

TARTU RIIKLIK ÜLIKOOL

Arvutusmatemaatika kateeder

R Ü H M I T A M I S M E E T O D I T E S T .

Diplomitöö.

Töö teostaja: V e s k i, Anu.

Matemaatikateaduskonna  
V kursuse üliõpilane.

Töö juhendaja: dots. L. V ö h a n d u.

Tartu 1969.

## I ÜLEVAADE RÜHMITAMISMEETODITEST.

Paljutunnuselise objektidesüsteemi rühmadeks jaotamist on aastaid uuritud. Kirjanduses on esitatud arvukalt rühmitamismeetodeid, kuid siiani esitatud meetodeist pole ükski täielikku tunnustust leidnud, vt./3/.

Rühmitamismeetodite sagedase kasutamise põhjuseks on suhteliselt lihtne matemaatiline aparatuur, mistõttu võivad neid edukalt kasutada ka need inimesed, kellel puuduvad erilised eelteadmised matemaatikast ja statistikast. Rühmitamine annab võimaluse ükskõik millises uurimisvaldkonnas uuritavate objektide kohta saadud andmeid viia edasise analüüsi jaoks ülevaatlikumale kujule. Selleks jaotatakse uuritav objektikogum rühmadeks nii, et iga rühma liikmed oleksid omavahel võimalikult sarnased, vt. /5/.

Et olemasolevaid meetodeid edukalt kasutada, on vajalik nende võrdlemine ja liigitamine. Kirjanduses leiduvaid rühmitamismeetodeid võib jagada kahte suurde rühma:

- 1) induktiivsed meetodid,
- 2) deduktiivsed e. hierarhilised meetodid.

Induktiivsete meetodite puhul algab analüüs üksikobjektide võrdlemisest ning rühmadeks ühendamisest. Deduktiivsete meetodite juures võetakse vaatluse alla terve objektikogum ja jaotatakse teda seni, kuni saadakse homogeensed osad, mis defineeritakse kui rühmad. Deduktiivsete meetodite tuletamisel on jõutud tunduvalt kõrgema viimistletuseni ja arvutuste keerukuseni, vt./1/. Puuduseks on aga neile küllalt suur arvutustööde maht, sest analüüs nõuab kõigi objektipaaride vaheliste seoste välja arvutamist. Teiselt poolt on hierarhilised meetodid sobivad rakendada vaid selgesti avalduva heterogeensuse korral. Kuna praktikas on hierarhilist rühmitamist võimalik suhteliselt vähem rakendada, on viimasel ajal pööratud suuremat tähelepanu induktiivsete meetodite arendamisele.

Täielikud induktiivsed rühmitamismeetodid võivad koosneda põhimõtteliselt neljast osast:

- 1) algrühmade määramine,
- 2) uute objektide lisamine olemasolevatele rühmadele või olemasolevate rühmade omavaheline liitmine,
- 3) rühmitamise lõpetamine (seejuures võib osa objekte jääda rühmitamata ja moodustada üheobjektilisi rühmi),
- 4) ümberrühmitamine pärast rühmade moodustamist ( võimalike valerühmituste kõrvaldamiseks).

Kõik induktiivsed rühmitamismeetodid sisaldavad esimest ja teist osa. Mõnede meetodite puhul puudub kas

kolmas või neljas osa või puuduvad mõlemad osad, vt. /2/.

Rühmitamisele asumisel on oluline sobiva sarnasuse määru valik (eriti hierarhiliste meetodite puhul).

Üheks sagedamini kasutatavaks määruks on eukleidiline kaugus:

$$d_{\alpha\beta} = \sum_i (x_{i\alpha} - x_{i\beta})^2$$

Kaalutatud Eukleidilist kaugust

$$d_{\alpha\beta} = \sum_i k_i (x_{i\alpha} - x_{i\beta})^2$$

/6/

on oma töödes kasutanud Bonner (1962), Sebestyen (1962) /10/, Ball ja Hall (1964) jt. Lisaks eukleidilisele kaugusele on kasutusel veel terve rida mitte- eukleidilisi kaugusi.

Teiseks kasutatavamaks sarnasuse määruks objektide võrdlemisel on korrelatsioonikoefitsient:

$$R_{ij} = \frac{E[(X_i - EX_i)(X_j - EX_j)]}{\sqrt{DX_i \cdot DX_j}}, \text{ vt. /4/}$$

Nii eukleidilist kaugust kui ka korrelatsioonikoefitsienti saab kasutada ka rühma raadiuse ligikaudse määruna.

Lisaks neile on kasutusel veel terve rida sarnasuse näitajaid, mis põhinevad informatsiooni mõistel, vt. /5/.

Olemasolevaid induktiivseid rühmitamismeetodeid võib jagada kolme suurede rühma:

- 1) meetodid, mis nõuavad kõigi objektipaaride vahelise korrelatsiooni või kauguse leidmist,
- 2) meetodid, mis võtavad üksikobjektid vaatluse alla järjekorras,

3) meetodid, mis opereerivad objektikogumitega.

Enamus kirjanduses esitatud meetodeist kuuluvad esimesse rühma. Vaatleme mõningaid meetodeid igast rühmast.

1962.aastal esitas Needham meetodi<sup>/M/</sup>, mis algab kõigi objektide-vahelise kauguste maatriksi leidmisega. Seejärel arvutatakse keskmine kaugus - nn. lävi. Kauguste maatriksi elemendid muudetakse nullideks või ühtedeks sõltuvalt sellest, kas lävi ületatakse või mitte. Selliselt teisendatud maatriksi i-s veerg annab i-ndale objektile lähedaste objektide loetelu. Kui võrreldakse i-ndat ja j-ndat veergu, siis uue rühma moodustavad i-ndale ja j-ndale objektile ühised lähedased objektid. Protseduuri korratakse seni, kuni leitakse kõik rühmad vastavalt ette antud arvule.

Sokal ja Michner ühendavad omavahel objektid, millel on suurim paariviisiline korrelatsioon. Järgmisena liidetakse objekt, millel on suurim keskmine korrelatsioon antud rühma liikmetega. Rühma lõpetamise kriteerium saadakse korrelatsiooni vähenemisest. "Oluline" langus määratakse empiirilisel, vt. /12/.

Induktiivsete rühmitamismeetodite üldiseks puuduseks ongi rühma lõpetamise kriteeriumite puudumine. Täpsed kriteeriumid on antavad vaid selgesti avalduva heterogeensuse korral.

Terve sarnasusmaatriksiga opereerivaid meetodeid on esitanud veel Bonner (1964), Goodall (1966), Sebestyen (1965) jt.

Tunduvalt väiksema töömahuga on meetodid, mis vaatlevad objekte järjekorras. Lihtsaima seda tüüpi meetodi

andis Bonner (1964) ning täiuslikuima Hyvarinen (1960), vt. /2/.

Bonner'i meetod. /2/.

Juhuslikult valitakse välja üks objekt. Edasi leitakse ülejäänud objektide kaugused valitud lähteobjektist. Küllalt lähedased objektid (mis on lähemal empiiriliselt ette antud lävest), liidetakse lähteobjektile ja moodustatakse uus rühm. Uus lähteobjekt järgmise sammu jaoks valitakse jällegi juhuslikult ülejäänud objektide seast. Küllalt lähedased objektid rühmitatakse analoogiliselt esimese sammuga. Rühmitamist teostatakse seni, kuni kogu objektimassiiv on ammendatud. Seejärel hinnatakse saadud rühmi. Rühmade sobivuse mööduks on nende eraldatus.

Hyvarinen'i meetod. /13/.

Esmakordselt toodi sisse "tüüpilisuse" mõõt. Lähteobjektiks valitakse "tüüpiline" objekt, mis annab suhteliselt vähe informatsiooni. Sellel eeldusel asub lähteobjekt suure tõenäosusega sellises piirkonnas, mis on tihedalt asustatud. Ülejäänud objektid, mis asuvad empiiriliselt ette antud lävest lähemal, liidetakse antud objektile ja moodustatakse rühm. Leitud rühma objektid kõrvaldatakse edasisest vaatlusest. Ülejäänud objektide seast valitakse jällegi uus "tüüpiline" lähteobjekt, moodustatakse uus rühm jne. Peale algset valikut rühma tsentreid (raskuskeskmeid) enam ümber ei muudeta. Suurte objektimassiivide korral on see meetod küllalt töömahukas. Saadud rühmade sobivus sõltub empiiriliselt ette antud sarnasuse piirist.

Seoses rühmitamismeetodite laialdase kasutamisega, on tekkinud vajadus suurte objektimassiivide rühmitamise järele. Suurt töömahtu on püütud vähendada sellega, et ei leita kõigi objektide vahelisi kaugusi. Paljude praktiliste ülesannete korral on leitud, et terve sarnasusmaatriksi defineerimine üle kogu objektimassiivi pole vajalik, vaid piisab kui defineerida sarnasusmaatiks teatud homogeensetele objektirühmadele, vt. /6/.

Selliseid meetodeid on esitatud terve rida ja nad moodustavad kolmanda suure rühma induktiivsetest rühmitamismeetoditest.

Nende meetodite puhul eeldatakse *á priori* ette antavat rühmade arvu. Rühmade arv võib rühmitamise käigus muutuda või mitte.

Meetodite kirjeldamisel kasutatakse ruumilisi mudeleid. Olgu antud  $n$  objekti, mida iseloomustavad  $m$  tunnust. Siis objektid kujutavad endast teatud punktikogumit  $m$ - dimensionaalses ruumis. Objektide omavaheliseks võrdlemiseks kasutatakse Eukleidilist kaugust, rühmi iseloomustatakse nende raskuskeskmega. Vanim selline töö on Forgy'lt (1965).

