

EMPÜ Matemaatika Instituut

E. ARUVEE, U. ENGSTRAND, U. OLSSON

Matemaatiline statistika

Põhimõisted

Bioloogilistele erialadele

EPMÜ Matemaatika Instituut

E. ARUVEE, U. ENGSTRAND, U. OLSSON

Matemaatiline statistika

Põhimõisted

Bioloogilistele erialadele

TARTU 2000

Matemaatiline statistika

Põhimõisted

Bioloogilistele erialadele

Toimetaja N. Veske

**Käsikirja ettevalmistamist toetas Rootsi Instituut
(grant 2080/1999 (380/98))**

© E. Aruvee, U. Engstrand, U. Olsson

ISBN

Eessõna

Koostöös Rootsi Põllumajandusülikooli kolleegidega Ulf Olssoniga ja Ulla Engstrandiga ning Rootsi Instituudi grandi toetusel valmis käesolev õpik. Seda tingis vajadus hoogustada matemaatilise statistika õpetamist Eesti Põllumajandusülikoolis. Käesoleva materjali valikul on tuginetud Rootsi Põllumajandusülikooli loengute materjalidele ja pikaajalistele kogemustele matemaatilise statistika õpetamisel. Arvutite laialdase kasutamisega koguneb mitmesuguseid andmestikke kiiresti, kuid sageli ei osata nednega midagi peale hakata. Seepärast on hariduse vajalikuks osaks oskus töötada arvandmestikuga, mida võimaldavad matemaatilise statistika meetodid.

Raamatus käsitletakse matemaatilise statistika põhimõisteid. Näidatakse, kuidas leida statistikute väärtusi käsitsiarvutamisel ja programmipakette kasutades. Teksti on illustreeritud statistikapakettide Minitab ja SAS väljatrükkidega. Minitabi kasutamisel võib tema lihtsus, kuid SAS-i puhul professionaalsus. Selle raamatu loogilise jätkuna ilmub peatsest raamat "Andmeanalüüs" mis koos käesoleva raamatuga moodustavad põllumajandusülikoolis õpetatava matemaatilise statistika kursuse.

Täna kolleeg Jüri Vardjat käsikirja läbilugemise ja tehtud kasulike märkuste eest. Raamatu eestikeelse käsikirja valmimise eest kuulub eriline tänu toimetaja Nora Veskele, kelle tähelepanelik töö oli raamatu valmimisel hindamatuks abiks.

Tartus, juuni 2000. a

Eve Aruvee

Peatükk 1

Statistiline vaatlus

1.1 Statistika ja bioloogia

Füüsika põhjal näib elu väga lihtne. Me formuleerime füüsikalise seaduse, nagu näiteks $E = mC^2$, ning seejuures võime kindlad olla, et antud seadus kehtib kõikjal; vähemalt järgmise suure teadusliku avastuseni. Füüsika on laialdase ulatusega deterministlik teadus. See tähendab, et paljusid füüsikalisi seadusi võime väljendada valemiga

$$y = f(x),$$

kus y on tundmatu suurus, mida soovime leida, f on mingi funktsioon ja x on funktsiooni argument.

Loodusseadused bioloogias, kaasa arvatud põllumajanduslikes teadustes, ei ole nii lihtsad. Sageli toob bioloogiline nähtus esile muutuse, senitundmatud seadused, mida soovime hinnata. Kui käsitleme kahte ala ühesuguse meetodiga, võime saada erinevad tulemused. Kahel ühevanusel konnal võivad olla erinevad kaalud. Kaks lehma, kes tarvitavad sama tüüpi võrdse koguse sööta, võivad anda erineva hulga piima. Järelikult: *varieeruvus* (muutlikkus) on bioloogilise andmestiku tüüpiline tunnus.

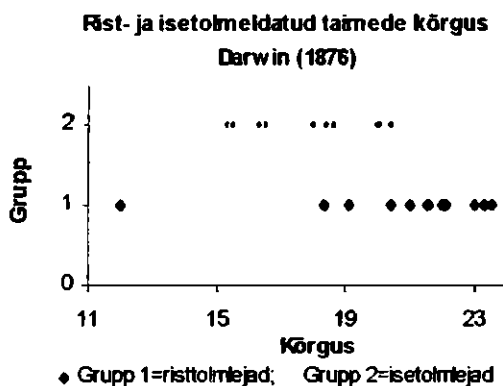
Varieeruvus, mida me ei oska selgitada, põhjustab probleeme, kui püüame koostada järeldusi bioloogilise andmestiku kohta. Üheks meetodiks bioloogilise varieeruvuse käsitlemisel on vaadelda seda juhuslikkusena. Seega paljud loodusseadused bioloogias on tõenäosuslikud. See tähendab, et me usaldame tõenäosuslikke väiteid.

Näiteks mingi bioloogilise nähtuse mudeli võime kirjutada kujul

$$y = f(x) + e,$$

kus y on mingi muutuja uuritav väärtus, f on mingi funktsioon, mis sümboliseerib oodatavat või keskmist muutuja y väärtust mingis üldkogumis, x on muutuja, mis mõjutab y -it ja e on mudeli viga. Mudeli vea ehk *jäägi* tõttu on sellist tüüpi mudelid tõenäosuslikud. Hiljem näeme, et statistilisi meetodeid ja mudeleid saab vaadelda selle üldise valemi erijuhuna.

Näide. Aastal 1876 ilmus Charles Darwinilt raamat "Taimeriigi rist- ja isetolmlemise mõjud" Darwin püüdis selles raamatus näidata, et taimed, mida on paljundatud risttolmeldamise teel, on elujõulisemad kui taimed, mida on paljundatud isetolmeldamise teel. Ta tegi katse, kus ühe liigi 15 taime kasvatati ühesugustes tingimustes. Mõne aja pärast mõõtis ta taimede kõrgused. Tulemused võib graafiliselt kujutada järgmiselt:



Graafikult näeme, et grupi 1 taimed on keskmiselt pikemad kui taimed, mis kuuluvad gruppi 2, aga tulemus ei ole päris tõepärane. Siin on osaline kattumine gruppide vahel ja grupis 1 oli ka väga väikesi taimi. On raske hinnata, kas Darwin'il oli õigus, lähtudes ainult graafikust. Küsimus seisneb: missugusele üldisele järeldusele võime jõuda selle andmestiku põhjal?

Üheks võimaluseks jõuda sellist tüüpi andmestiku põhjal teaduslikule järeldusele on formuleerida statistiline mudel. Darwin'i juhul võib mudel olla midagi taolist:

$$\text{Taimede pikkus} = \text{(kõikide taimede keskmine pikkus)} + \text{(muutus, kui taimed on risttolmeldatud)} + \text{(juhuslik variatsioon)}$$

See on tõenäosuslik mudel, mis on analoogiline eelpool esitatule $y = f(x) + e$. Enamikel juhtudel püstitame väite mudeli süstemaatilise osa $f(x)$ kohta. Selle näite korral soovime leida vastust küsimusele: "Kas risttolmeldatud taimed on keskmiselt teistest pikemad"?

1.2 Üldkogumid ja valimid

Teaduslikud järeldused peavad olema mingis mõttes üldised. Ühe katse tulemusi peab olema võimalik seostada mingi üldise teooriaga. Katset või uuringut planeerides peame määratlema uurimisobjekti, mille kohta soovime järeldusi teha.

