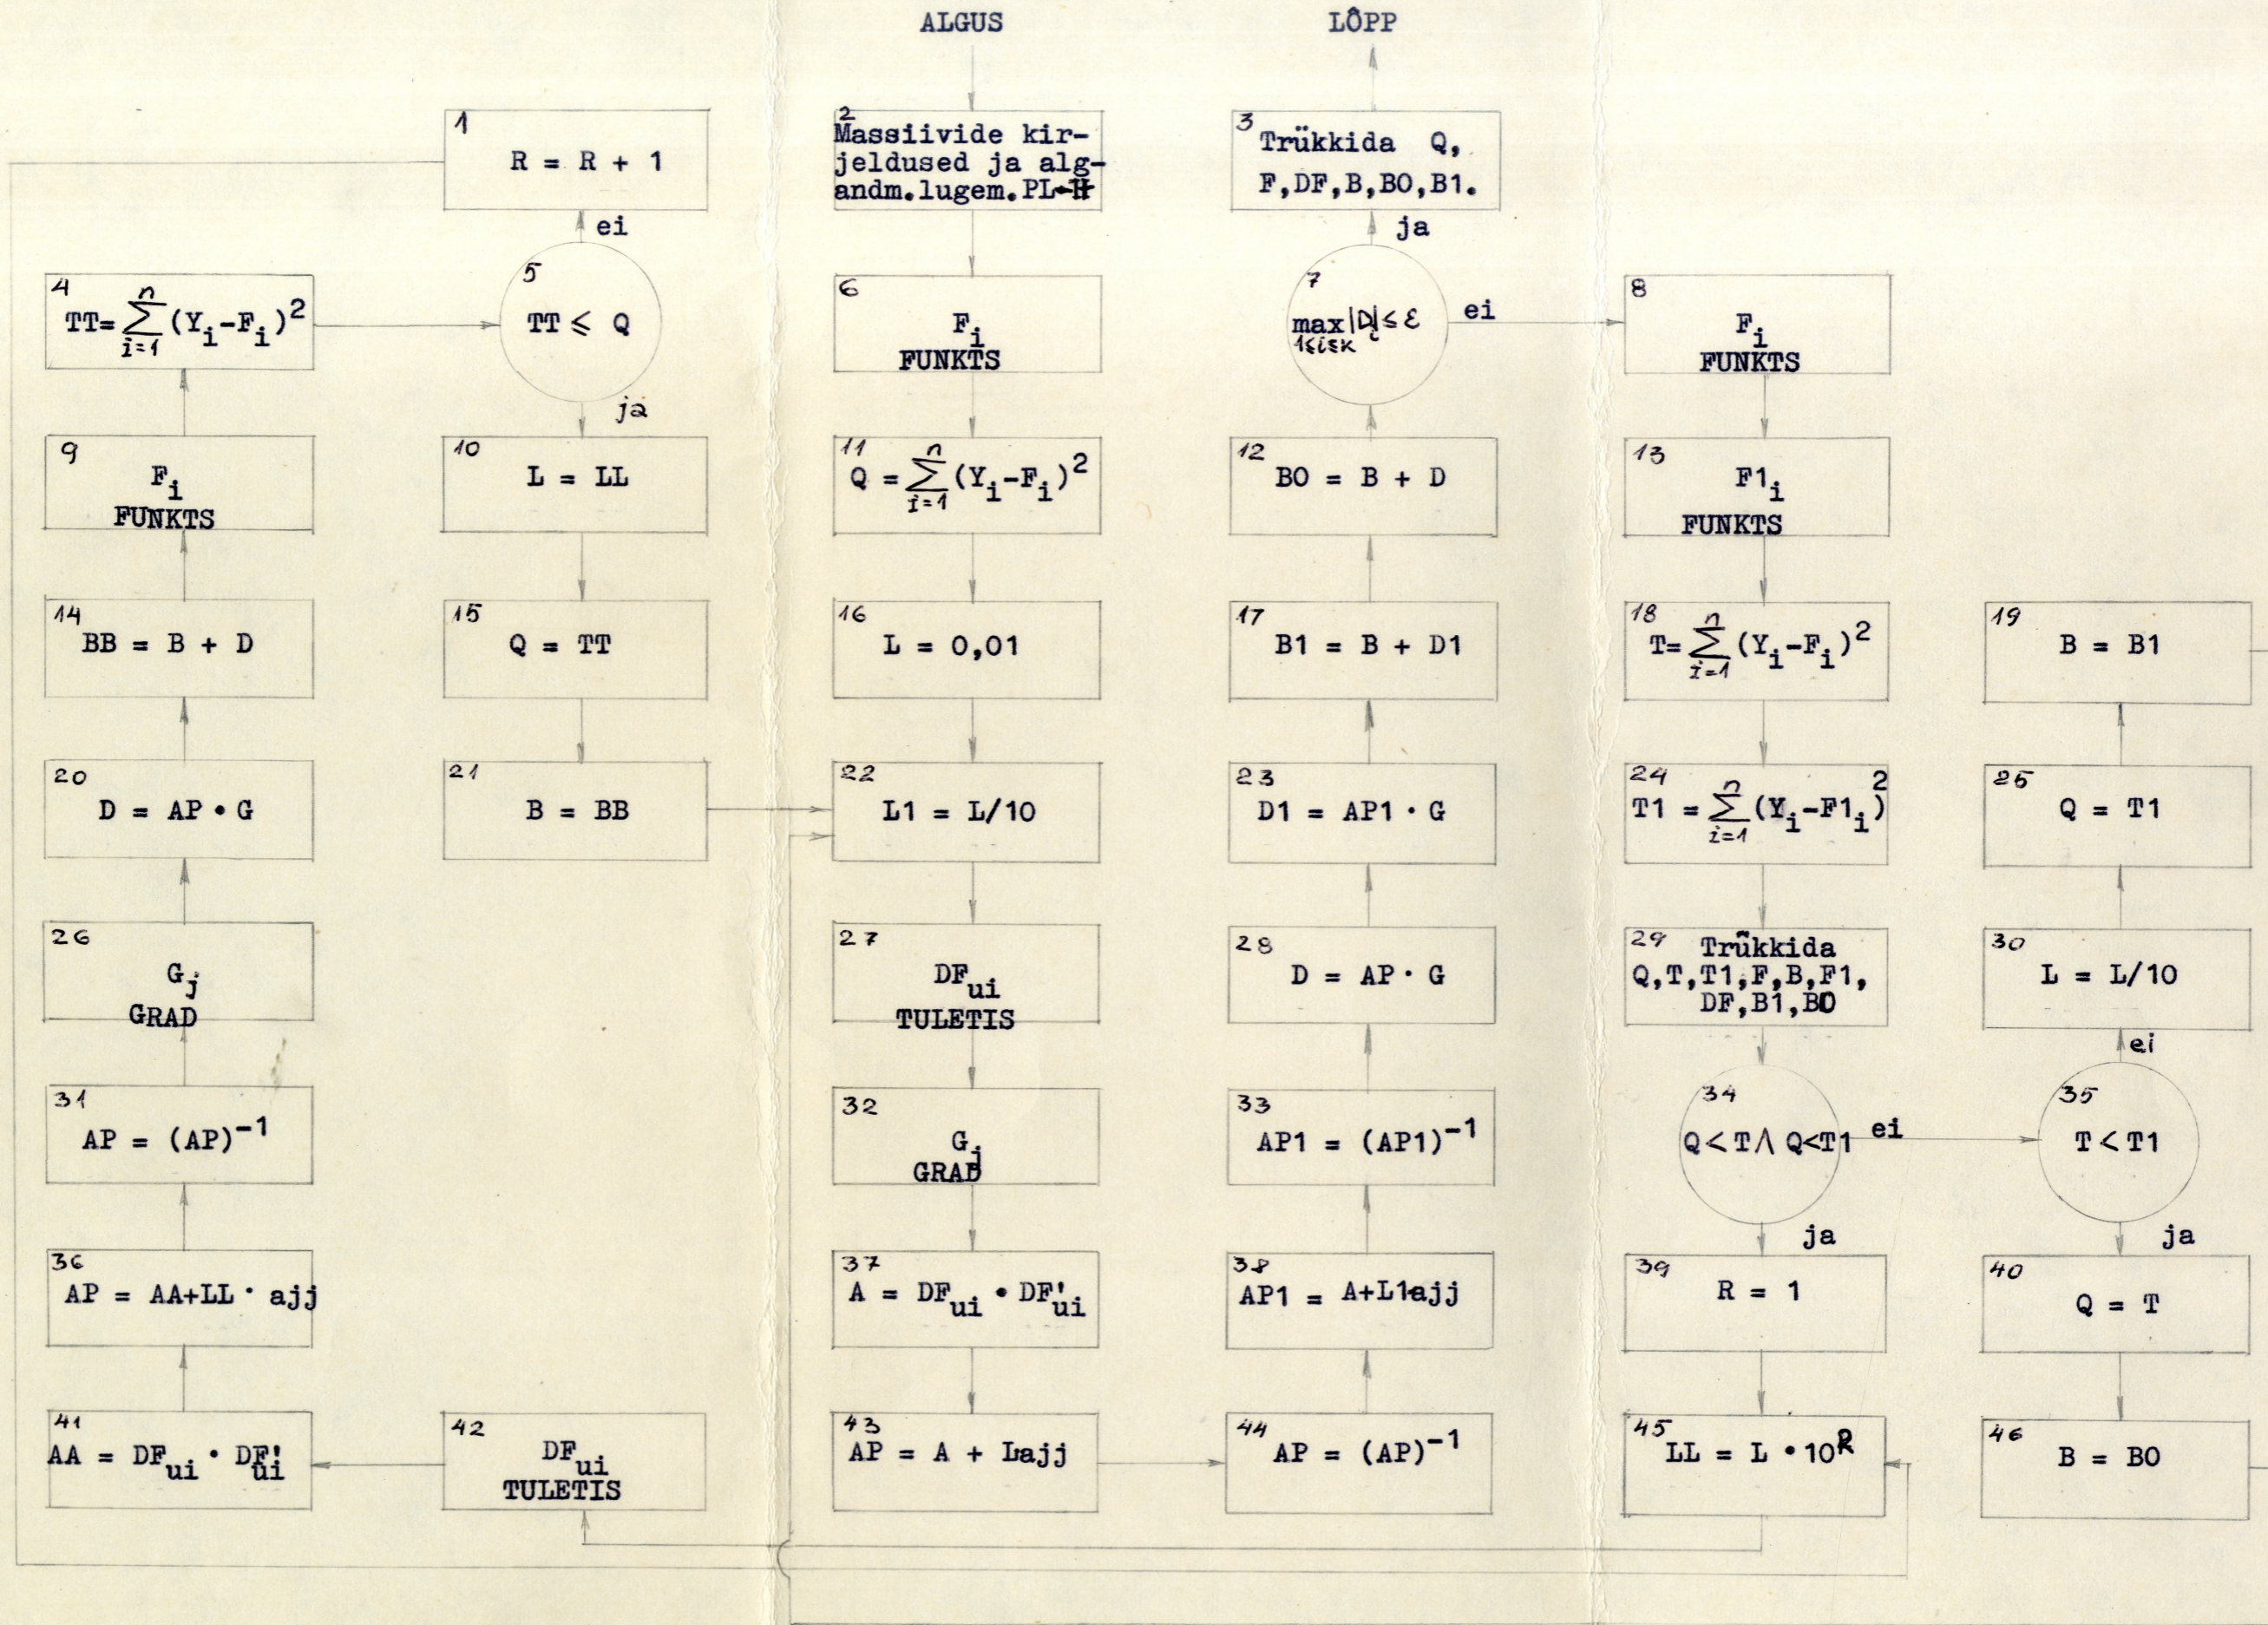
В третьей главе описана на языке `MALGOL` написанная программа, реализующая метод максимальной окрестности.