Objektikogum jaotatakse  $k$  rühmaks selliselt, et valitakse  $k$  objekti rühmade tsentreiks ja kõik objektid liidetakse rühmadele, milliste raskuskeskmeile on nad lähemal. Analoogilise meetodi kirjeldas ka Jancy (1966). Paindlikuma kuju andis meetodile MacQueen 1966.aastal. Esialgseiks rühma tsentreiks valitakse juhuslikult  $k$  objekti. Iga objekt liidetakse olemasolevaist rühmadest sellega, mille tsenter (raskuskese) on lähim. Objekte

vaadeldakse järjekorras. Pärast objekti rühmale liit-  
mist leitakse rühma uus raskuskese. Rühmade raskuskesk-  
med muudavad oma asukohti seni, kuni objektide rühmita-  
mine on lõppenud. Kui kahe rühma raskuskeskmed tulevad teine-  
teisele lähemale, kui antud ülesande puhul on ette lubatud, lii-  
detakse nad ning rühmade arvu k vähendatakse ühe võrra.  
Kui mõni objekt asub olemasolevaist rühmadest küllalt  
kaugel, moodustab ta uue, üheobjektilise rühma ja k suu-  
reneb ühe võrra.

MacQueen kasutas saadud tulemuste parandamiseks  
peale rühmitamise lõpetamist ka ümberrühmitamist. Selleks  
võrreldi kõiki objekte rühmitamise lõpus uuesti leitud  
rühmade raskuskeskmetega. Võrdlemise eesmärgiks oli rüh-  
mitamise käigus saadud väikeste rühmade ümberjaotamine.

## II. Vöhandu meetod.

Induktiivsete rühmitamismeetodite kasutamisega saab arvutustööde mahtu tunduvalt vähendada. Kuid vaatamata sellele on koostatud rühmitamisprogrammide töörohkearvuliste võrdluste tõttu küllalt aeglane. Praktikas esinevate suurte objektimassiivide rühmitamisel muutub olukord veelgi keerukamaks. Ülesannete lahendamist hakkab piirama masina mälu maht ning arvutusteks kuluv pikk aeg.

Nagu TPI Arvutuskeskuse praktika on näidanud, on suhteliselt väikese arvutustööde mahuga nn. puu-tüüpi rühmitamismeetodid. Selleks, et  $n$ -objektile joonistada minimaalsete ühendusteedega puud, on tarvis välja arvutada kõigi objektide vahelised kaugused. Neid kaugusi on  $\frac{n(n-1)}{2}$ . Minimaalsete ühendusteedega puu välja joonistamisel aga ei kasutata kaugeltki kõiki leitud kaugusi. See viib mõttele, et ilmselt on võimalik objektimassiivi struktuuri eelneva analüüsiga puu-tüüpi rühmitamiseks vajalike kauguste arvu tunduvalt vähendada.

Ühe võimaluse annab L.Vöhandu meetod. Siin kasutatakse ära asjaolu, et põhilise informatsiooni iga objekti kohta annab antud objekti lähim naaber, vt. /9/.

Järelikult võime iga objekti rühmitamisel piirduda tema paari lähima naaber-objekti vaatlemisega, kaugemad objektid võime vaatluse alt välja jätta. Et meie eesmärgiks on arvutuste mahu vähendamine, peaksid vaatluse alla tulevad objektid olema kogu objektimassiivi ulatuses

üksteisest küllaltki erinevad. Seega tuleks leida objekti-  
massiivist üles omavahel küllalt erinevad objektid - nime-  
tame neid koordinaatobjektideks ning seejärel leida igale  
objektile  $n$  lähimat koordinaatobjekti, mis määravad kind-  
laks objekti asukoha  $m$ -dimensionaalses tunnuste ruumis.

Iga  $n$  sellist koordinaatobjekti määrab selles  $m$ -  
dimensionaalses ruumis mingi hüperkolmnurga. Selliste hü-  
perkolmnurkade arv sõltub objektimassiivis leiduvate koor-  
dinaatobjektide arvust. Kui me igale objektile leiame  $n$   
lähimat koordinaatobjekti, määrame me sellega kindlaks  
antud objektile lähima hüperkolmnurga. Omavahel lähedased  
objektid koonduvad seejuures ilmselt ühise hüperkolmnurga  
sisse või vahetusse lähedusse.

Nüüd võime objektimassiivist üles otsida need objek-  
tid, millel on ühised lähimad koordinaatobjektid ja leida  
nende objektide omavahelised kaugused. Sellega oleme  $(n \times n)$   
kauguste maatriksist välja arvutanud vaid teatud "tüki"  
omavahel lähedaste objektide vaheliste kaugustega. Leitud  
kauguste abil saab täieliku minimaalsete ühendusteedega  
puu välja joonistada ning seejärel leida rühmad. Töömaht  
on tunduvalt vähenenud.

Käesolevas diplomitöös piirduakse kõigi kooordinaat-  
objektide ning igale objektile  $n$  lähima koordinaatobjekti  
leidmisega. Objektide edasine rühmitamine ühiste koordinaat-  
objektide järgi jäetakse vaatluse alt välja.

Koordinaatobjektide leidmisel kerkib üles kaks küsi-  
must. Milline on koordinaatobjektide arv konkreetse objek-  
timassiivi korral? Milline peab olema objektide vaheline

kaugus, et neid lugeda koordinaatobjektideks?

Koordinaatobjektide arvu  $h_{\max}$  ja koordinaatobjektide vahelise minimaalseima kauguse  $d_{\min}$  vahel on ilmselt seos olemas, sest mida vähem me lubame koordinaatobjekte, seda kaugemal nad peavad üksteisest asuma. Täpset funktsionaalset seost nende vahel on raske määrata, sest see sõltub objektimassiivi struktuurist. Sellise heuristilise meetodi rakendamisel on konkreetse objektimassiivi korral otstarbekas piirduda suuruste  $h_{\max}$  ja  $d_{\min}$  empiirilise ette andmisega.

Koordinaatobjektide arvu  $h_{\max}$  ette andmisel tuleb arvestada, et suurus  $h_{\max}$  on nii alt kui ülalt tõkestatud. Alumiseks tõkkeks on säiluv informatsioon. Mida väiksem on koordinaatobjektide arv, seda harvemini nad paiknevad objektimassiivis, seda vähem informatsiooni annavad objekti lähimad koordinaatobjektid, Selle piiri kindlaks tegemiseks tuleb konkreetset ülesannet lahendada mitme intuiitiivselt ette antava koordinaatobjektide arvuga. Ülalt piirab koordinaatobjektide arvu objektide arv  $n$ . Et meie eesmärgiks on rühmitamiseks vajalike arvutuste vähendamine, huvitab meid võimalikult väike koordinaatobjektide arv

$$h_{\max} \ll n.$$

Arvutatavate kauguste arv koordinaatobjektide otsimisel sõltub objektimassiivi struktuurist ning esimese koordinaatobjekti valikust. Juhul, kui enamus otsitavaid koordinaatobjekte leitakse esimeste vaadeldavate objektide seast, võib arvutatavate kauguste arv olla maksimaalne ning olla ülimalt

$$\frac{h(n-h)}{2}$$

Praktiliselt osutub see arv tunduvalt väiksemaks.

Ka suurust  $d_{\min}$  pole võimalik täpselt ette anda, sest see eeldaks, et meil oleksid kõigi objektide vahelised kaugused teada. Konkreetse objektimassiivi puhul valime juhuslikult mõned objektid ning leiame nende omavahelised kaugused  $d_1 \dots d_r$ . Suuruse  $d_{\min}$  valime

$$\min \{ d_1 \dots d_r \} < d_{\min} < \max \{ d_1, \dots, d_r \} .$$

Arvestades koordinaatobjektide arvu  $h_{\max}$  ja kauguse  $d_{\min}$  omavahelist sõltuvust, on võimalik etteantud  $d_{\min}$  väärtust ülesande lahendamise käigus parandada, vt.lk.14.

Olgu antud  $n$  objektist koosnev massiiv.

$$O = (O_1 \dots O_n).$$

Iga objekti iseloomustagu  $m$  tunnuse väärtust. Mõõtmistulemused võime siis kirja panna maatrikskujul:

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ \dots & \dots & \dots & \dots \\ a_{i1} & a_{i2} & \dots & a_{im} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{pmatrix} ,$$

kus element  $a_{ij}$  on  $i$ -nda objekti  $j$ -nda tunnuse väärtus. Selline objektikogum kujutab endast  $n$  punktist koosnevat punktihulka  $m$  mõõtmelises ruumis. Objektide omavaheliseks võrdlemiseks kasutatav kaugus võib olla defineeritud mitme suguselt. Kasutada võib Mahalanobise, Eukleidilisi jt. kaugusi. Käesoleva ülesande lahendamisel kasutame Eukleidilist kaugust. Kahe objekti  $O_i$  ja  $O_j$  vahel defineerime kauguse :

$$d_{ij} = \sqrt{(a_{i1} - a_{j1})^2 + \dots + (a_{im} - a_{jm})^2},$$

kus suurused  $a_{ik}$  ja  $a_{jk}$  on nende objektide vastavate tunnuste väärtused. Kui erinevatel tunnustel on muutumispiirkonnad erinevad, siis normeerime tunnuste väärtused:

$$\frac{x_i - \bar{x}_i}{x_{\max} - x_{\min}}, \quad \text{kus } \bar{x}_i, x_{\max} \text{ ja } x_{\min} \text{ on vastavalt } i\text{-nda tunnuse keskmine, maksimaalne ja minimaalne väärtus, vt. /4/.$$

Esimese koordinaatobjekti valime suvaliselt. Praktiliselt on sobiv selleks valida esimene objekt algandmete maatriksist  $KO_1 = O_1$ . (hiljem kasutame tähistust  $KO_k$  ka  $k$ -nda koordinaatobjekti indeksi tähisena).