Statistikas nimetatakse uurimisobjekti üldkogumiks, kuid bioloogilistes uurimisvaldkondades kasutatakse üldkogumi sünonüümina ka populatsiooni mõistet. Soovime formuleerida isendite populatsiooni kohta üldist teooriat. Darwin'i näites tahame saada järeldust ainult ühe liigiga piirduva taimede populatsiooni kohta. Üldkogum võib eksisteerida mingis reaalses tähenduses, näiteks "Kõik Eestis elavad piimalehmad seisuga 1. jaanuar 1999"; "Eesti üliõpilaste hulk 1999/2000. õppeaastal" Teisel juhul on ta kujutletav. Näiteks soovis Darwin arvatavasti teha järeldusi taimede kohta üldse, mitte ainult antud liigi isendite kohta. On keeruline koostada head üldkogumi definitsiooni, aga teeme proovi.

Definitsioon 1 *Üldkogum on mingit kindlat liiki objektide hulk.*

Katsetes kasutame harva kogu üldkogumit. Üldiselt teeme mõõtmisi üldkogumist võetud valimi elementide kohta. Ning kasutame seda järelduste tegemiseks üldkogumi kohta.

Definitsioon 2 *Valim on üldkogumi alamhulk.*


Igas katses peab olema mõningane sarnasus valimi ja üldkogumi vahel. Valim peab *esindama üldkogumit (olema representatiivne)*. Kuidas me selle saavutame?

Statistiline vastus on: valim tuleb moodustada juhusliku valiku teel, üldkogumi igal elemendil peab olema ühesugune võimalus sattuda valimisse. Selle eelis on, et uurija ei saa luua valimit süstemaatilisel teel, mis üldkogumist oluliselt erineks. Sageli teostatakse juhuslik valik juhuslike arvude generaatori või tabeli abil. Niisiis, juhusliku valiku tõttu võime kasutada

käsitlemise meetodeid, milles valim on moodustatud juhuslikult. Seega valimi all mõistame juhuslikku valikuga moodustatud valimit mingist üldkogumist.

1.3 Statistiline otsustus

Suur osa sellest kursusest on pühendatud üldiste järelduste tegemise probleemidele, mis põhinevad andmestiku lõplikel valimitel. Näiteks soovime järeldust teha mingi üldkogumi keskvaärtuse kohta. Moodustame üldkogumist valimi ja arvutame tema keskvaärtuse. Tulemust kasutame järelduste tegemiseks üldkogumi keskvaärtuse kohta mingi kindla täpsusega. Meetodid, mida kasutame, põhinevad tõenäosusteoorial. Antud olukorda saab kujutada järgnevalt:



Kursus on üldjoontes jagatud kolmeks osaks.

Esimeses osas uurime kogutud andmete kirjeldavaid meetodeid. Andmete paremaks mõistmiseks on otstarbekas arvutada andmete numbrilisi statistikuks või esitada andmed diagrammil.

Teine osa on rohkem teoreetiline. See on tõenäosusest ja statistilistest jaotustest. Kui kursuse esimene osa aitab meil kirjeldada valimit, siis teine esitab üldkogumi kirjeldamise meetodeid.

Kõige mahukamas, kursuse kolmandas osas (ilmub käesoleva raamatu teises osas), käsitleme meetodeid järelduste tegemiseks valimi alusel üldkogumi kohta ja neid nimetatakse *statistilisteks otsustusteks*.

Peatükk 2

Kirjeldava statistika põhimõisted

2.1 Andmete kogumine

2.1.1 Sissejuhatus

Bioloogilise andmestiku kogumise tulemuseks võib olla suur hulk andmeid. Nende interpreteerimiseks on vaja leida mingi sobiv mudel, aga sageli on seda raske valida, kuna võimalusi on palju. Kirjeldava statistika eesmärk on korrastada andmed mitmel viisil selliselt, et tähtsamad suunad oleksid selgitatud. See ei ole formaalne probleem; sageli on see “detektiivitöö”, kus me pöörame ja painutame andmeid erineval viisil seni, kuni märkame mudelit ja seni, kuni oleme võimelised selgitama mudelit teistele.

Kirjeldav statistika sisaldab endas ka edastamist. Uuriija, kes on töötanud eksperimendiga mingi aja, võib sageli märgata andmestikus seda, mida teine ei oska näha. Illustreerides leidu graafikul või tabelis, võime veenda teisi, et järeldused on õiged. Niisiis, kirjeldav statistika on andmeanalüüsi tähtis osa nii uurijale kui ka uuringu tulemuse kasutajale.

2.1.2 Tunnused

Tunnus on mingi näitaja, mida võime kirjeldada või mõõta andmestikku kuuluval objektil. Näiteks kui objektideks on inimesed, võime igat neist kirjeldada vanuse, soo, kaalu, õdede - vendade arvu, aastase sissetuleku, juuste värvuse, matemaatika hinde või elukutse põhjal. Sel juhul on tunnused:

vanus, sugu, kaal, õdede - vendade arv, aastane sissetulek, juuste värvus, matemaatika hinne või elukutse.

2.1.3 Kvalitatiivsed ja kvantitatiivsed tunnused

Kirjeldava statistika meetodeid (samuti ka teisi statistika meetodeid) kasutatakse sõltuvalt sellest, kas tunnus on kvalitatiivne või kvantitatiivne. Kvantitatiivsete (või arvuliste) tunnuste väärtused on reaalarvud. Kvantitatiivse tunnuse näiteks on vanus, kaal ja aastane toodang.

Kvantitatiivne tunnus võib olla pidev või diskreetne. Pidev tunnus peab omama mingit väärtust mingist vahemikust. Näiteks inimeste kaal võib olla mõõdetud (vähemalt põhimõtteliselt) määramatu täpsusega. Järelikult - kaal ja vanus on pideva kvantitatiivse tunnuse näited.

Diskreetne tunnus saab omandada vaid kindlaid erinevaid väärtusi, tunnuse väärtused määratakse loendamise teel. Näiteks õdede-vendade arvuks saavad olla vaid väärtused 0, 1, 2, 3, ..., st nad on vaid täisarvud.

Kvalitatiivsed tunnused e mittearvulised tunnused jaotatakse omakorda järjestatud -, binaarsed - ja nominaaltunnusteks. Kõige levinum on järjestus- (järjestatud) tunnus. Seda iseloomustab väärtuste hulga sisuline järjestatus. Näiteks matemaatika hinne, hinnang etendusele. Binaarse tunnuse näiteks on sugu. Sool võib olla vaid kaks väärtust (enamike liikide juures): naine ja mees. Juuste värvus on nominaaltunnuse näide. Selle korral ei leidu üht ühist sisuliselt põhjendatud skaalat, mille alusel iga kaht väärtust saaks võrrelda. Sageli kasutatakse andmetöötlusprotsessis mingeid koode "soo" või "juuste värvuse" jaoks. Näiteks võime kasutada koodina arvu 0 väärtuse "naine" ja arvu 1 väärtuse "mees" jaoks, juuste värvuse koodid võivad olla järgnevad: 1 - blondid, 2 - pruunijuukselised, 3 - mustajuukselised jne. Nominaaltunnuse korral võime ka kasutada koode, kuid ei tohi neid töödelda arvulistena. Kodeerimine ei tohi muuta tunnuste fundamentaalset olemust: sugu ja juuste värvus on vaid kvalitatiivsed tunnused ja neid peab analüüsima ka selliselt.

2.1.4 Skaala tüübid

Erinevate tunnuste mõõtmiseks võib kasutada erinevaid skaalasid.