В приложении даны программа и блок-схемы программы.

SISUKORD

	lk.
Sissejuhatus.....	2
I. Lineaarse regressioonanalüüsi ülesande lahendamise	
§ 1. Regressiooni üldistatud mudel.....	3
§ 2. Vähimruutude meetod.....	4
II. Mittelineaarse regressioonanalüüsi ülesande lahendamise	
§ 1. Gradientmeetod.....	8
§ 2. Funktsiooni Tayloriga ritta arendamise meetod.....	11
§ 3. Maksimaalse ümbruse meetod.....	13
III. Maksimaalse ümbruse meetodit realiseeriv programm	
§ 1. Probleemi seade.....	24
§ 2. Lahendusalgoritm.....	26
§ 3. Programmi kasutamise juhend.....	29
Kirjandus.....	31
Resümees.....	32

L I S A D



Märkused üldise blokskeemi
kohta.

Programmi silumise käigus osutus otstarbekaks
teha järgmised parandused.

1. Ara jätta 29. blokk ning asendada 3. blokk
blokiga: "trükkida Q, B ". Lisada pärast
11. blokki blokk "trükkida Q, B ".
2. Ara jätta blokk 7 , sest selline lõpukri-
teerium ei õigusta end.

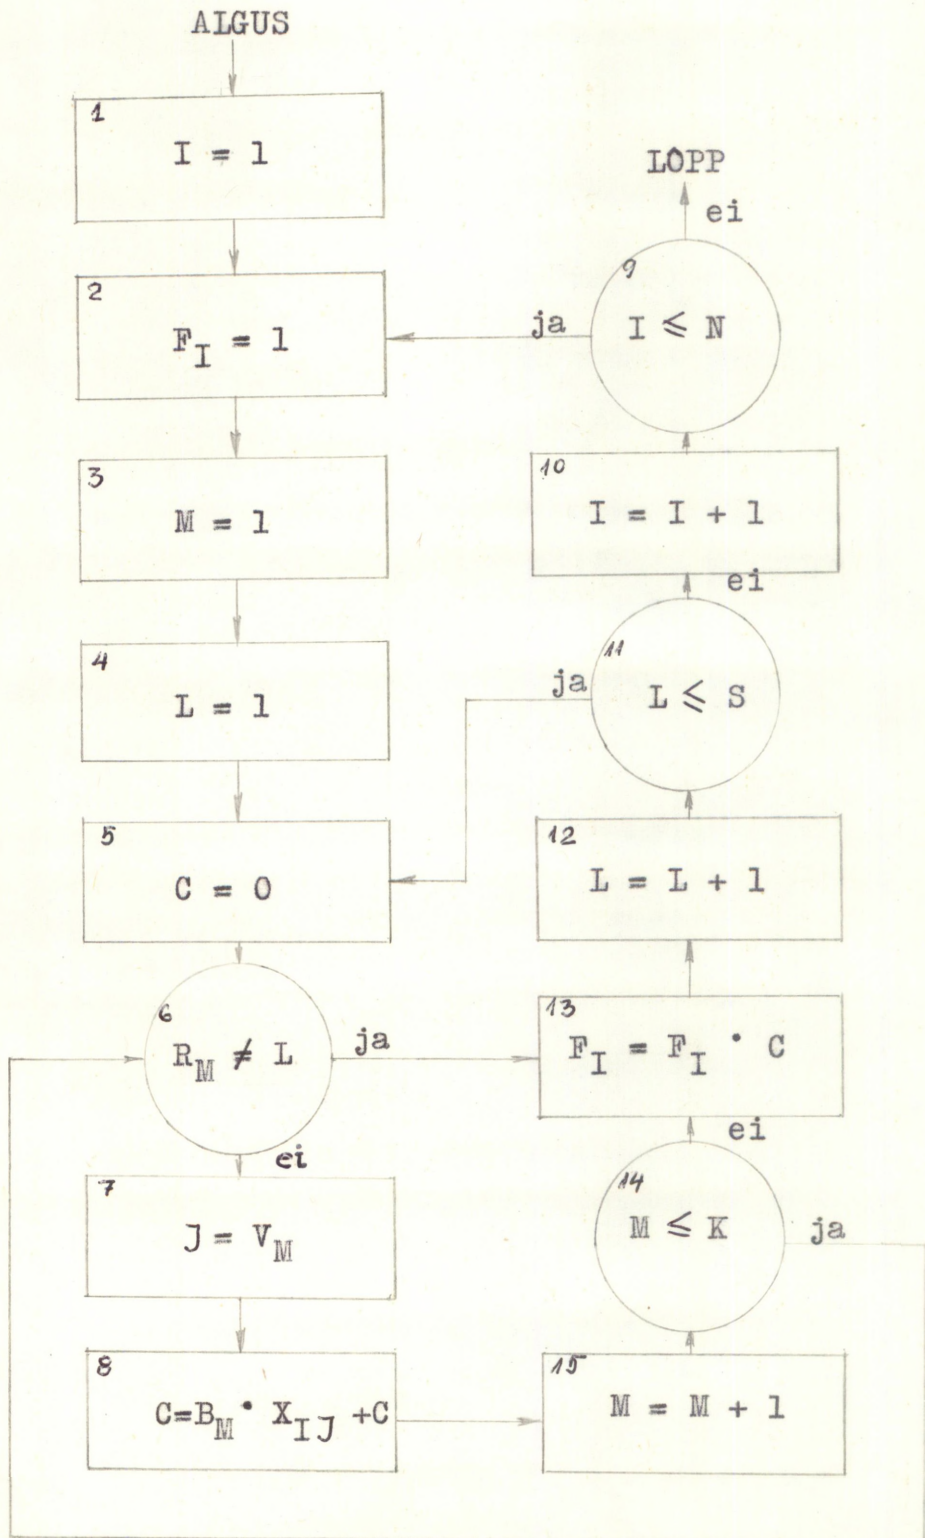
Lõpukriteerium

$$\left| \frac{\beta_i}{\beta(k)_i} - 1 \right| \leq \varepsilon$$

panna pärast 15-ndat, 25-ndat ning 40-ndat
blokki, kusjuures antud võrratuses tuleb
vektoriks $\vec{\beta}(k)$ võtta vastavalt vektor
 $\vec{\beta}_\beta$, $\vec{\beta}_1$ või $\vec{\beta}_0$.