Võrdleme objekte alates  $O_2$  -st koordinaatobjektiga  $KO_1$ , st. leiame objektide  $O_2 \dots O_k$  kaugused koordinaatobjektist  $KO_1$ . Olgu:

- 1)  $d(O_i, KO_1) \leq d_{\min}$ , kus  $i = 2 \dots k-1$ ,
- 2)  $d(O_i, KO_1) > d_{\min}$ , kus  $i = k$ .

Juhul kui objektid  $O_i$ , kus  $i = 2 \dots k-1$ , on küllalt lähedal koordinaatobjektile  $KO_1$ , siis uuteks koordinaatobjektideks neid ei loeta ja nad kuuluvad mittekoordinaatobjektide massiivi  $\overline{KO}$

$$O_i \in \overline{KO}$$

Et vähendada tööd kõigile objektidele  $m$  lähima koordinaatobjekti leidmisel, fikseerime selle koordinaatobjekti indeksi, mille lähedal antud objekt asus. Selleks defineerime vektori  $KOI(i)$  järgmiselt:

$$KOI(i) = \begin{cases} 0, & \text{kui } d(O_i, KO_1) \leq d_{\min} , \\ 1, & \text{kui } d(O_i, KO_1) > d_{\min} . \end{cases}$$

Indeksi  $i$  teatud väärtusel  $k$  osutub objekt  $O_k$  küllalt erinevaks  $KO_1$ -st ja ta lisatakse koordinaatobjektide massiivi:

$$KO_2 = O_k .$$

Oletame, et on leitud  $s$  koordinaatobjekti  $KO_1 \dots KO_s$ . Nüüd tuleb objektimassiivi objekte  $O_i$  võrrelda kõigi olemasolevate koordinaatobjektidega. On kaks võimalust:

- 1)  $d(O_i, KO_s) \leq d_{\min}$ , kus  $s = 2 \dots h_{\max}$ ,
- 2)  $d(O_i, KO_s) > d_{\min}$ , mingi  $s$  korral.

Juhul, kui objekt  $O_i$  asub kas ühe või mitme koordinaatobjekti lähedal, on ta mittekoordinaatobjekt

$$O_i \in KO .$$

Sellisel juhul paneme kirja selle esialgse lähima koordinaatobjekti indeksi:

$$KOI(i) = \begin{cases} 0, & \text{kui } d(O_i, KO_s) \leq d_{\min} , \\ s, & \text{kui } d(O_i, KO_s) > d_{\min} . \end{cases}$$

Niipea, kui mingi  $s$  väärtusel  $t$  objekt  $O_t$  asub küllalt kaugel kõigist olemasolevaist koordinaatobjektidest, lisatakse ta koordinaatobjektide massiivi. Objektidemassiivi järgmisi vaatluse alla tulevaid objekte võrreldakse juba ühe objekti võrra suurenenud koordinaatobjektidemassiivi elementidega.

Protseduuri jätkatakse seni, kuni on leitud kõik koordinaatobjektid vastavalt etteantud arvule  $h_{\max}$  või  $h < h_{\max}$  koordinaatobjekti.

Võib tekkida olukord, et koordinaatobjektid  $KO_1 \dots KO_{h_{\max}}$  on kõik leitud, kuid seejuures pole tervet objektimassiivi  $O = O_1 \dots O_n$  läbi vaadatud. Ilmselt on siis ette antud  $d_{\min}$  liialt väike, teda tuleks suurendada. Üks võimalus on järgmine.

Oletame, et selleks ajaks millal leiti viimane koordinaatobjekt  $KO_{h_{\max}}$ , oli objektimassiivist läbi vaadatud  $t$  objekti  $O_1 \dots O_t$ . Vaatamata oli jäänud

$$p = \frac{(n-t)}{n} \cdot 100\% .$$

Seda arvestades võiks  $d_{\min}$  väärtust parandada valemiga:

$$d = d_{\min} \frac{(100+p)}{100} .$$

Seejärel tuleb uut  $d$  väärtust kasutades alustada koordinaatobjektide otsimist uuesti algusest, kuni on leitud kõik koordinaatobjektid kogu objektimassiivi ulatuses.

Nagu praktika näitas, suurenes  $d_{\min}$  sellisel parandamisel liiga palju ja ülesande edasisel lahendamisel ei leitud enam kõiki koordinaatobjekte vastavalt esialgu ette antud arvule  $h_{\max}$ . Märksa parema tulemuse andis  $d_{\min}$  parandamine valemiga:

$$d = d_{\min} \sqrt{\frac{(100+p)}{100}} .$$

Juhul, kui kogu objektimassiiv on läbi vaadatud, kuid leitud koordinaatobjektide arv on väiksem kui  $h_{\max}$ , siis on ette antud  $d_{\min}$  liiga suur. Ülesande lahendamist tuleb alustada uuesti, andes ette väiksema  $d_{\min}$  väärtuse.

Järgmiseks sammuks on koordinaatobjektide omavaheliste kauguste leidmine, st. leitakse algandmete maatriksist A koordinaatobjektide  $KO_1 \dots KO_{n_{\max}}$  omavahelised kaugused. Saadud tulemused võib esitada maatrikskujul:

$$D_{KO} = \begin{vmatrix} d_{11} & d_{12} & \dots & d_{1h} \\ \dots & \dots & \dots & \dots \\ d_{k1} & d_{k2} & \dots & d_{kh} \\ \dots & \dots & \dots & \dots \\ d_{h1} & d_{h2} & \dots & d_{hh} \end{vmatrix}$$

See on peadiagonaali suhtes sümmeetriline maatriks ( $d_{ij} = d_{ji}$ ) ning peadiagonaalil asuvad nullid.

Järgnevalt leiame iga koordinaatobjekti u lähimat koordinaatobjekti. Selleks leitakse maatriksi  $D_{KO}$  igas reas u vähimat elementi:

$$D'_{KO} = \begin{vmatrix} d'_{11} & d'_{12} & \dots & d'_{1u} \\ \dots & \dots & \dots & \dots \\ d'_{k1} & d'_{k2} & \dots & d'_{ku} \\ \dots & \dots & \dots & \dots \\ d'_{h1} & d'_{h2} & \dots & d'_{hu} \end{vmatrix}$$

Iga koordinaatobjekti u lähima koordinaatobjekti indeksid fikseerime maatriksis:

$$KOI = \begin{vmatrix} KO_{11} & KO_{12} & \dots & KO_{1u} \\ \dots & \dots & \dots & \dots \\ KO_{k1} & KO_{k2} & \dots & KO_{ku} \\ \dots & \dots & \dots & \dots \\ KO_{h1} & KO_{h2} & \dots & KO_{hu} \end{vmatrix}$$

Viimaseks sammuks on kõigile objektidele  $O_1 \dots O_n$  u lähima koordinaatobjekti leidmine.

Juhul, kui vaadeldav objekt  $O_i$  on ise koordinaatobjekt, saame tema lähimate koordinaatobjektide indeksid matriksist KOI, vastavad kaugused matriksist  $D_{KO}^i$ .

Kui objekt  $O_i$  ei ole koordinaatobjekt, saame ta lähima koordinaatobjekti indeksi  $\overline{KOI}$  -st. Teisi objektile  $O_i$  lähimaid koordinaatobjekte otsime tema lähima koordinaatobjekti lähedaste koordinaatobjektide seast (need saame matriksi KOI vastavast reast). Vaatluse alla võtame kokku objekti  $O_i$   $(u+1)$  lähimat koordinaatobjekti, millest leiame  $u$  lähimat.

Selleks arvutame algandmete matriksist kõigi  $(u+1)$  lähedase koordinaatobjekti ja antud objekti  $O_i$  vahelised kaugused. Neist leiame  $u$  vähimat.

Nii leiame kõigi objektide lähimate koordinaatobjektide kaugused ning indeksid:

$$AK = \begin{vmatrix} d_{11} & d_{12} & \dots & d_{1u} \\ \dots & \dots & \dots & \dots \\ d_{k1} & d_{k2} & \dots & d_{ku} \\ \dots & \dots & \dots & \dots \\ d_{n1} & d_{n2} & \dots & d_{nu} \end{vmatrix}$$

$$O = \begin{vmatrix} KO_{11} & KO_{12} & \dots & KO_{1u} \\ \dots & \dots & \dots & \dots \\ KO_{k1} & KO_{k2} & \dots & KO_{ku} \\ \dots & \dots & \dots & \dots \\ KO_{n1} & KO_{n2} & \dots & KO_{nu} \end{vmatrix}$$

Et edaspidi oleks omavahel sarnaseid objekte mugavam leida, tuleks ka lähimate koordinaatobjektide indeksid järjestada kasvavalt:

$$O' = \begin{pmatrix} KO_{11} & KO_{12} & \dots & KO_{1u} \\ \dots & \dots & \dots & \dots \\ KO_{k1} & KO_{k2} & \dots & KO_{ku} \\ \dots & \dots & \dots & \dots \\ KO_{n1} & KO_{n2} & \dots & KO_{nu} \end{pmatrix}$$

### VÖHANDU MEETODI PROGRAMM

Programm on koostatud elektronarvutile "Minsk-22". Programm on koostatud automaatses programmeerimiskeeles Malgol. Eeldatud on, et objektimassiiv ei sisalda üle 50 objekti, tunnuste arv on kuni 60 ja ette antav koordinaatobjektide arv on kuni 15 objekti.