Skaala tüüp	Väärtused on järjestatud	Väärtused on võrdvahemikulised	Skaalal on 0-punkt
Nominaalne			
Ordinaalne	X		
Intervall	X	X	
Proportsionaalne	X	X	X

Nominaalne skaala ainult nimetab väärtusi, mitte ei järjestane neid. Näiteks sugu.

Ordinaalne skaala järjestab kategooriaid. Näiteks hinne matemaatikas.

Intervallskaala on võrdvahemikuline, kuid tal ei ole alguspunkti. Näiteks temperatuur Celsiuse järgi.

Proportsionaalsel skaalal on 0-punkt, kuid tunnusel see omadus puudub. Näiteks kaal.

Meetodid, mida kasutatakse statistilise andmestiku (võivad olla esitatud tabelite või graafikute kujul) jaoks, sõltuvad sellest, missugust tüüpi tunnustega me töötame ja missugust tüüpi skaalas on tehtud tunnuse mõõtmised.

2.2 Numbriliste andmete ülevaade

2.2.1 Aritmeetiline keskmine

Definitsioon 3 Valimis vaatluste (aritmeetiline) keskmine arvutatakse

$$\bar{x} = \frac{\sum x_i}{n}$$

Selles valemis tuleb kõigi vaatluste väärtuste summa jagada vaatluste arvuga.

Näide 1.

Järgnev andmestik on rottide, kelle vanus on 1 päev ja rohkem, hapniku hingamise hulk (VO_2 , ml/t)¹

1,57 1,60 1,81 1,60 1,88 1,79 1,75 1,85
1,92 1,68 1,75 1,73 1,72 1,68 1,76 1,78

¹Andmed on võetud: Claes Lilja A note on the metabolic rate in the young rat. Swedish J. agric. Res. 17:103-104, 1987

Kõikide vaatluste väärtuste summa

$$\sum x_i = 1,57 + 1,60 + \quad + 1,76 + 1,78 = 27,87$$

Valimi, 16 roti, keskmine on $\bar{x} = \frac{\sum x_i}{n} = \frac{27,87}{16} = 1,741875$.

Keskmit võib ümardada vajaliku täpsuseni. Tulemuse võib esitada $\bar{x} = 1,74$ või $\bar{x} = 1,742$.

Märkus: tulemust ei tohi ümardada, kui soovime seda kasutada edaspidistes arvutustes. Keskmit on mõttekas arvutada ainult numbrilistele tunnustele (vähemalt) intervallskaalas. Mõnikord arvutatakse ka aritmeetilist keskmit ordinaalses skaalas mõõdetud andmete korral, mis on teataval määral sobimatu. Näiteks õpilaste hinded koolis.

2.2.2 Mediaan

Valimi mediaani tähistatakse sageli Me või \tilde{x} . Mediaan on väärtus, millest valimis pooled vaatlused on väiksemad ja pooled on suuremad. Mediaani leidmiseks on vaja moodustada valimi elementidest järjestatud jada, mida nimetatakse variatsioonreaks. Seejärel leiame mediaani asukoha.

Definitsioon 4 Mediaan on variatsioonrea vaatlus positsiooniga $\frac{n+1}{2}$. Kui positsioon ei ole täisarv, siis mediaan on kahe keskmise vaatluse väärtuste poolsumma.

Näite 1 andmetest on moodustatud variatsioonrida, st valimi elemendid on sorteeritud kasvavasse järjekorda; iga arvu positsioon on antud tema all.

1,57	1,60	1,60	1,68	1,68	1,72	1,73	1,75
1	2	3	4	5	6	7	8
1,75	1,76	1,78	1,79	1,81	1,85	1,88	1,92
9	10	11	12	13	14	15	16

Vaatlusandmeid on $n=16$ (paarisarv), mediaani asukoht on $\frac{16+1}{2} = 8,5$. Mediaan on kahe keskmise vaatluse väärtuse keskmine, st 8. ja 9.

variatsioonrea elemendi väärtuste keskmine. Need vaatlused on 1,75 ja 1,75. Seega $Me = \tilde{x} = 1,75$. Mediaani võib leida numbriliste tunnuste (intervalli või proportsionaalse skaala) korral ning ordinaalses skaalas tunnustele.

2.2.3 Kohendatud keskmine (Trimmed mean)

Aritmeetiline keskmine on kõikide vaatlusväärtuste keskmine. Ta on tundlik ekstreemsete vaatlusväärtuste suhtes. Näiteks aritmeetiline keskmine arvudest 1, 2, 3, 4 ja 5 on 3. Arimeetiline keskmine arvudest 1, 2, 3, 4 ja 50 on

12. Järelikult võib aritmeetiline keskmine ühe vaatluse tõttu palju muutuda. Mediaan ei ole tundlik mõnede ekstreemsete vaatlusväärtuste suhtes: mediaan on 3 mõlema eelpool vaadeldud näite korral.

Teiste sõnadega võib öelda, et keskmine \bar{x} põhineb kõigil n vaatlusel, aga mediaan \tilde{x} baseerub peamiselt kahel vaatlusel. Kompromissina kasutatakse järgmist protseduuri: näiteks kustutatakse 5% suurimatest ja 5% väiksematest vaatlusväärtustest ning arvutatakse aritmeetiline keskmine ülejäänud vaatluste väärtustest.

Vaatleme näites 1 esitatud andmestikku, kustutame variatsioonreast suurima (1,92) ja vähima (1,57) elemendi. Aritmeetiline keskmine ülejäänud elementidest on 1,7414.

Märkus. Kuigi kohendatud keskmine võib intuiitiivselt meeldida, eriti kui andmestik sisaldab erilisi väärtusi (erindeid), ei kasutata teda statistiliste järelduste tegemisel kuigi sageli.

2.2.4 Dispersioon

Dispersioon on valimis mõõdetav kui vaatlusväärtuste hajuvus keskväärtuse suhtes. Kui vaatlused on kõik lähedaste väärtustega, siis on dispersioon väike, aga kui vaatluste väärtused on väga erinevad, siis on dispersioon suur.

Definitsioon 5 Valimi dispersioon on defineeritud valemiga

$$s^2 = \frac{\sum (x_i - \bar{x})^2}{n - 1}$$

See valem on käsitsi arvutamisel veidi tülikas, kuna on vaja lahutada iga vaatluse väärtusest keskväärtus \bar{x} ning seejärel tulemus ruutu tõsta. Valem, mis annab sama tulemuse, aga mida on käsitsi kergem kasutada, on järgmine:

$$s^2 = \frac{\sum x_i^2 - \frac{(\sum x_i)^2}{n}}{n - 1}$$

Näite 1 andmete põhjal võib dispersiooni arvutada järgmiselt.

Kõigi vaatlusväärtuste summa on

$$\sum x_i = 1,57 + 1,60 + \quad + 1,76 + 1,78 = 27,87$$

Kõigi vaatlusväärtuste ruutude summa on

$$\sum \hat{x}_i^2 = 1,57^2 + 1,60^2 + \quad + 1,76^2 + 1,78^2 = 2,4649 + 2,5600 + \quad + 3,0976 + 3,1684 = 48,6955.$$

Meenutame, et valimimaht $n = 16$, dispersioon on

$$s^2 = \frac{\sum x_i^2 - \frac{(\sum x_i)^2}{n}}{n - 1} = \frac{48,6955 - \frac{27,87^2}{16}}{15} = 0,009963.$$

Tulemuse võime ümardada $s^2 = 0,01$.