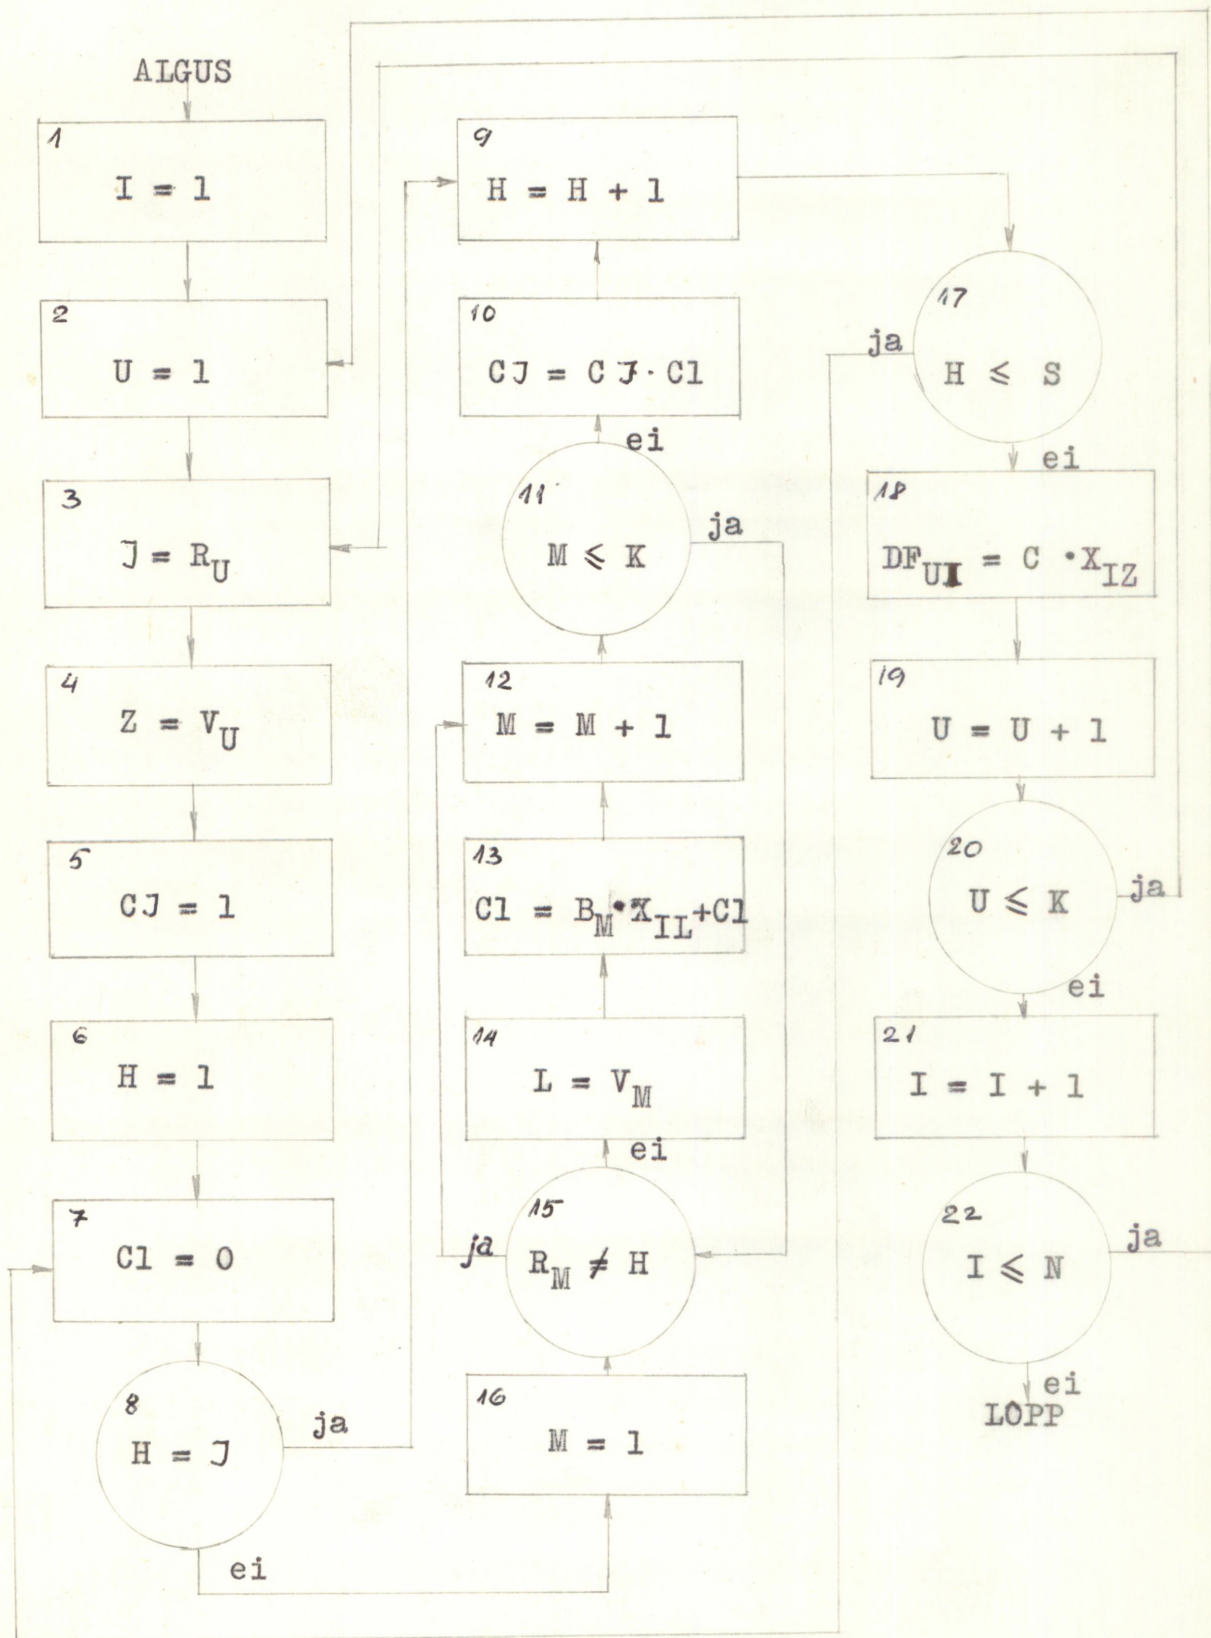
BLOKKSKEEM PROTSEDUURILE

FUNKTS




BLOKKSKEEM PROTSEDUURILE

TULETIS



BLOKKSKEEM PROTSEDUURILE

GRAD



```

R001 COMMENT'PARAMEETRID;
R002 A1:READ1'(N,P,S,K,EPS);
R003 ARRAY'Y.(1:N),X.(1:N,0:P),
R004 B.(1:K),R.(1:K),V.(1:K);
R005 READAR'(Y,X,B,R,V);
R006 ARRAY'F.(1:N),F1.(1:N),DF.(1:K,1:N),
R007 G.(1:K),A.(1:K,1:K),AP.(1:K,1:K),
R010 H.(1:K*(K+1)/2),
R011 AP1.(1:K,1:K),AA.(1:K,1:K),D.(1:K),
R012 D1.(1:K),B0.(1:K),B1.(1:K),BB.(1:K);
R013 FUNKTS(F,N,S,R,V,B,X,K);
R014 Q:=0;
R015 FOR'I:=1 STEP'1 UNT'L'N DO'

R016 BEGIN'Q:=Q+(V.(I).-F.(I.))*2 END';
R017 PRINT1'(Q);
R020 PRINTARRAY'(B.);
R021 L:=0.01;
R022 A2:L1:=L/10;
R023 TULETIS(DF,N,K,S,R,V,B,X);
R024 GRAD(G,Y,F,DF,K,N);
R025 MULTR3'(DF,H.);
R026 ARR3Q'(H,A.);
R027 TRANS'(A,AP);
R030 FOR'I:=1 STEP'1 UNTIL'K DO'
R031 BEGIN'AP.(I,I).:=A.(I,I).*L+A.(I,I). END';
R032 INVERS'(AP.);
R033 TRANS'(A,AP1.);
R034 FOR'I:=1 STEP'1 UNTIL'K DO'