Programmi töö käigus trükitakse välja koordinaatobjektide indeksid, iga mittekoordinaatobjekti lähima koordinaatobjekti indeks, koordinaatobjektide kauguste matriks ning kõigile objektidele vastavalt parameetri TK väärtusele kuni kuue lähima koordinaatobjekti kaugused ja vastavad indeksid.

```

MAGNETIC TAPE 77 PROGRAM 01
COMMENT 'TUNNUSPUNKTID' YESKI;
R001 PROCEDURE 'KAUGUS(A.,T,S,M,D); BEGIN'
R002 K:=0;
R003 FOR 'U:=1 STEP 1 UNTIL 'M DO 'BEGIN'
R004 K:=K+(A.(S,U).-A.(T,U).)*(A.(S,U).-A.(T,U).);
R005 END'; D:=SQRT'(K); END';
R006 ALGUS: READ1'(N,M,HM,DM,TK);
R007 ARRAY 'A.(1:N,1:M)., TPC.(1:HM)., TPE.(1:N).;
R010 READARRAY'(A.); K:=0;
R011 FOR 'J:=1 STEP 1 UNTIL 'M DO 'BEGIN'
R012 FOR 'I:=1 STEP 1 UNTIL 'N DO 'BEGIN'
R013 K:=K+A.(I,J).;
R014 K:=K/N; END';
R015 MAX:=A.(1,J).; MIN:=A.(1,J).;
R016 FOR 'I:=1 STEP 1 UNTIL 'N DO 'BEGIN'
R017 IF 'A.(I,J).)MAX THEN 'MAX:=A.(I,J).;
R020 IF 'A.(I,J).(MIN THEN 'MIN:=A.(I,J).; END';
R021 FOR 'I:=1 STEP 1 UNTIL 'N DO'
R022 A.(I,J).:=(A.(I,J).-K)/(MAX-MIN); END';
R023 M2:H:=1; TPC.(1).:=1;
R024 FOR 'J:=1 STEP 1 UNTIL 'N DO 'TPE.(J).:=0;
R025 FOR 'I:=2 STEP 1 UNTIL 'N DO 'BEGIN'
R026 FOR 'K:=1 STEP 1 UNTIL 'H DO 'BEGIN'
R027 X:=I; Y:=TPC.(K).; KAUGUS(A.,X,Y,M,D);
R030 IF 'D(:DM THEN 'GOTO 'M; END';
R031 TPC.(H+1).:=1;
R032 IF 'H=HM THEN 'BEGIN'
R033 DM:=DM*((2*N-I)/N); PRINT1'(DM); GOTO 'M2; END';
R034 H:=H+1; GOTO 'L; M:TPE.(I).:=TPC.(K).; FOR 'R:=K+1 STEP 1 UNTIL 'H DO 'BEGIN'
R035 KAUGUS(A.,I,TPC.(R).,M,D1); IF 'D(:D1 THEN 'BEGIN' D:=D1; TPE.(I).:=TPC.(R).; END'; END'; L: END'; HM:=H;
R036 ARRAY 'TPI.(1:HM)., TPK.(1:HM,1:HM)., TPLI.(1:HM,1:TK)., TPLK.(1:HM,1:TK)., D1.(1:TK+1)., F1.(1:HM)., F3.(1:TK+1)., B1.(1:N,1:TK).,
B2.(1:N,1:TK).;
R037 FOR 'I:=1 STEP 1 UNTIL 'HM DO 'BEGIN'
R040 TPI.(I).:=TPC.(I).; END';
R041 TEXT10'('KOORDINAATOBJEKTID'); OUTPUT'(2);
R042 FOR 'I:=1 STEP 1 UNTIL '124 DO'
R043 TEXT10'('='); OUTPUT'(1); K:=0;
R044 FOR 'I:=1 STEP 1 UNTIL 'HM DO 'BEGIN'
R045 TEXTR10'(4,0,TPI.(I).,'I'); K:=K+1;
R046 IF 'K=20 THEN 'BEGIN' K:=0; OUTPUT'(1); END';
R047 END'; OUTPUT'(1);
R050 FOR 'I:=1 STEP 1 UNTIL '124 DO'
R051 TEXT10'('='); OUTPUT'(3);
R052 TEXT10'('OBJEKT I LAHEDANE KOORDINAATOBJEKT'); OUTPUT'(2);
R053 FOR 'I:=1 STEP 1 UNTIL '124 DO'
R054 TEXT10'('='); OUTPUT'(1);
R055 FOR 'I:=1 STEP 1 UNTIL 'N DO'
R056 IF 'TPE.(I).#0 THEN 'BEGIN'
R057 TEXTR10'(2,0,'I=' ,I,':',TPE.(I).,'I'); K:=K+1;
R060 IF 'K=9 THEN 'BEGIN' K:=0; OUTPUT'(1); END'; END';
R061 OUTPUT'(1); FOR 'I:=1 STEP 1 UNTIL '124 DO'
R062 TEXT10'('='); OUTPUT'(6);
R063 FOR 'I:=1 STEP 1 UNTIL 'HM DO 'BEGIN'
R064 FOR 'J:=1 STEP 1 UNTIL 'HM DO 'BEGIN'
R065 X:=TPI.(I).; Y:=TPI.(J).; KAUGUS(A.,X,Y,M,D);

```

```

R066 TPK. (I,J). := D; END; END;
R067 TEXT 10 ('KOORDINAATOBJEKTIDE KAUGUSED'); OUTPUT (2);
R070 FOR I:=1 STEP 1 UNTIL 124 DO
R071 TEXT 10 ('='); OUTPUT (1);
R072 FOR I:=1 STEP 1 UNTIL HM DO BEGIN
R073 FOR J:=1 STEP 1 UNTIL HM DO
R074 TEXT R10 (2,2,TPK.(I,J).);
R075 OUTPUT (1); END;
R076 OUTPUT (1); FOR I:=1 STEP 1 UNTIL 124 DO
R077 TEXT 10 ('='); OUTPUT (3);
R100 FOR I:=1 STEP 1 UNTIL HM DO BEGIN
R101 FOR J:=1 STEP 1 UNTIL HM DO BEGIN
R102 F1.(J). := 0; END;
R103 FOR V:=1 STEP 1 UNTIL TK DO BEGIN
R104 MIN:=40000;
R105 FOR J:=1 STEP 1 UNTIL HM DO BEGIN
R106 IF TPK.(I,J). (<MIN*.I/=J*.F1.(J).)=0
R107 THEN BEGIN MIN:=TPK.(I,J).; U:=J; END; END;
R110 F1.(U). := 1; TPLI.(I,V). := TPI.(U).; TPLK.(I,V). := TPK.(I,U).; END; END;
R111 TEXT 10 ('KOLMURGAD'); OUTPUT (2);
R112 FOR I:=1 STEP 1 UNTIL 124 DO
R113 TEXT 10 ('='); OUTPUT (1);
R114 FOR I:=1 STEP 1 UNTIL HM DO BEGIN
R115 FOR V:=1 STEP 1 UNTIL TK DO
R116 TEXT R10 (4,0,TPLI.(I,V).); OUTPUT (1);
R117 FOR V:=1 STEP 1 UNTIL TK DO
R120 TEXT R10 (2,2,TPLK.(I,V).); OUTPUT (2); END;
R121 FOR I:=1 STEP 1 UNTIL 124 DO
R122 TEXT 10 ('='); OUTPUT (3);
R123 FOR I:=1 STEP 1 UNTIL N DO BEGIN
R124 FOR K:=1 STEP 1 UNTIL HM DO
R125 BEGIN IF I=TPI.(K). THEN BEGIN
R126 FOR L:=1 STEP 1 UNTIL TK DO BEGIN
R127 B2.(I,L). := TPLK.(K,L).; B1.(I,L). := TPLI.(K,L).;
R130 END; GOTO G; END; END;
R131 X:=I; Y:=TPI.(I).; KAUGUS(A.,X,Y,M,D);
R132 D1.(1). := D; F3.(1). := Y; FOR K:=1 STEP 1 UNTIL HM DO IF Y=TPI.(K). THEN GOTO P;
R133 P: FOR W:=1 STEP 1 UNTIL TK DO BEGIN
R134 X:=I; Y:=TPLI.(K,W).; KAUGUS(A.,X,Y,M,D);
R135 F3.(W+1). := Y; D1.(W+1). := D; END;
R136 FOR WW:=1 STEP 1 UNTIL TK DO BEGIN
R137 FOR W:=WW STEP 1 UNTIL TK+1 DO BEGIN
R140 IF D1.(W). (<D1.(WW)). THEN BEGIN MIN:=D1.(W).; D1.(W). := D1.(WW).; D1.(WW). := MIN;
R141 MIN:=F3.(W).; F3.(W). := F3.(WW).; F3.(WW). := MIN; END; END; END;
R142 FOR W:=1 STEP 1 UNTIL TK DO BEGIN B1.(I,W). := F3.(W).; B2.(I,W). := D1.(W).; END;
R143 G; END;
R144 TEXT 10 ('LAHIMAD KOORDINAATOBJEKTID'); OUTPUT (2);
R145 FOR I:=1 STEP 1 UNTIL 124 DO
R146 TEXT 10 ('='); OUTPUT (1);
R147 FOR I:=1 STEP 1 UNTIL N DO BEGIN
R150 FOR V:=1 STEP 1 UNTIL TK DO
R151 TEXT R10 (4,0,B1.(I,V).); OUTPUT (1); END; OUTPUT (2);
R152 FOR I:=1 STEP 1 UNTIL 124 DO
R153 TEXT 10 ('='); OUTPUT (3);
R154 TEXT 10 ('LAHIMATE KOORDINAATOBJEKTIDE KAUGUSED');
R155 OUTPUT (2); FOR I:=1 STEP 1 UNTIL 124 DO