Märkus. Taskuarvutid ja tabelarvutusprogrammid nagu Excel omavad dispersiooni jaoks kahte dispersiooni standardfunktsiooni, mis sageli põhjustab veidi segadust. Näiteks Excelis on üks funktsioon VAR(), mis on paketi abitekstis kirjeldatud järgmiselt: “Arvutab dispersiooni, mis põhineb valimil“, ja teine funktsioon VARP() on kirjeldatud järgmiselt: “Arvutab dispersiooni, mis põhineb üldkogumil“ Nendevaheline erinevus seisneb selles, et üldkogumi valem kasutab n -i murru nimetajas ($n - 1$) asemel. Käesolevas tekstis eeldame, et dispersiooni arvutamiseks kasutame eelpool toodud valimi valemit.

2.2.5 Standardhälve

Definitsioon 6 Valimi standardhälve on ruutjuur valimi dispersioonist:

$$s = \sqrt{s^2}$$

Näite 1 andmestiku standardhälve on
 $s = \sqrt{s^2} = \sqrt{0,009963} = 0,099814$. Tulemuse võime ümardadada
 $s = 0,1$.

Märkus. Sageli esitatav küsimus on: “Miks vajame mõlemat - dispersiooni ja standardhälvet”? Vastus on: standardhälvet on lihtsam interpreteerida, kuna ta on mõõdetud samades ühikutes kui andmed. Kui andmed on cm-tes, siis standardhälve on ka cm-tes. Järelikult, kui on vaja kirjeldada muutust andmehulgas, võime kasutada pigem s -i kui s^2 . Kuna aga paljud statistilised arvutused põhinevad dispersioonil, tuleb sagedamini kasutada s^2 kui s -i.

2.2.6 Haare

Haare on defineeritud kui suurima ja vähima vaatlusväärtuse erinevus, ta on andmestikus hõlpsasti arvutatav hajuvuskarakteristik.

Näite 1 andmetes on suurim vaatluse väärtus 1,92 ja vähim väärtus on 1,57. Järelikult haare on $1,92 - 1,57 = 0,35$.

Märkus. Andmete korral, kui valimi suurus ei ole nii suur, kasutatakse haaret, et anda esialgne hinnang standardhälbele. Sageli on see järgmine $s \approx \frac{\text{haare}}{4}$. Seda lihtsat “rusikareeglit“ võib kasutada standarhälbe arvutuste kontrollimiseks. Selle reegli kohaselt näite 1 andmete jaoks on $s \approx \frac{0,35}{4} = 0,0875$, mis ei erine väga palju eelpool arvutatud õigest väärtusest 0,1.

2.2.7 Variatsioonikordaja (CV)

Mõnel juhul vajame varieeruvusele andmestikus väljundit mingis ühikus, mis ei tohi sõltuda kasutatavate mõõtmiste skaalast. Sel juhul arvutame variatsioonikordaja, mis on tunnuse standardhälbe ja keskväärtuse suhe;

$$CV = \frac{s}{\bar{x}}$$

Näite 1 andmete korral $CV = \frac{0,099814}{1,7419} = 0,057303$. CV väljendatakse sageli protsendina. Nende andmete korral on standardhälve umbes 5,7% keskväärtusest, st $CV = 5,7\%$.

2.2.8 Keskväärtuse standardviga (SEM)

Keskväärtuse standardviga (SEM) ei ole andmestikus varieeruvuse hulga mõõt. Pigem on ta üldkogumi keskväärtuse \bar{x} kui hinnangu täpsuse mõõt. Kui palju eeldame keskväärtuse \bar{x} varieerumist?

Keskväärtuse standardviga sõltub:

- 1) dispersioonist,
- 2) valimi suurusest,
- 3) valimi moodustamise viisist.

Juhusliku valimi keskväärtuse standardvea võime arvutada järgmiselt

$$SEM = s_{\bar{x}} = \frac{s}{\sqrt{n}}$$

Näite 1 andmete korral $SEM = s_{\bar{x}} = \frac{s}{\sqrt{n}} = \frac{0,099814}{\sqrt{16}} = 0,02495 \approx 0,025$.

2.2.9 Kvartiilid ja protsentiilid

Nagu mediaan jagab andmed kahte ossa, võime defineerida esimest kvartiili q_1 kui väärtust, millest 25% valimi vaatlusi on sattunud ettepoole. Mediaan on teine kvartiil. Kolmas kvartiil q_3 on väärtus, millest 75% valimi vaatlusi on sattunud ettepoole. Ka teisi protsenteile võime kasutada; võime rääkida 20-st protsentiilist (või 95-st protsentiilist) kui väärtusest, millest 20% (95%) valimi vaatlusi on sattunud ettepoole.

Interpoleerimise juures on sageli vaja arvutada valimist kvartiile ja protsenteile.

Näite 1 andmete korral q_3 asukoht on $\frac{3(n+1)}{4} = \frac{51}{4} = 12,75$, st kolmanda kvartiili asukoht on vaatlus numbriga 12,75. Vaatlusel numbriga 12 on väärtus 1,79 ja vaatlusel numbriga 13 on väärtus 1,81. Interpoleerime nende kahe vaatluse vahel ja saame kolmanda kvartiili järgmiselt:
 $1,79 + 0,75(1,81 - 1,79) = 1,805$.

Esimese kvartiili q_1 asukoht arvutatakse $\frac{n+1}{4} = \frac{17}{4} = 4,25$. Vaatlusel numbriga 4 on väärtus 1,68 ja vaatlusel numbriga 5 on samuti väärtus 1,68, seega $q_1 = 1,68$.

2.2.10 Kvartiilide vahe

Kvartiilide vahe on andmestikus hajuvuskarakteristik. See on alternatiivne standardhälbele. Kvartiilide vahe arvutatakse

$$v = q_3 - q_1.$$

Näite 1 andmete korral $v = 1,805 - 1,68 = 0,125$.

2.2.11 Arvuti programmpaketid kirjeldava statistika jaoks

Arvuti programmpaketid nagu Minitab ja SAS arvutavad eelnevas kirjeldatud suurusi. Näite 1 andmete korral annab Minitab järgmise väljatrüki:

Descriptive Statistics

Variable	N	Mean	Median	Tr Mean	StDev	SE Mean
HAPNIK	16	1.7419	1.7500	1.7414	0.0998	0.0250

Variable	Min	Max	Q1	Q3
HAPNIK	1.5700	1.9200	1.6800	1.8050

Märkus. TrMean on keskmine, kui andmestikust on 5% väiksemaid ja 5% suurimaid vaatlusi välja jäetud.

SAS paketi protseduur MEANS annab järgmise väljatrüki (kui kvartiilid või teised statistikud on vajalikud, siis sellised statistikud tuleb eraldi arvutatada).