R035 BEGIN'AP1.(I,I).:=A.(I,I).*L1+A.(I,I). END';
R036 INVERS'(AP1.);
R037 FOR'U:=1 STEP'1 UNTIL'K DO'
R040 BEGIN'D.(U).:=0;
R041 D1.(U).:=0;
R042 FOR'I:=1 STEP'1 UNTIL'K DO'
R043 BEGIN'D.(U).:=D.(U).+AP.(U,I).*G.(I.);
R044 D1.(U).:=D1.(U).+AP1.(U,I).*G.(I). END';
R045 END';
R046 ADD'(B.,D1.,B1.);
R047 ADD'(B.,D.,B0.);
R050 FUNKTS(F,N,S,R,V,B0,X,K);
R051 FUNKTS(F1,N,S,R,V,B1,X,K);
R052 T:=0;
R053 T1:=0;
R054 FOR'I:=1 STEP'1 UNTIL'N DO'
R055 BEGIN'T:=T+(V.(I).-F.(I.))*2;
R056 T1:=T1+(V.(I).-F1.(I.))*2 END';
R057 IF'Q(:T+.Q(:T1 THEN'GOTO'A4;
R060 IF'T(:T1 THEN'GOTO'A3;
R061 L:=L/10;
R062 Q:=T1;
R063 MAX:=ABS'(B.(1)/B1.(1).-1);

R064 FOR'I:=2 STEP'1 UNTIL'K DO'
R065 BEGIN'IF'ABS'(B.(I)/B1.(I).-1)>MAX
R066 THEN'MAX:=ABS'(B.(I)/B1.(I).-1) END';
R067 FOR'I:=1 STEP'1 UNTIL'K DO'
R070 BEGIN'B.(I).:=B1.(I). END';
R071 IF'MAX(<=EPS THEN'GOTO'A7;
R072 GOTO'A2;
R073 A3:Q:=T;
R074 MAX:=ABS'(B.(1)/B0.(1).-1);
R075 FOR'I:=2 STEP'1 UNTIL'K DO'