```

```

R156 TEXT10('=');OUTPUT'(2);
R157 FOR'I:=1 STEP'1 UNTIL'N DO'BEGIN'
R160 FOR'V:=1 STEP'1 UNTIL'TK DO'
R161 TEXTR10'(2,2,B2.(I,V).);OUTPUT'(2);END';
R162 FOR'I:=1 STEP'1 UNTIL'124 DO'
R163 TEXT10('=');OUTPUT'(3);
R164 STOP';START'ALGUS;FINISH';
R165
R166

```

COMMENT: TUNNUSPUNKTID' VESKI;

MEMORY PLAN

VARIABLES		2262	TPI
2140	K	2263	TPKI
2141	U	2264	TPLI
2142	N	2265	TPLK
2143	M	2266	D1
2144	HM	2267	F1
2145	DM	2270	F3
2146	TK	2271	B1
2147	K	2272	B2
2150	J	SUBROUTINES	
2151	I	2334	2362
2152	MAX	2431	2562
2153	MIN	2443	2451
2154	H	2476	2531
2155	X	2544	2561
2156	V	2602	2606
2157	D	2621	2753
2161	R	2633	2653
2163	D1	2723	2752
2171	V	3051	3061
2172	U	3102	3104
2175	L	3122	3144
2176	W	3161	3163
2201	WW	3211	3213
TABLE OF ARRAYS		3230	3264
2257	A	3301	3303
2260	TPC	3320	3356
2261	TPE	3332	3355

3401	3403
3420	3446
3432	3443
3463	3465
3502	3632
3514	3520
3533	3631
3546	3601
3652	3654
3671	3745
3703	3714
3731	3742
3760	3762
3777	4334
4011	4061
4033	4057
4117	4130
4143	4173
4206	4276
4222	4275
4311	4333
4357	4361
4376	4424
4410	4421
4441	4443
4472	4474
4511	4537
4523	4534

4552	4554	
LABELS		
2370	ALGUS	
2563	M2	
2700	M	
2753	L	
4131	P	
4334	G	
PROCEDURES		
0504	0627	READ1
0630	0742	ARRAY
0743	1053	READAR
1054	1232	PRINT1
1233	1554	TEXT10
1555	1564	OUTPUT
1565	2127	TEXTR1
2320	2367	KAUGUS
FUNCTIONS		
0460 - 0503	SQRT	
OPERATING VARIABLES		
2205 - 2210		
CONSTANTS		
2211 - 2256		
PROGRAM		
2307 - 4560		
START 0105		

### N ä i d e.

Objektide massiiv koosneb 24 objektist. Objektideks on antigeenid, vt. /tabel 1/. Tunnuste arv on 24.

Ülesande lahendamisel anti ette suhteliselt suur koordinaatobjektide arv - 12. Kauguse  $d_{\min}$  ette andmiseks valiti juhuslikult neli objektipaari. Nendevahelised kaugused olid 1,54; 2,42; 1,85; 2,08. Leitud kauguste põhjal ette antud  $d_{\min} = 1,5$  osutus väikseks. Suurust  $d_{\min}$  suurendati 1,7-le. Nagu arvutuste käigus selgus, sobis  $d_{\min} = 1,7$  ette antud koordinaatobjektide arvuga 12.

Ülesande esmakordsel lahendamisel leiti igale objektile 3 lähimat koordinaatobjekti. Kui lahenduse kontrollimiseks tervekauguste tabel välja arvutati, selgus et esimese kaheteistkümnepunktse objekti seas olevatele mittekoordinaatobjektidele ei olnud leitud lähimaid koordinaatobjekte.

Põhjus oli ilmselt selles, et koordinaatobjektide arv protseduuri alguses on suhteliselt väike. Peale mittekoordinaatobjekti  $\bar{O}_i$  lähima koordinaatobjekti  $KO_i$  fikseerimist võis mõni hiljem juurde tulnud koordinaatobjekt  $KO_i'$  asuda objektile  $O_i$  lähemal, kui  $KO_i$ .

Kui koordinaatobjekt  $KO_i'$  ei asunud  $KO_i$ -le küllalt lähedal, st. ei tulnud koordinaatobjekti  $KO_i$  kolme lähima koordinaatobjekti hulka, siis mittekoordinaatobjekti  $O_i$  lähimate koordinaatobjektide otsimisel jäi  $KO_i'$  vaatluse alt hoopis välja.

Siis, kui parameetrile TK anti väärtus 5, st. leiti igale koordinaatobjektile 5 lähimat koordinaatobjekti ja seega ka igale objektile 5 lähimat koordinaatobjekti, muutusid tulemused tunduvalt.

Täieliku kauguste tabeliga võrdlemisel selgus, et saadud tulemused olid kõigi viie lähima koordinaatobjekti jaoks absoluutselt täpsed. Ülesande lahendamiseks kuluv aeg suurenes seejuures väga vähe.

Antigeenid	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	5	5	5	5	5	3	2	5	4	4	4	4	4	2	3	3	3	2	5	5	4	5	5	3
2	5	4	4	5	5	2	4	5	4	4	5	5	5	2	4	5	4	3	5	5	5	5	5	4
3	3	3	5	3	3	2	2	3	2	3	4	4	4	2	3	3	3	3	4	4	3	5	3	3
4	5	5	3	5	3	2	3	5	4	3	4	5	5	2	3	3	3	3	3	4	3	3	3	3
5	3	4	3	3	4	2	3	5	3	3	4	3	3	2	2	3	2	3	4	4	4	4	4	2
6	4	4	2	4	3	3	3	4	4	4	3	4	3	2	3	3	2	3	3	4	3	4	3	2
7	3	2	2	4	4	2	3	3	3	3	5	3	3	2	2	3	3	3	5	5	4	3	5	3
8	5	5	5	3	5	2	2	5	3	4	5	5	4	2	3	4	3	3	3	5	5	5	5	3
9	5	4	2	3	2	2	3	3	4	2	4	4	3	1	4	3	2	2	2	3	3	3	2	3
10	5	3	3	5	3	2	2	5	5	4	5	5	5	2	3	4	4	4	4	4	5	5	5	3
11	4	5	3	3	3	2	3	5	3	4	5	5	4	2	3	3	3	2	4	4	3	5	5	3
12	5	4	2	5	3	2	3	5	3	3	5	5	3	2	3	3	3	3	3	5	4	4	5	3
13	3	2	2	4	4	3	2	5	4	3	5	5	5	2	3	4	3	3	3	3	3	4	3	3
14	3	4	3	4	4	2	3	5	5	3	3	3	5	3	3	3	3	3	4	3	4	3	3	3
15	3	2	2	4	5	2	4	5	3	2	4	4	5	2	4	3	3	3	4	3	3	2	3	4
16	4	3	2	5	4	3	2	2	3	4	5	3	3	2	3	5	3	2	3	3	3	3	2	3
17	4	3	3	2	5	1	5	5	4	3	4	4	3	2	3	4	3	4	3	4	3	4	2	3
18	4	3	3	5	4	2	3	5	5	4	5	5	5	2	3	2	3	4	3	5	3	5	4	2
19	4	3	3	4	4	2	3	5	4	3	5	4	3	2	3	3	4	5	4	4	4	5	4	2
20	4	3	4	5	3	2	3	3	3	4	5	5	2	2	3	4	3	3	4	5	3	4	2	3
21	3	3	3	5	5	2	2	5	4	5	5	4	3	3	3	4	5	4	5	4	5	5	5	3
22	4	4	4	5	5	3	2	5	5	4	5	5	3	3	4	4	3	3	4	5	3	5	5	3
23	3	3	3	5	5	3	4	5	4	3	5	5	4	3	4	5	4	5	4	5	4	5	5	3
24	3	3	3	5	5	2	3	3	4	3	5	5	5	2	3	4	2	2	5	5	3	5	3	4

T a b e l 1

KOORDINAATOBJEKTID

```

=====
1.I      3.I      4.I      7.I      9.I      10.I     13.I     14.I     16.I     17.I     23.I     24.I
=====

```

OBJEKT I LAHEDANE KOORDINAATOBJEKT

```

=====
I=2.: 1.II= 3.: 3.II= 6.: 4.II= 8.: 1.II= 11.: 4.II= 12.: 4.II= 15.: 13.II= 18.: 4.II= 19.: 10.II= 20.: 3.II= 21.:
10.II= 22.: 1.I
=====

```

KOORDINAATOBJEKTIDE KAUGUSED

```

=====
0.00  2.18  1.91  2.38  2.87  1.89  2.53  2.31  2.67  2.64  2.26  2.14
2.18  0.00  2.06  1.98  2.23  2.42  1.91  2.03  2.11  2.01  2.42  1.86
1.91  2.06  0.00  2.49  1.80  1.83  1.85  1.89  2.26  1.99  2.37  2.07
2.38  1.98  2.49  0.00  2.73  2.37  2.23  2.22  2.13  2.30  2.30  1.99
2.87  2.23  1.80  2.73  0.00  2.73  2.24  2.36  1.99  2.11  3.20  2.67
1.89  2.42  1.83  2.37  2.73  0.00  2.01  2.35  2.66  2.54  1.92  2.27
2.53  1.91  1.85  2.23  2.24  2.01  0.00  1.96  1.89  2.11  2.02  1.81
2.31  2.03  1.89  2.22  2.36  2.35  1.96  0.00  2.29  1.99  2.46  2.35
2.67  2.11  2.26  2.13  1.99  2.66  1.89  2.29  0.00  2.42  2.77  2.25
2.64  2.01  1.99  2.30  2.11  2.54  2.11  1.99  2.42  0.00  2.35  2.25
2.26  2.42  2.37  2.30  3.20  1.92  2.02  2.46  2.77  2.35  0.00  2.01
2.14  1.86  2.07  1.99  2.67  2.27  1.81  2.35  2.25  2.25  2.01  0.00
=====