Analysis Variable : HAPNIK

N	Mean	Std Dev	Minimum	Maximum
16	1.7418750	0.0998144	1.5700000	1.9200000

Võime kasutada SAS protseduuri UNIVARIATE, mis annab väljatrukis suurema hulga statistikute väärtusi:

Variable=HAPNIK

Univariate procedure

Moments			
N	16	Sum Wgts	16
Mean	1.741875	Sum	27.87
Std Dev	0.099814	Variance	0.009963
Skewness	-0.09452	Kurtosis	-0.4475
USS	48.6955	CSS	0.149444
CV	5.73086	Std Mean	0.024954
T-Mean=0	69.80455	Pr> T	0.0001
Num ^= 0	16	Num > 0	16
M(Sign)	8	Pr>= M	0.0001
Sgn Rank	68	Pr>= S	0.0001

Quantiles (Def=5)

100% Max	1.92	99%	1.92
75% Q3	1.8	95%	1.92
50% Med	1.75	90%	1.88
25% Q1	1.68	10%	1.6
0% Min	1.57	5%	1.57
		1%	1.57
Range	0.35		
Q3-Q1	0.12		
Mode	1.6		

Extremes

Lowest	Obs	Highest	Obs
1.57 (1)	1.79 (6)
1.6 (4)	1.81 (3)
1.6 (2)	1.85 (8)
1.68 (14)	1.88 (5)
1.68 (10)	1.92 (9)

Märkus. Selle väljatruki mõned lühendid vajavad selgitust. Skewness ja Kurtosis on jaotuse kuju mõõdud; USS (“Uncorrected sum of squares”) on $\sum x^2$; CSS (“corrected sum of squares”) on $\sum (x - \bar{x})^2$; CV on variatsioonikoefitsient; Std Mean on keskväärtuse standardviga. Med on mediaan ning Q1 ja Q3 on kvartiilid. Ülejäänud lühendid on kas arusaadavad või praegu mitteolulised.

2.3 Numbrilise andmestiku graafiline esitus

2.3.1 Tüvi-leht-diagramm

Tüvi-leht-diagramm on kiire ülevaade numbrilise andmestiku hulgast. Teda on sobiv kasutada, kui tunnuse väärtuste hulk pole väga suur. Illustreerime selle ideed näite 1 andmete põhjal. Tüvi-leht-diagrammi koostamiseks on esiteks vaja valida "tüve" suurus. Käesolevas näites kasutame "tüvena" täisosa ning esimest kümnendkohta. Kirjutame üksteise alla kasvavasse järjekorda kõikvõimalikud "tüved". Iga väärtuse ülejäänud kümnendkohad kirjutame kõrvale vertikaalsesse tulpa:

"Tüvi"	"Leht"		"Tüvi"	"Leht"
1,5	7	Teeme "ilusa" tabeli,	1,5	7
1,6	0088	võime igas "tüves"	1,6	0088
1,7	9553268	sorteerida vaatlused	1,7	2355689
1,8	185	suuruse järgi. Ühtlasi	1,8	158
1,9	2	kergendab see	1,9	2

kvartiilide arvutamist jne.

Tüvi-leht-diagrammid on kasutatavad, kui soovime saada kiiret ülevaadet numbrilisest andmestikust. Need annavad üheaegselt andmestikust tabeli ja graafiku.

2.3.2 Karpdiagramm

Näite 1 andmete põhjal karpdiagrammi koostamiseks on vaja eelnevalt arvutada järgmised statistikud:


esimene kvartiil $q_1 = 1,64$,

teine kvartiil q_2 , mis on ka mediaan $Me = q_2 = 1,75$,

kolmas kvartiil $q_3 = 1,805$,

kvartiilide vahe $v = q_3 - q_1 = 1,805 - 1,64 = 0,165$.

Karpdiagrammi kujutamiseks joonistame kõigepealt vertikaalse skaala. Horisontaalsed jooned tõmbame kvartiilide q_1 , $q_2=Me$ ja q_3 kohalt. Ühendame need jooned karbiks. Karbist väljapoole joonistame "vurrud", need on jooned, mis ühendavad karbiga vaatluse vähimat ja suurimat väärtust. Järgnev karpdiagramm on koostatud näite 1 andmetele, selle koostamiseks on kasutatud programmipaketti Minitab.



Märkus. Karpdiagrammi võib ka joonistada horisontaalselt.

Karpdiagrammi "vurrud" on pikendus vähima ja suurima vaatluseni, nad on piiratud seestpoolt alumise ja ülemise piiriga. Alumist ja ülemist piiri analüütilise andmestiku žargoonis kutsutakse "seesmiseks aiaks" Need on defineeritud järgmiselt:

alumine piir: $q_1 - 1,5v$,

ülemine piir: $q_3 + 1,5v$.

Vaatlused, mis on "seesmisest aiast" väljaspool, joonistatakse eraldi ja võivad tulla arvesse kui "leebed eemalasujad" Mõned programmid joonistavad diagrammile veel teisigi punkte. Vaatlusi, mis asuvad väljaspool, kutsutakse "väliseks aiaks", joonistatakse diagrammile mingi muu sümboliga ja neid vaadeldakse kui "ekstreemsed eemalasujad" Alumine ja ülemine "väline aed" defineeritakse vastavalt $q_1 - 3v$ ja $q_3 + 3v$. Karpdiagrammi vastav näide koos eemalasujatega on toodud edaspidi selles peatükis.

2.3.3 Sagedustabel

Sagedustabeliks nimetatakse tabelit, milles on ära näidatud tunnuse erinevad väärtused ja nende väärtuste esinemiste arv (sagedus) uuritavas andmestikus. Kui tunnusel on palju erinevaid väärtusi, on sobiv koostada andmestikust ülevaate saamiseks sagedustabel (jaotustabel), kus andmed on jaotatud klassideks, ja lugeda, mitu vaatlust satub vastavasse klassi. Mõned üldised juhised, mida vaja arvestada:

- Valida klassid selliselt, et vaatlused oleksid üheselt klassidesse jaotatud.
- Enamikel juhtudel on soovitatav kasutada 5-10 klassi.

- Praktikas sobivad klassipiirideks tihti nn ümmargused, näit nulli või viiega lõppevad arvud.
- Vältida avatud klasse.
- Kui võimalik, valida klassid võrdse laiusega.


Sagedustabel näite 1 andmete jaoks, kus andmed on jaotatud viieks võrdse laiusega klassiks, on järgmine:

Klassipiirid	Keskpunkt	Sagedus
[1,50 – 1,60)	1,55	1
[1,60 – 1,70)	1,65	4
[1,70 – 1,80)	1,75	7
[1,80 – 1,90)	1,85	3
[1,90 – 2,00)	1,95	1

2.3.4 Histogrammid

Histogramm ehk tulpdiaagramm on graafik, millel kujutatakse andmestiku sagedustabelit. Iga klass on esitatud tulbana. Tulba kõrgus on võrdeline sagedusega, st on võrdne vaatluste arvuga selles klassis. Märkusena olgu öeldud, et tulba kõrgus on võrdeline sagedusega ainult siis, kui klassid on võrdse laiusega.

Histogrammil peavad tulbad asuma kõrvuti, ei tohi jätta tühja ruumi kahe tulba vahele, näidates, et kõik väärtused antud vahemikus on võimalikud. (Mõned programmid teevad histogrammid sellest erinevalt, aga näiteks Excel ja Minitab joonistavad tulbad sel teel.) Eelnevate andmete põhjal on histogramm järgmine:



2.3.5 Histogrammid kui klassid ei ole võrdse laiusega

Eelpool soovitasime, et histogrammi tulba kõrgus peab olema võrdeline sagedusega. Püüame selgitada, miks see on nii ja kuidas joonistada histogrammi, kui klassid ei ole võrdsed.