```

```

R076 BEGIN'IF'ABS'(B.(I)/BO.(I).-1);)MAX
R077 THEN'MAX:=ABS'(B.(I)/BO.(I).+1) END';
R100 FOR'I:=1 STEP'1 UNTIL'K DO'
R101 BEGIN'B.(I).:=BO.(I). END';
R102 IF'MAX(=EPS THEN'GOTO'A7;
R103 GOTO'A2;
R104 A4:R:=1;
R105 A5:LL:=L*10**R;
R106 TULETIS(DF.,N,K,S,R.,V.,B.,X.);
R107 MULTR3'(DF.,H.);
R110 ARR3Q'(H.,AA.);
R111 TRANS'(AA.,AP.);
R112     FOR'I:=1 STEP'1 UNTIL'K DO'
R113 BEGIN'AP.(I,I).:=AA.(I,I).*LL+AA.(I,I). END';
R114 INVERS'(AP.);
R115 GRAD(G.,V.,F.,DF.,K,N);
R116 FOR'U:=1 STEP'1 UNTIL'K DO'
R117 BEGIN'D.(U).:=0;
R120 FOR'I:=1 STEP'1 UNTIL'K DO'
R121 BEGIN'D.(U).:=D.(U).+AP.(U,I).*G.(I). END';
R122 END';
R123 ADD'(B.,D.,BB.);
R124 FUNKTS(F.,N,S,R.,V.,BB.,X.,K);
R125 TT:=0;
R126 FOR'I:=1 STEP'1 UNTIL'N DO'
R127 BEGIN'TT:=TT+(V.(I).-F.(I).)**2 END';
R130 IF'TT(=Q THEN'GOTO'A6;
R131 R:=R+1;
R132 GOTO'A5;
R133 A6:L:=LL;
R134 Q:=TT;
R135 MAX:=ABS'(B.(1)/BB.(1).-1);
R136 FOR'I:=2 STEP'1 UNTIL'K DO'
R137 BEGIN'IF'ABS'(B.(I)/BB.(I).-1);)MAX
R140 THEN'MAX:=ABS'(B.(I)/BB.(I).-1) END';
R141 FOR'I:=1 STEP'1 UNTIL'K DO'
R142 BEGIN'B.(I).:=BB.(I). END';
R143 IF'MAX(=EPS THEN'GOTO'A7;
R144 GOTO'A2;
R145 A7:PRINT1'(Q);
R146 PRINTARRAY'(B.);
R147 STOP';
R150 START'A1;
R151 PROCEDURE'FUNKTS(Q1.,Q2.,Q3.,Q4.,Q5.,Q6.,Q7.,Q8.);
R152 BEGIN'FOR'I:=1 STEP'1 UNTIL'Q2 DO'
R153 BEGIN'Q1.(I).:=1;
R154 M:=1;
R155 FOR'L:=1 STEP'1 UNTIL'Q3 DO'
R156 BEGIN'C:=0;
R157 A1:IF'Q4.(M).=/L THEN'GOTO'A2;
R160 J:=Q5.(M).;
R161 C:=Q6.(M).*Q7.(I,J).+C;
R162 M:=M+1;
R163 IF'M(=Q8 THEN'GOTO'A1;
R164 A2:Q1.(I).:=Q1.(I).*C END';
R165 END';
R166 END';
R167 PROCEDURE'TULETIS(Q1.,Q2.,Q3.,Q4.,Q5.,Q6.,Q7.,Q8.);
R170 BEGIN'FOR'I:=1 STEP'1 UNTIL'Q2 DO'
R171 BEGIN'FOR'U:=1 STEP'1 UNTIL'Q3 DO'
R172 BEGIN'J:=Q5.(U).;
R173 Z:=Q6.(U).;
R174 CJ:=1;

```

```

R175 H:=1;
R176 A1:C1:=0;
R177 IF'H=J THEN'GOTO'A4;
R200 M:=1;
R201 A2:IF'Q5.(M).=/H THEN'GOTO'A3;
R202 L:=Q6.(M).;
R203 C1:=Q7.(M).×Q8.(I,L).+C1;
R204 A3:M:=M+1;
R205 IF'M(=Q3 THEN'GOTO'A2;
R206 CJ:=CJ×C1;
R207 A4:H:=H+1;
R210 IF'H(=Q4 THEN'GOTO'A1;
R211 Q1.(U,I).:=CJ×Q8.(I,Z).
R212 END';
R213 END';
R214 END';
R215 PROCEDURE'GRAD(Q1.,Q2.,Q3.,Q4.,Q5,Q6);
R216 BEGIN'FOR'J:=1 STEP'1 UNTIL'Q5 DO'
R217 BEGIN'C:=0;
R220 FOR'I:=1 STEP'1 UNTIL'Q6 DO'
R221 BEGIN'C:=(Q2.(I).-Q3.(I).)×Q4.(J,I).+C END';
R222 Q1.(J).:=C END';
R223 END';
R224 FINISH';
R225