```

KOLMNRG D

10.	4.	24.	3.	23.
1.89	1.91	2.14	2.18	2.26
24.	13.	7.	17.	14.
1.86	1.91	1.98	2.01	2.03
9.	10.	13.	14.	1.
1.80	1.83	1.85	1.89	1.91
3.	24.	16.	14.	13.
1.98	1.99	2.13	2.22	2.23
4.	16.	17.	3.	13.
1.80	1.99	2.11	2.23	2.24
4.	1.	23.	13.	24.
1.83	1.89	1.92	2.01	2.27
24.	4.	16.	3.	14.
1.81	1.85	1.89	1.91	1.96
4.	13.	17.	3.	7.
1.89	1.96	1.99	2.03	2.22
13.	9.	3.	7.	24.
1.89	1.99	2.11	2.13	2.25
4.	14.	3.	13.	9.
1.99	1.99	2.01	2.11	2.11
10.	24.	13.	1.	7.
1.92	2.01	2.02	2.26	2.30
13.	3.	7.	23.	4.
1.81	1.86	1.99	2.01	2.07

LAHIMAD KOORDINAATOBJEKTID

10.	4.	24.	3.	23.
10.	1.	23.	24.	4.
24.	13.	7.	17.	14.
9.	10.	13.	14.	1.
7.	14.	3.	17.	13.
4.	9.	14.	13.	1.
3.	24.	16.	14.	13.
1.	10.	4.	23.	3.
4.	16.	17.	3.	13.
4.	1.	23.	13.	24.
4.	1.	13.	10.	9.
4.	10.	1.	13.	9.
24.	4.	16.	3.	14.
4.	13.	17.	3.	7.
13.	14.	4.	24.	3.
13.	9.	3.	7.	24.
4.	14.	3.	13.	9.
4.	10.	13.	1.	14.
10.	23.	13.	4.	1.
3.	24.	17.	7.	13.
23.	10.	1.	13.	24.
23.	1.	24.	10.	4.
10.	24.	13.	1.	7.
13.	3.	7.	23.	4.

LAHIMATE KOORDINAATOBJEKTIDE KAUGUSED

=====

1.89	1.91	2.14	2.18	2.26
1.80	1.64	1.66	2.12	2.24
1.86	1.91	1.98	2.01	2.03
1.80	1.83	1.85	1.89	1.91
1.52	1.61	1.67	1.81	2.07
1.57	1.72	1.76	1.89	2.11
1.98	1.99	2.13	2.22	2.23
1.49	1.71	2.07	2.19	2.23
1.80	1.99	2.11	2.23	2.24
1.83	1.89	1.92	2.01	2.27
1.55	1.78	1.85	1.86	2.22
1.44	1.55	1.85	2.09	2.22
1.81	1.85	1.89	1.91	1.96
1.89	1.96	1.99	2.03	2.22
1.56	1.64	1.99	2.01	2.09
1.89	1.99	2.11	2.13	2.25
1.99	1.99	2.01	2.11	2.11
1.60	1.66	1.79	1.99	2.29
1.53	1.66	1.81	1.89	2.01
1.63	1.68	2.00	2.02	2.07
1.64	1.68	2.09	2.21	2.31
1.47	1.51	1.86	1.89	2.01
1.92	2.01	2.02	2.26	2.30
1.81	1.86	1.99	2.01	2.07

=====

### III 1. Järk-järguline rühmitamine.

TA Ajaloo Instituudis tekkis seoses ühe konkreetse tööga vajadus uuritavate objektide rühmitamiseks. Ülesande lahendamiseks sai valitud suhteliselt väikese töömahuga ja lihtsa algoritmiga järk-järguline rühmitamise meetod, vt. /7/.

Meetod kuulub induktiivsete rühmitamise meetodite klassi ja on põhimõtteliselt sarnane Sokal-Michneri meetodiga.

Rühmitamine algab objektidevahelise korrelatsioonimaatriksi leidmisest. Rühmadeks ühendamisel peetakse silmas objektidevahelist maksimaalset korrelatsiooni, rühmade omavahelisel ühendamisel rühmade raskuskeskmete vahelist maksimaalset korrelatsiooni.

Olgu antud  $n$  - objekti  $O_1 \dots O_n$ , mida soovime rühmitada. Esimesel sammul on rühmade arvuks  $n$ . Iga rühm sisaldab vaid üht objekti ning rühmad on tähistatud neisse kuuluvate objektide järgi indeksitega

$$R_1 \dots R_n .$$

Leiame  $(n \times n)$  korrelatsioonimaatriksist maksimaalse suuruse  $r_{ij}$ , mis esitab objektide  $O_i$  ja  $O_j$  vahelist korrelatsiooni

$$\max_{i \neq j} r_{ij} = r_{i^* j^*} .$$

Nende kahe objekti kokkuliitmisel moodustatakse uus rühm, mis tähistatakse indeksiga:

$$b = \min \{ i^* , j^* \} .$$

Järgnevalt leitakse antud sammul mitteliitunud objektide ja äsja moodustatud rühma vahelised korrelatsioonid.

Rühma  $R_b$  ja objektide  $O_q$  vahelised parandatud korrelatsioonid saadakse seostest:

$$\begin{aligned} r_{bq} &= s_{bq} / \sqrt{s_{bb} \cdot s_{qq}} = \\ &= \text{cov}(x_{i^*} + x_{j^*}, x_q) / \sqrt{D(x_{i^*} + x_{j^*}) \cdot D(x_q)} = \\ &= (s_{i^* q} + s_{j^* q}) / \sqrt{(s_{i^* i^*} + s_{j^* j^*} + 2 s_{i^* j^*})} \end{aligned}$$

kus  $x_i$  tähistab indeksile  $i$  vastavat objekti ja  $s_{i q}$  on tavaline objektikogumi kovariatsioon. Saadud korrelatsioonid asendatakse maatriksi  $b$ -ndasse ritta ja veergu. Seejärel muudetakse  $m$ -s rida ja veerg

$$m = \max \{ i^*, j^* \}$$

mitteoluliseks, asendades vastava rea ja veeru elemendid mingi suure negatiivse arvuga (näit. - 100). Otsime uuesti korrelatsioonimaatriksist suurimat elementi. Teisel sammul vaatleme sisuliselt juba  $(n-1) \times (n-1)$  -maatriksit, sest esialgsest maatriksist üks rida ja veerg ei tule enam arvesse. Leitud <sup>simaalse</sup> korrelatsiooni põhjal võib sellel sammul ühineda äsja moodustatud rühmaga  $R_b$  mingi uus objekt  $O_i$ . Suurim korrelatsioon võib kuuluda aga ka mingile uuele objektipaarile ja järgmisel sammul ühendatakse need. Parandused korrelatsioonimaatriksis tehakse analoogiliselt esimesele sammule.

Kolmandal ja järgnevatel sammudel võivad ühineda:

- 1) kaks rühma (rühmad sisaldavad enam kui üht objekti),
- 2) kaks objekti (ehk üheobjektulist rühma),
- 3) rühm ja mingi objekt.

Liites igal sammul 2 rühma, mille raskuskeskmete vaheline korrelatsioon on suurim, vähendatakse rühmade arvu ühe võrra. Samal ajal parandatakse ka korrelatsioonimaatriksit, võttes arvesse muutusi rühmade koosseisus. Rühmitamine lõpetatakse, kui kõik vaadeldavad objektid on ühendatud ühte rühma. Seega suurim rühm sisaldab kõiki objekte. Et rühmitamise alguses oli rühmade arv  $n$ , kulus kogu objektimassiivi rühmitamiseks  $(n-1)$  sammu. See, millise sammu järel moodustunud rühmad vastavakõige paremini konkreetsele olukorrale, sõltub lahendatavast ülesandest.

Juhul, kui vaadeldavad objektid on kirjeldatud juba korrelatsioonimaatriksiga, ei ole uute korrelatsioonide arvutamiseks eespool toodud valemeid võimalik kasutada. Sellisel juhul võib minna teist teed: leida moodustunud rühma  $b$  ja antud sammul mitteühinenud objektide vahel  $n_n$  keskmine korrelatsioon järgmiste valemite abil:

$$z_{i^*q} = \frac{1}{2} \ln \frac{1 + r_{i^*q}}{1 - r_{i^*q}},$$

$$z_{j^*q} = \frac{1}{2} \ln \frac{1 + r_{j^*q}}{1 - r_{j^*q}},$$

$$\bar{z} = \frac{z_{i^*q} + z_{j^*q}}{2},$$

$$\bar{r}_{bq} = \frac{e^{2\bar{z}_{bq}} - 1}{e^{2\bar{z}_{bq}} + 1}.$$

Saadud  $\bar{r}_{bq}$  väärtused asendatakse korrelatsioonimaatriksi  $b$ - ndasse ritta ja veergu.

Korrelatsioonimaatriksi peadiagonaalil asuvad ühed muudavad logaritmitava avaldise nimetaja juhul, kui  $q = i^*$  või  $q = j^*$ , nulliks, avaldise enda määramatuks. Et aga suurimat  $r_{ij}$  otsitakse väljaspool peadiagonaali ja  $m - s$  rida ja veerg ( $m = \max\{i^*, j^*\}$ ) muudetakse järgnevalt mitteoluliseks, võib praktilisel arvutamisel asendada peadiagonaali elemendid suvalise arvuga  $-1 < a < +1$ .