Näide. Oletame, et soovime illustreerida 30 farmi pindala jaotusi järgmise tabeli järgi:

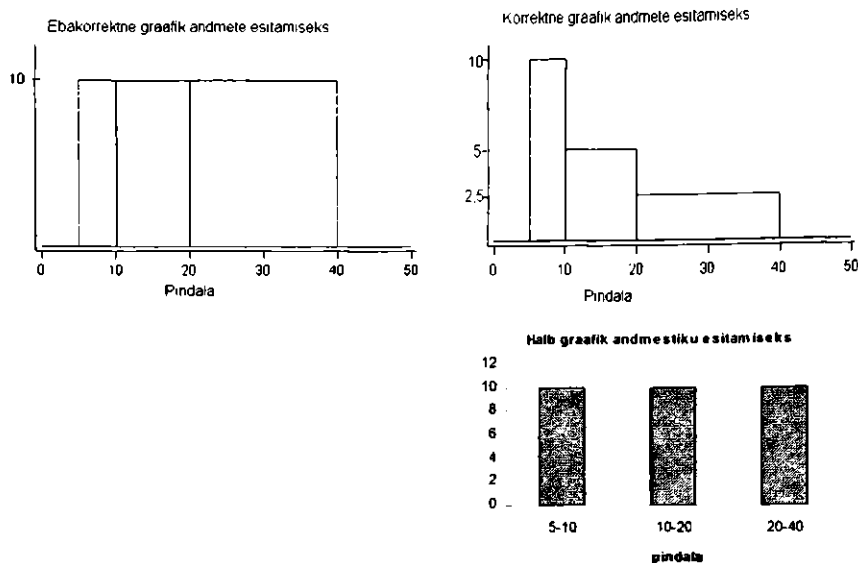
Pindala	Farmide arv
5 – 10 ha	10
10 – 20 ha	10
20 – 40 ha	10

Igas klassis on ühesugune arv farme, aga klassid pole pindalalt võrdsed. Kui jagame andmed võrdse laiuselise klassidesse, eeldame farmide võrdset jaotust kõigis klassides, saame:

Pindala	Farmide arv
5 – 10 ha	10,0
10 – 15 ha	5,0
15 – 20 ha	5,0
20 – 25 ha	2,5
25 – 30 ha	2,5
30 – 35 ha	2,5
35 – 40 ha	2,5

Järelikult, järgnev vasakpoolne graafik, mis on koostatud esimese tabeli põhjal, näitab jaotuse moonutatud pilti, aga graafik paremal pool on parem.

Seal on kõik tulbad võrdse pindalaga ning esile on toodud fakt, et farmide arvukus on võrdne kõikides klassides.




Parempoolne alumine graafik on pigem halb. Klassid on kujutatud võrdse laiusega, ehkki nendel laius ei ole võrdne.

2.3.6 Hajuvusdiagramm

Tüvi-leht-diagrammid, histogrammid ja karpdiagrammid iseloomustavad enamasti ainult ühte tunnust. Vahel on huvitav uurida mitme numbrilise tunnuse vahelisi seoseid. Kujutame graafikul ühe tunnuse väärtusi horisontaalsel teljel ja mõne teise tunnuse väärtusi vertikaalsel teljel, kus iga vaatlus tähendab punkti graafikul: moodustuvat graafikut nimetatakse hajuvusdiagrammiks ehk korrelatsiooniväljaks.

Näide. Järgneva graafiku andmed on võetud uurimusest², kus mõõdeti seemikute juurekasvu. Seemikuid väetati erinevate 2-(2,4-diklorofenoksi)-propioonhappe (Dichloroprop) annustega. Annused on graafikul logaritmitud. Graafikul näeme suurt hulka varieeruvust, aga näeme ka süstemaatilist mudelit: keskmine juure kasv väheneb annuse kasvades.

²Ulla Didon and Ulf Olsson (1997): A bioassay method for detection of Dichloroprop and MCPA in water. Swedish J. Agr. Res., 27: 121-128.

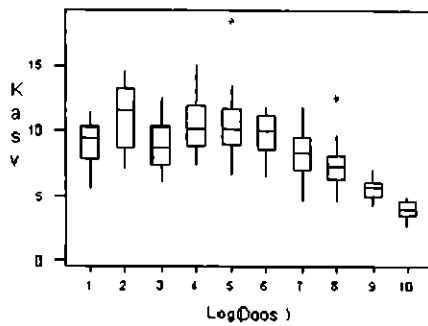


2.3.7 Varieeruvuse esitamine graafikul

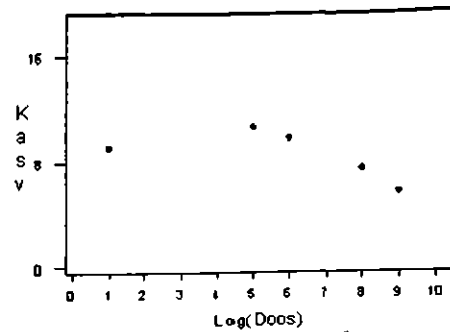
Mõnikord suure andmestiku korral võib vajalik informatsioon graafikul kaduma minna. Näiteks joonisel on liiga palju punkte ja mudel on raskesti nähtav. Sel juhul on kasulik mingil viisil summeerida vaatlused ja kujutada graafikul ainult summad. Mõned alternatiivid:

- kujutada graafikul ainult keskvaartusi,
- koostada karpdiagramm iga x-i väärtuse jaoks,
- joonistada iga x-i väärtuse juurde keskvaartus \pm standardhälve,
- joonistada iga x-i väärtuse juurde keskvaartus \pm keskvaartuse standardviga.


Järgnevatel graafikutel on esitatud sama andmestiku põhjal need neli alternatiivi. Segaduste vältimiseks on joonisel kindlasti vaja märkida mis-sugust alternatiivi kasutame. Meie näite korral kasutame vastavalt karpdiagrammi, ainult keskvaartust, $\text{Mean} \pm \text{SEM}$ ja $\text{Mean} \pm s$.




Karpdiagramm



Ainult keskmised



Mean ± SEM



Mean ± s

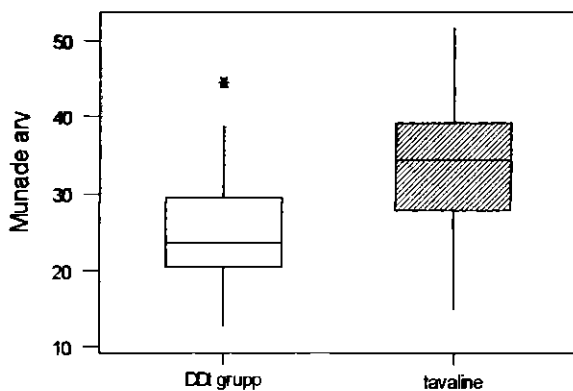
2.3.8 Teised bivariantseid graafikud

Mõnikord on kasulik kombineerida erinevaid diagrammide tüüpe. Üheks näiteks võiks olla erinevate gruppide karpdiagrammid (näiteks erinevate töötluste) esitamine ühel ja samal graafikul. Sellel on siis kvalitatiivne muutuja horisontaalteljel ja kvantitatiivne muutuja on vertikaalteljel.

Näide. Uuriti kahte gruppi puuviljakärbseid. Üks grupp valiti selline, mis on vastupidav DDT suhtes, teine grupp oli normaalne selekteerimata grupp. Vaatlustena fikseeriti iga emase poolt munetud keskmine munade arv päevas ning mõõtmisi teostati kahe nädala jooksul.