```

COMMENT'PARAMETRID;
MEMORY PLAN

VARIABLES		TABLE OF ARRAYS		LABELS		PROCEDURES		FUNCTIONS		OPERATING VARIABLES		CONSTANTS		PROGRAM	
2236	N	2273	M	2752	3037	4107	A1	1061	-	1207	xx	2300	-	2304	
2237	P	2274	L	2774	3036	4117	A2	2305	-	2313		2305	-	2313	
2240	S	2275	J	3106	3136	4145	A3	2362	-	4260		2362	-	4260	
2241	K	2276	C	3203	3234	4156	A4								
2242	EPS	2277	I	3247	3257										
2244	Q	2314	V	3314	3345										
2245	I	2315	X	3360	3370										
2246	L	2316	B	3441	3461										
2247	L1	2317	R	3505	3545										
2250	U	2320	V	3523	3544										
2251	T	2321	F	3576	3612										
2252	T1	2322	F1	3651	3702										
2253	MAX	2323	DF	3715	3725										
2254	R	2323	DF	3755	4045										
2255	LL	2324	G	3775	4044										
2256	TT	2325	A	4062	4201										
2257	I	2326	AP	4075	4200										
2260	M	2327	H	4075	4200										
2261	L	2327	H	4216	4256										
2262	C	2330	AP1	4232	4251										
2263	J	2331	AA												
2264	I	2331	AA												
2265	U	2332	D												
2266	J	2333	D1												
2267	Z	2334	B0												
2270	CJ	2335	B1												
2271	H	2336	BB												
2272	C1	2336	BB												
			SUBROUTINES												
		2566	2602	3623	A6										
		2655	2675	3735	A7										
		2715	2735	3776	A1										
				4034	A2										

NÄIDE

Näiteülesanne on koostatud selliselt: on vabalt valitud x_{ij} ($i = 1, 2, \dots, n$; $j = 0, 1, \dots, p$) ning β_m ($m = 1, 2, \dots, k$) väärtused ja nende põhjal leitud y_i väärtused valemist

$$y_i = f_i(x_{i0}, x_{i1}, \dots, x_{ip}; \beta_1, \beta_2, \dots, \beta_k) + \mu_i,$$

kus μ_i on normaaljaotusega juhuslik suurus, $N(0; 0, 001)$.

Funktsioon f_i on järgmine:

$$f_i = (\beta_{10} x_{i0} + \beta_{11} x_{i1}) \cdot \beta_{21} \cdot x_{i1} \cdot \beta_{32} \cdot x_{i2}.$$

Algandmeteks on väärtused x_{ij} , y_i ja $\beta_m^{(0)}$, kusjuures

$\beta_m^{(0)} \neq \beta_m$ ($m = 1, 2, \dots, k$) on parameetrite vektori alg- lähend.

Algandmed: $n = 20$; $p = 2$; $s = 3$; $k = 4$; $\mathcal{E} = 0, 001$,

$$\vec{y} = \begin{pmatrix} 0,209518 \\ 0,326678 \\ 1,319943 \\ 0,268771 \\ 0,539514 \\ 0,070856 \\ 0,649509 \\ 0,658017 \\ 0,135004 \\ 0,406119 \\ 0,449287 \\ 0,899459 \\ 1,349470 \\ 1,798401 \\ 2,248398 \\ 1,625412 \\ 1,298550 \\ 0,975140 \\ 0,441004 \\ 0,220199 \end{pmatrix}, \quad X = \begin{pmatrix} 1 & 0,2 & 0,3 \\ 1 & 0,5 & 0,1 \\ 1 & 0,4 & 0,6 \\ 1 & 0,3 & 0,2 \\ 1 & 0,3 & 0,4 \\ 1 & 0,2 & 0,1 \\ 1 & 0,5 & 0,2 \\ 1 & 0,4 & 0,3 \\ 1 & 0,3 & 0,1 \\ 1 & 0,3 & 0,3 \\ 1 & 0,6 & 0,1 \\ 1 & 0,6 & 0,2 \\ 1 & 0,6 & 0,3 \\ 1 & 0,6 & 0,4 \\ 1 & 0,6 & 0,5 \\ 1 & 0,5 & 0,5 \\ 1 & 0,5 & 0,4 \\ 1 & 0,5 & 0,3 \\ 1 & 0,4 & 0,2 \\ 1 & 0,4 & 0,1 \end{pmatrix}.$$

$$\vec{\beta}^{(0)} = (0,35 ; 2,5 ; 5,5 ; 1,5) ,$$

$$\vec{R} = (1 \quad ; 1 \quad ; 2 \quad ; 3 \quad) ,$$

$$\vec{V} = (0 \quad ; 1 \quad ; 1 \quad ; 2 \quad) .$$

Vektor $\vec{\beta}$, mida on kasutatud \vec{y} elementide leidmisel,
on järgmine:

$$\vec{\beta} = (0,3 ; 2 ; 5 ; 1) .$$

Tulemuseks saadakse

$$\vec{\beta} = (0,273 ; 1,820 ; 4,488 ; 1,224) .$$

БПМ	+7777777777777	+0000000000003	
БПМ	+7777777777777	+2126013+02	+1489842-06
БПМ			
БПМ	+0000000000000		
БПМ	+0000000000003		
БПМ	+0000000000000		
БПМ	+0000000000003	+3500000+00	+2731285+00
БПМ	+0000000000000	+2500000+01	+1820270+01
БПМ	+0000000000003	+5500000+01	+4487628+01
БПМ	+0000000000000	+1500000+01	+1223992+01