III 2. Järk-järgulise rühmitamise meetodi  
programm.

Rühmitamise programm on koostatud elektronarvutile "Minsk - 22". Programm on koostatud automaatses programmeerimiskeeles Malgol. Eeldatud on, et objektide massiiv ei ületa 45 objekti ning antud on objektide vaheline samasus-maatriks. Programmi töö käigus trükitakse välja igal sammul ühinenud objektide indeksid.

MAGNETIC TAPE 77 PROGRAM 03

COMMENT' CLUST WESKI;

```

R001 SUBROUTINE' MAX; BEGIN'
R002 M:=R.(1,2); K:=1; S:=2;
R003 FOR' I:=1 STEP' 1 UNTIL' N-1 DO'
R004 FOR' J:=I+1 STEP' 1 UNTIL' N DO' BEGIN'
R005 IF' M(:R.(I,J)). THEN' BEGIN'
R006 K:=I; S:=J; M:=R.(I,J);
R007 END'; END';
R010 IF' K:)S THEN' BEGIN'
R011 I:=K; K:=S; S:=I; END';
R012 FOR' I:=1 STEP' 1 UNTIL' N DO' BEGIN'
R013 IF' R.(I,S) -1 * R.(I,K) -1 THEN' BEGIN'
R014 Z:=(LN'((1+R.(I,K))/(1-R.(I,K)))+LN'((1+R.(I,S))/(1-R.(I,S))))/2;
R015 Z:=(EXP'(Z)-1)/(EXP'(Z)+1);
R016 R.(I,K):=Z; R.(K,I):=Z;
R017 END'; END'; FOR' I:=1 STEP' 1 UNTIL' N DO' BEGIN' R.(S,I):=-10; R.(I,S):=-10; END';
R020 FOR' I:=1 STEP' 1 UNTIL' N DO' BEGIN'
R021 F.(K,I):=F.(K,I)+F.(S,I);
R022 IF' F.(K,I) =/0 THEN' TEXT10'(2,0,I); END';
R023 TEXT10'('
R024
R025 '); END';
R026 ALGUS: READ1'(N); OUTPUT'(6);
R027 ARRAY' R.(1:N,1:N), F.(1:N,1:N);
R030 READARRAY'(R.);
R031 FOR' I:=1 STEP' 1 UNTIL' N DO'
R032 FOR' J:=1 STEP' 1 UNTIL' N DO' BEGIN'
R033 IF' I=J THEN' F.(I,J):=1 ELSE' F.(I,J):=0; END';
R034 L:=0; FOR' B:=1 STEP' 1 UNTIL' N DO'
R035 FOR' W:=B+1 STEP' 1 UNTIL' N-1 DO' BEGIN'
R036 IF' R.(B,W) -1 THEN' MAX; L:=L+1; IF' L=33 THEN' PRINTA'(R.); END';
R037 STOP'; START' ALGUS; FINISH';
R040
R041

```

COMMENT' CLUST WESKI;

MEMORY PLAN

VARIABLES

1702	M
1703	K
1704	S
1705	I
1707	N
1710	J
1711	Z
1712	L
1713	B
1714	W

TABLE OF ARRAYS

1731	R
1732	F

SUBROUTINES

1747	2254	MAX
1772	2026	
2005	2025	
2050	2154	
2167	2203	
2216	2251	
2311	2344	

2323	2343
2360	2421
2375	2420

LABELS

2255	ALGUS
------	-------

PROCEDURES

0556	1077	TEXT10
1100	1223	READ1
1224	1233	OUTPUT
1234	1346	ARRAY
1347	1457	READAR

1460	1673	PRINTA
------	------	--------

FUNCTIONS

0516	-	0555	EXP
0460	-	0515	LN

OPERATING VARIABLES

1716	-	1717
------	---	------

CONSTANTS

1720	-	1730
------	---	------

PROGRAM

1735	-	2423
------	---	------

START 0105

### III 3. Näide.

Ülesanne on seotud TA Ajaloo Instituudi sotsioloogia sektoris läbi viidud uurimusega "Teie ja kultuur". Uurimuse üheks eesmärgiks oli uurida raamatukogude lugejaskonna struktuuri, saada raamatukogude töötajatele andmeid kirjanduse soovitamiseks. Lugejail lasti nimetada eesti lemmikirjanik, lemmikautor vene ja nõukogude kirjanike seast.

Sellisel saadud andmete põhjal oli arvutatud Yule'i korrelatsioonikoefitsient kõigi kirjanike vahel. Tulemused olid esitatud korrelatsioonimaatriksina /vt. tabel 2/.

Vaatluse alla oli võetud 40 sagedamini nimetatud kirjanikku. Esitatud korrelatsioonimaatriks peegeldas kirjanike "lähedust" sõltuvalt teatud lugejagruppide vanusest, haridusest, maitsest jms.

Sobivaiks osutusid rühmad, mis olid moodustunud 34. sammuks. Need rühmad sisaldasid juba enamuse vaadeldavaist kirjanikest. Rühmadesisese struktuuri sai eelnevatel sammudel moodustunud alamrühmi vaadeldes. Kirjanikevaheline "sarnasus" alamrühmade sees oli ilmselt suurem kogu rühma kirjanike omavahelisest sarnasusest. Peale 33. sammu oli korrelatsioonimaatriksi suurimaks elemendiks 0,3503, korrelatsioon oli tunduvalt vähenenud. Saadud korrelatsioonitabelist sai välja lugeda moodustunud rühmade omavahelised korrelatsioonid, vt. /tabel 3/

Kirjanike loetelu korrelatsioonimaatriksis on

järgmine:

1. Koidula	14. Kuusberg	27. Sand
2. Turgenjev	15. Metsanurk	28. Puškin
3. Bornhöhe	16. Jessenin	29. Kaugver
4. Mälk	17. Brontë, C.	30. Tolstoi, A.
5. London	18. Sirge	31. Tuglas
6. Lermontov	19. Zolà	32. Hint
7. Jakobson, A.	20. Tagore	33. Smuul
8. Liiv	21. Simonov	34. Dumas
9. Balzac	22. Rolland	35. Šolohhov
10. Gross	23. Galsworthy	36. Tolstoi, L.
11. Dostojevski	24. Hemingway	37. Vilde
12. Sergó	25. Hugo	38. Lacis
13. Gorki	26. Vaher	39. Luts
		40. Tammsaare

Saadud kirjanike rühmitused (kaldkriipsudega on tähistatud alarühmad sarnasuse kohanemise järjekorras):

- I / Kuusberg, Kaugver / Brontë, Vaher, Sand, Lacis /
- II / Lermontov, Puškin / Koidula, Turgenjev / Bornhöhe, London / Balzac, Hugo, Liiv / /
- III / Jessenin, Hemingway / Mälk, Dostojevski, Rolland / Galsworthy, Tolstoi, A., Tammsaare / Tuglas / /
- IV / Sirge, Tolstoi, L., / Tagore /
- V / Gorki, Vilde / Hint, Smuul /
- VI / Jakobson, A., Zolà, Šolohhov / Gross, Metsanurk / Simonov, Dumas, Luts /

Edasine analüüs viis juba nende põhjuste otsimisele, miks teatud kirjanikud osutusid omavahel lähedasteks. Saadud tulemuste põhjal võib lugejaile soovitada uut kirjandust nende lemmikirjanike järgi.