Grupp 1		Grupp 2	
12.8	27.3	35.4	22.6
21.6	22.4	27.4	40.4
14.8	27.5	19.3	34.4
23.1	20.3	41.8	30.4
34.6	38.7	20.3	14.9
19.7	26.4	37.6	51.8
22.6	23.7	36.9	33.8
29.6	26.1	37.3	37.9
16.4	29.5	28.2	29.5
20.3	38.6	23.4	42.4
29.3	44.4	33.7	36.6
14.9	23.2	29.2	47.4
	23.6	41.7	

Missugune on kahe grupi vahelise viljakuse erinevus? Vastuse küsimusele võime välja lugeda järgnevalt jooniselt:



Olgugi et kaks gruppi osaliselt katavad sama ala, näeme, et grupil 1 on madalam viljakus kui grupil 2. Hiljem vaatleme formaalseid viise, kuidas seda järeldust hinnata.

2.4 Kvalitatiivse andmestiku kokkuvõte

2.4.1 Sagedustabel

Lihtsaim võimalus ülevaate saamiseks diskreetsest andmestikust (numbrilise või ka nominaalse skaala andmestikust) on koostada sagedustabel. Selle paremaks illustreerimiseks kasutame näidet. Märkigi üles erinevat liiki puude arvukus Lansing Wood'i, Michigan³ metsas. Tulemus on esitatud tabelis, mis ongi sagedustabel:

Liik	Puude arv
Punane tamm	346
Valge tamm	448
Must tamm	135
Hikkoripuu	703
Vaher	514
Teised liigid	105
Kokku	2251

2.4.2 Risttabel

Risttabel on tabel, kus ühikud jaotatakse kasutatavate kahe (või rohkema) kriteeriumi järgi. Risttabelit kasutatakse tunnustevaheliste sõltuvuste leidmiseks.

Näide.

Uuriti, kas leidub sõltuvust norskamise ja südamehaiguste vahel⁴ Andmeid koguti 2484 patsiendilt, kellel oli mingi südamehaigus ning nendelt küsiti, kui suurel määral nad öösiti norskavad. Saadud andmestik on järgmine:

Kas on südamega probleem?	Norskavad harva/mitte kunagi	Norskavad sageli/alati	Kokku
Ja	59	51	110
Ei	1958	416	2374
Kokku	2017	467	2484

³Anmed on võetud: P. G. N. Digby and R. A. Kempton (1987): Multivariate analysis of ecological communities. London, Chapman & Hall.

⁴Andmed on võetud: P. G. Norton and E. V. Dunn (1985): Snoring as a risk factor for disease. British Medical Journal, pp. 630-632.

Mõnikord on risttabelit raske lugeda, seepärast on kasulik esitada arvud protsentidena. Selleks on vaja läbida kolm järgnevat sammu:

1. Arvutada kokkuvõtted protsentidena (antud juhul protsent 2484-st).
2. Arvutada reakokkuvõtted protsentidena. 51 patsienti südamehaigustega moodustab $\frac{51}{467} \cdot 100 = 10,9\%$ kõigist, kes norskavad sageli/alati.
3. Arvutada veerukokkuvõtted protsentidena. Kõigist, kel on südamehaigusi, norskasid sageli või alati $\frac{51}{110} \cdot 100 = 46,4\%$.

Kumba protsenti arvutada, sõltub sellest, mida on vaja näidata. Käesolevas näites südamehaigustega patsientidest norskasid 46% sageli/alati. Samal ajal kui 18% kontrollgrupist norskasid. See viib mõttele, et on mingi seos norskamise ja südamehaiguste vahel. Hiljem uurime seda, kas see on "reaalne" või võib seda selgitada juhuslikkusega.

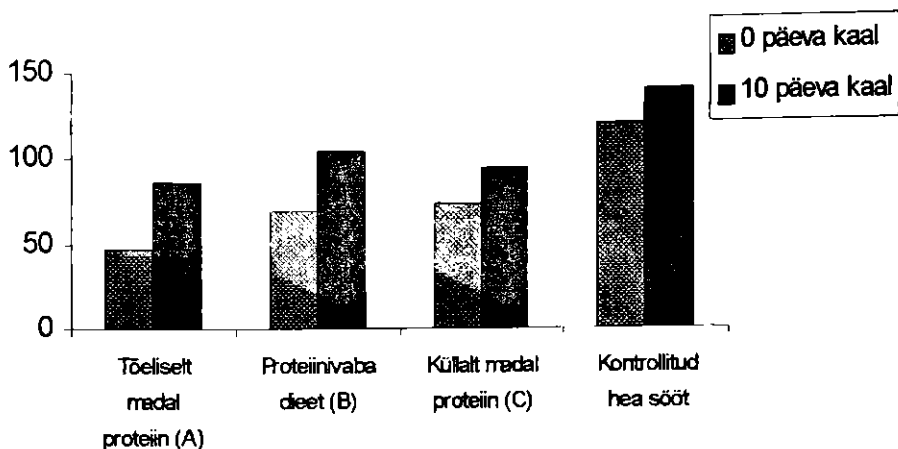
2.4.3 Tulpdiagrammid

Järgnevas tabelis on esitatud andmed hiirte kehakaalu kohta, keda söödeti erinevate toiduratsioonidega⁵ Andmed on kogutud eksperimendi esimesel päeval (0. päev) ja peale kümnenadat päeva (10. päev).

Grupp	0. päeva kaal (g)	10. päeva kaal (g)
Tõeliselt madal proteiin (A)	46	86
Proteiinivaba dieet (B)	70	105
Küllalt madal proteiin (C)	73	95
Kontrollitud hea sööt	120	140

Tulpdiagramm, mis kirjeldab hiirte juurdekasvu, on järgmine:

⁵Andmed on võetud: R.O. Lawal: The effect of a single oral dose of polyphenols obtained from the outercoat of the fruit of *Treculia africana* in protein-deficient rats. Food Chemistry 44 (1992) 321-323.




2.4.4 Sektordiagramm (Pie graafik)

Kevadise nisu kiudainete sisaldus on toodud järgmises tabelis⁶:

Dieedi kiud	Keskmine (%)
Arabinosi sete	2,30
Xylosi sete	3,60
Mannosi sete	0,28
Galactosi sete	0,49
Glucosi sete	3,60
Uronic happe sete	0,35
Klason ligniin	0,74

Nende andmete kujutamiseks sektordiagrammil arvutame erinevate komponentide protsendid ja transleerime need nurgakraadidesse.

⁶Andmed on võetud: Per Åman: The variation in chemical composition of Swedish wheats. Swedish J.agric.Res.18:27-30, 1988.