0,83 0,22 -0,90 0,21 0,64 0,46 0,70 0,09 -0,90 0,07 -0,90 -0,90 -0,90 0,01 -0,04 0,34 -0,01 -0,04 -0,90 -0,11 0,20 0,52 -0,21 0,21 0,20 0,10 -0,69 -0,39 0,18 0,24 0,25 0,18 -0,23 -0,42 0,44 0,15 0,16 0,27 0,27  
0,50 0,49 0,16 0,77 0,42 0,04 0,57 0,39 0,55 0,01 -0,01 0,51 0,62 -0,90 0,30 0,49 0,73 -0,90 -0,90 0,36 0,48 0,11 0,37 0,46 0,63 0,77 0,40 -0,43 0,03 0,07 0,13 -0,28 0,31 0,19 0,49 -0,15 0,29 0,23  
-0,90 0,73 0,62 0,06 0,66 0,56 -0,90 0,54 -0,90 0,71 0,06 -0,06 0,29 0,48 -0,05 0,26 -0,12 -0,17 0,48 -0,39 0,55 0,55 -0,27 0,05 0,49 -0,07 0,28 0,18 0,29 0,22 -0,14 -0,11 0,24 0,48 -0,26 0,02 0,00  
0,47 -0,90 0,57 0,01 0,55 0,37 0,72 0,38 -0,90 -0,90 0,29 0,60 0,42 0,42 0,66 0,43 -0,90 0,74 0,69 0,61 0,45 0,07 0,25 -0,01 0,10 0,73 0,28 0,36 -0,04 0,50 0,53 0,22 0,12 0,25 0,38 0,60  
0,42 0,38 0,37 0,37 0,01 0,35 0,64 0,33 0,29 0,48 0,47 -0,09 -0,90 0,57 0,56 0,52 -0,39 0,31 0,44 0,61 -0,29 -0,90 0,36 0,26 0,60 0,38 0,27 0,37 -0,03 0,27 0,44 0,25 0,25 0,11 0,20  
0,53 0,76 0,62 -0,90 -0,07 -0,90 0,47 0,24 0,24 0,75 0,41 0,22 0,40 0,17 0,12 0,66 0,57 0,24 0,64 0,08 0,35 0,98 0,39 -0,50 0,48 0,21 0,49 -0,36 0,64 0,32 0,38 -0,16 0,40 0,59  
-0,68 -0,68 0,49 0,67 -0,90 0,57 -0,90 0,54 -0,16 -0,90 -0,90 0,57 0,49 0,10 0,25 -0,34 -0,36 -0,01 0,47 -0,05 0,28 -0,21 0,01 -0,59 0,54 0,03 0,33 0,64 0,01 0,31 0,37 0,36 0,49  
0,41 -0,90 0,76 -0,90 0,55 0,52 0,18 0,60 0,50 -0,21 0,13 0,46 0,52 0,47 0,20 0,59 0,52 -0,39 -0,09 0,60 -0,24 0,26 0,42 0,23 0,48 0,04 0,28 0,33 0,09 0,14 -0,05 0,45  
0,26 0,44 0,23 -0,15 -0,90 0,57 0,37 0,16 -0,21 0,74 0,32 0,06 0,48 0,66 0,64 0,73 0,17 0,29 0,53 -0,03 0,44 0,48 0,14 0,24 -0,16 0,38 0,37 0,53 0,08 0,18 0,41  
0,24 0,64 -0,15 0,67 0,72 0,37 0,50 0,32 0,48 0,32 0,41 0,37 0,46 0,33 0,44 0,40 0,13 0,25 0,68 0,44 -0,13 0,49 0,31 0,32 0,56 0,37 0,20 0,44 0,35 0,13  
-0,16 0,19 0,36 -0,21 0,78 0,23 -0,23 0,63 0,13 0,06 0,79 0,52 0,63 0,57 -0,07 -0,43 0,07 -0,05 0,33 0,58 -0,11 0,04 -0,18 0,35 0,20 0,43 -0,06 -0,18 0,52  
0,18 0,14 0,14 -0,23 -0,24 0,33 0,09 -0,28 -0,33 0,33 -0,39 -0,42 0,50 0,29 0,10 0,56 0,19 0,40 0,12 0,11 0,49 -0,00 -0,13 -0,18 0,10 0,47 0,07 0,06  
0,13 0,34 0,57 -0,25 0,63 0,44 0,42 0,34 0,32 -0,68 0,28 0,56 0,12 -0,13 0,55 0,31 0,57 0,11 0,39 0,59 -0,11 0,57 0,17 0,65 0,07 0,33 0,54  
0,30 0,44 0,43 0,43 0,57 0,39 0,53 0,13 0,47 0,45 0,24 0,58 0,49 0,16 0,69 0,35 0,17 0,14 0,14 0,02 0,38 0,44 0,13 0,57 0,24 0,46  
0,29 0,28 0,07 0,69 0,39 0,53 -0,42 0,54 -0,90 0,45 0,45 -0,17 -0,21 0,27 0,62 0,46 0,14 -0,39 0,37 0,55 0,41 0,38 0,60 0,35 0,46  
0,06 0,28 0,25 0,57 0,44 0,65 0,68 0,88 0,52 -0,15 0,31 0,65 0,16 0,42 0,54 -0,07 0,57 -0,26 0,41 0,46 0,16 0,23 -0,16 0,47  
-0,31 0,02 0,67 -0,39 0,11 0,09 -0,47 0,22 0,66 0,67 0,36 0,25 0,25 0,31 0,03 -0,05 0,07 0,36 0,27 0,06 0,71 0,42 0,41  
0,72 0,22 0,43 0,54 0,36 0,22 0,22 0,34 0,39 -0,02 0,41 0,25 0,24 0,43 0,04 0,07 0,52 0,76 0,20 0,40 -0,02 0,45  
0,45 0,56 0,70 0,43 0,60 0,32 0,48 -0,22 0,23 0,44 0,54 0,35 0,56 0,22 0,56 0,81 0,31 0,50 0,61 0,25 0,18  
0,39 0,50 0,20 0,53 0,47 -0,20 0,64 0,21 0,42 0,20 0,33 0,28 0,05 0,41 0,09 0,55 0,35 0,39 0,34 0,46  
0,38 -0,01 0,54 0,13 -0,55 0,20 -0,32 0,48 0,52 0,28 0,43 0,55 0,59 0,22 0,48 0,18 0,32 0,41 0,32  
0,61 0,69 0,59 0,18 0,46 0,47 0,47 0,47 0,42 0,50 0,46 0,42 0,43 0,48 0,20 0,32 0,22 0,54  
0,35 0,25 0,13 -0,01 0,50 0,29 0,59 0,57 0,13 0,34 -0,13 0,32 0,52 0,14 0,20 0,05 0,58  
0,25 -0,14 -0,25 0,24 0,27 0,04 0,50 0,17 0,45 0,20 0,45 0,35 0,95 0,14 0,04 0,30  
0,01 -0,39 0,63 0,21 0,33 0,34 0,31 0,32 -0,04 0,42 0,20 0,37 0,08 0,16 0,47  
0,55 0,15 0,38 0,20 -0,17 0,27 0,02 0,15 0,41 0,23 0,20 0,20 0,25 0,48  
-0,11 0,48 0,29 0,02 0,38 0,14 0,45 0,05 0,32 0,05 0,64 0,29 0,52  
0,11 -0,12 0,38 0,12 0,47 -0,19 -0,01 0,44 0,32 -0,20 0,29 0,20  
0,26 -0,04 0,09 0,09 0,39 0,36 0,11 0,22 0,47 0,10 0,32  
0,37 0,28 0,29 0,43 0,58 0,53 0,50 0,26 0,50 0,50  
0,24 0,37 0,13 0,25 0,31 0,04 0,19 0,20 0,40  
0,52 0,41 0,39 0,26 0,37 0,53 0,30 0,37  
0,07 0,49 0,19 0,18 0,29 0,29 0,32  
0,43 0,37 0,26 0,54 0,50 0,32  
0,27 0,37 0,25 0,35 0,47  
0,38 0,31 0,31 0,53  
0,35 0,41 0,51  
0,47 0,42  
0,45

Tabel 2





T a b e l 3

	I	IV	VII	XIII	XIV	XVIII
I		0,3041	0,0413	0,2599	0,0232	0,0013
IV	0,3041		0,1710	0,2370	0,1113	0,3503
VII	0,0413	0,1710		0,3117	0,2079	0,2767
XIII	0,2599	0,2370	0,3117		0,1501	0,2899
XIV	0,0232	0,1113	0,2079	0,1501		0,3194
XVIII	0,0131	0,35036	0,2767	0,2899	0,3194	

KASUTATUD KIRJANDUS:

1. Lance, G.N., and Williams, W.T. (1966 ),  
A general theory of classificatory sorting strategies I.  
The Computer Journal, Vol. 9, p. 373.
2. Lance, G.N., Williams, W.T. (1967 ),  
A general theory of classificatory sorting strategies II.  
The Computer Journal, Vol. 10, p. 241.
3. Frey, T., Vöhandu, L.,  
Uus meetod klassifikatsioonihikute püstitamiseks. ENSV TA Toimetised.  
XV köide, Bioloogiline seeria 1966.
4. Vöhandu, L.,  
Kauguse mõiste rakendusi. Matemaatika ja kaasaeg II. Tartu, 1964.
5. Ball, H., What about the details?  
AFIPS. Conference proceedings.  
Vol. 27, part. 1. 1965.
6. Bonner, R., On some clustering techniques.  
IBM Journal of. Res. and Devpt., Vol. 8. 1.
7. Sheperd, M., and Willmott, A.,  
Cluster analysis on the Atlas computer.  
The computer Journal, Vol. 2.1.
8. King, B. Step-wise clustering procedures.  
Journal of American Statistical Association,  
1967, p. 86 - 101.
9. Goodman, L., and Kruskal, W.,  
Measures of association for cross-classification II,  
Journal American Statistical Association,  
Vol. 54, p. 123.

10. Sebestyen , G.S.,

Pattern Recognition by an Adaptive  
Process of Sample Set Construction.  
IRE Trans. on Info.Theory, Vol. 1 T - 8. 9.

11. Needham, R.M.'

The Theory of Clumps, II.  
Report M.L. 139, Cambridge Language  
Research Unit, Cambridge 1961.

12. Sokal, R.R. and Michner, C. D.,

A Quantitative Approach to a Problem  
in Classification.  
Evolution , Vol. 11. 6.

13. Hyvarinen, L.,

Classificatoin of Qualitative Data .  
British Info. Theory J. 1962.

## Резюме

В первой главе настоящей дипломной работы дан обзор методов классификаций. Эти методы можно разделить на 2 части:

I индуктивные

II дедуктивные "

Особое внимание уделено индуктивным методам, так как важнейшей чертой индуктивных методов с точки зрения обработки первичных данных является небольшая их трудоемкость по сравнению с дедуктивными методами.

Во второй главе дано описание метода Выханду, дана программа метода и приведен образец. Этот метод уменьшает количество вычислений для классификаций, так как с помощью его находятся кратчайшие расстояния между объектами.

В третьей главе дано описание метода классификаций Б. Кинга, дана программа и приведен образец.

S I S U K O R D:

	lk.
I Ülevaade rühmitamismeetoditest .....	1
II Vöhandu meetod.	
1. Meetodi kirjeldus .....	8
2. Programm .....	18
3. Näide .....	20
III Järk-järguline rühmitamine.	
1. Meetodi kirjeldus .....	21
2. Programm .....	25
3. Näide .....	26
Kasutatud kirjandus .....	29

2. vi 1969. a. *A. Vento*