2.5 Ülesanded

2.1

20 taimest koosneva valimi kasvud (cm-tes) mõõdeti järgmiselt:

12	16	24	13	8	15	22	18	14	10
18	26	17	12	11	17	21	18	16	5

A. Kujuta andmestik sagedustabelina, moodustades selleks eelnevalt sobivad klassid.

B. Kasuta saadud sagedustabelit ja joonista selle põhjal histogramm.

C. Arvuta keskmine, dispersioon, standardhälve ja mediaan.

2.2

Emaseid rotte (28-84 päeva vanad) söödeti kindla toiduga. Nad kaaluti ja saadi järgmised andmed:

134	146	104	119	124	101	107	83	113	129	97	123	92	118
-----	-----	-----	-----	-----	-----	-----	----	-----	-----	----	-----	----	-----

A. Arvuta keskväärtus.

B. Arvuta dispersioon.

C. Kirjelda andmed, kasutades stem-and-leaf diagrammi.

D. Arvuta mediaan.

E. Koosta kastdiagramm.

2.3

Urija kasvatas kasvuhuone ühel peenral 15 tomatitaimet. Peale 21. päeva mõõtis ta taimede varrepikkused (cm), mis olid järgmised:

12,4	10,9	11,8	14,1	12,6
------	------	------	------	------

12,2	12,2	13,5	12,7	11,9
------	------	------	------	------

13,4	12,1	12,0	13,2	13,1
------	------	------	------	------

A. Konstrueeri nende andmete põhjal tüvi-leht-diagramm.

B. Arvuta keskväärtus.

C. Arvuta dispersioon.

D. Arvuta mediaan.

E. Koosta karpdiagramm.

2.4

Katses sooviti uurida, kuidas mõjub valgus sinepitaimede juurekasvule. 20 sinepitaimet istutati pottidesse. 10 juhuslikult valitud taime pagutati pimedasse, ülejäänud 10 taime jäeti kasvama päevavalgusesse. Mõne aja möödudes mõõdeti iga taime juure pikkust ja saadi järgmised tulemused:

Taimed päevavalgusest	Taimed pimedast
21	22
39	16
31	20
13	14
52	32
39	28
55	36
50	41
29	17
17	22

Küsimused:

- A. Arvuta keskväärtus mõlemas grupis.
- B. Arvuta dispersioon mõlemas grupis.
- C. Koosta karpdiagramm nii, et mõlemad grupid oleksid samal diagrammil.
- D. Tee tüvi-leht-diagrammid kahele grupile, kasutades ühesugust "tüve" mõlemale grupile.

Peatükk 3

Tõenäosus

3.1 Mõned kontseptsioonid ja märkused

Tõenäosusteooria sisaldab arvutusi ja tõenäosuslikke otsuseid selle kohta, mis võib juhtuda. See on väärtuslik bioloogidele, näiteks geneetikutele. Selle abil formuleeritakse ka meetodilised alused järelduste tegemiseks andmete kohta. Tõenäosusteooria põhimõisteks on sündmus, mis defineeritakse katse abil.

Definitsioon 7 *Juhuslikuks katseks nimetatakse katset, mille tulemus ei ole katsetingimustega üheselt määratud. Katse on suvaline arv korratav, tal on lõplik arv võrdvõimalikke tulemusi.*

Juhusliku katse kirjeldamisel ei lähtuta üksikust katsetulemusest, vaid sageli ilmneb katse paljukordsel kordamisel mingi seaduspärasus. Katse kordamise tingimused tuleb enne katse sooritamist fikseerida.

Näide. Kui me viskame täringut, siis katsetulemuste hulk on $\{1, 2, 3, 4, 5, 6\}$. Resultaat "6" on tulemus.

Definitsioon 8 *Sündmuseks nimetame iga katsetulemuste hulka.*

Ütleme, et sündmus A toimub, kui katse tulemusena esineb mõni selle võimalikest sündmuse katsetulemustest. Sündmus on määratud parajasti siis, kui on fikseeritud katse ja määratud tema katsetulemuste hulk. Seega ka iga üksik katsetulemus võib olla sündmus.

Näide. Võime defineerida sündmuse A kui "täringu kõik paarisarvulised arvud". Sel juhul on sündmus $A = \{2, 4, 6\}$.


Definitsioon 9 Täiend mingile sündmusele A sisaldab kõiki tulemusi, kus A ei esine. Sageli tähistatakse seda \bar{A} .

Näide. Kui $A = \{2, 4, 6\}$, siis esitatud näites täiend on $\bar{A} = \{1, 3, 5\}$.

3.2 Tõenäosuse üldmõisted

3.2.1 Tõenäosus kui suhteline sagedus

Näide. Oletame, et viskame münti. Märgame tulemused järgnevalt: münti esikülje saamise korral 1 ning tagakülje korral 0. Esimesel viskel saime münti tagakülje. Peale esimest viset on münti esikülgede suhteline sagedus 0. Teise viske tulemus on münti esikülg. Kui me tähistame münti esikülje ilmumise arvu f_n ja kõikide visete arvu n , siis saame $f_n/n = 0,5$. Münti esikülje ilmumise suhteline sagedus on 0,5. Võime jätkata münti viskamist. Peale 250 viset saame näiteks:



Näeme, et suhteline sagedus (proportsioon) stabiliseerub arvu 0,5 ümbruses. Võime oletada, et tõenäosus selleks, et viskel tuleb münti esikülg, on 0,5. Tõenäosuse ebatäpne definitsioon võiks olla $P = \lim_{n \rightarrow \infty} \frac{f_n}{n}$. See on Bernoulli poolt tõestatud suurte arvude seadus, mis väidab suhteliste sageduste jada koondumist tõenäosuseks.

3.2.2 "Soodsad" ja "võimalikud" tulemused

Tõenäosuse teine kontseptsioon on järgmine: oletame, et mingis katses saadi n võimalikku tulemust. Nendest f on soodsad. Missugune on tõenäosus, et üks soodne tulemus esineb?

Vastus on: kui erinevad tulemused on võrdtõenäosed ehk võrdvõimalikud, siis soodsate tulemuste saamise tõenäosus

$$P = \frac{f}{n}.$$

Näide. Meil on 100 loteriipiletit, millest igal piletil on ühesugune võimalus võiduks. Tõmbame nendest 5 piletit. Tõenäosus selleks, et võidame, on $\frac{5}{100} = 0,05$.

3.2.3 Aksiomaatiline tõenäosus

Matemaatikud eelistavad sageli tõenäosuse defineerimiseks kasutada kolme aksiomi.

1. Mingi sündmuse A tõenäosus $P(A)$ on arv, mis asub vahemikus

$$0 \leq P(A) \leq 1.$$

2. Mingi liitsündmuse tõenäosus on iga üksiku sündmuse tõenäosuste summa.

Näide. Tõenäosus, et täringuviskel tuleb paarisarv, on

$$P(2) + P(4) + P(6).$$

3. Iga sündmuse esinemistõenäosus on 1.

Näide. Tõenäosus, et täring näitab ühte numbritest (1, 2, 3, 4, 5, või 6), on 1^1

3.3 Mõned tõenäosuse reeglid

3.3.1 Liitmise reegel

Kui A ja B on kaks sündmust, siis tõenäosus selleks, et toimub üks sündmustest A või B või mõlemad (A ja B) on $P(A) + P(B) - P(A \text{ ja } B)$.

Märkus. Loogiline ja tähistatakse sageli märgiga \cap ja loogiline või tähistatakse \cup . Liitmise reegli võib kirjutada järgmiselt

$$P(A \cup B) = P(A) + P(B) - P(A \cap B).$$

¹Jätame tähelepanemata võimaluse, et viskel võib täring kaduma minna.

Näide. Teatav geen päritakse vastavalt järgmistele tõenäosustele:

	Mees	Naine	Kokku
Omab geeni	0,167	0,083	0,250
Ei oma geeni	0,333	0,417	0,750
Kokku	0,500	0,500	1,000

Mis on tõenäolisem, kas sündiv indiviid on mees või omab geeni või mõlemad - on mees ja omab geeni?

Vastus. Tõenäosus $P(A)$, et sündiv indiviid on mees, on 0,5. Tõenäosus $P(B)$, et see indiviid omab teatud geeni, on 0,25. Tõenäosus $P(A \text{ ja } B) = P(A \cap B)$, et indiviid on mees ja omab teatavat geeni, on 0,167. Seega kahe sündmuse koos esinemise tõenäosus on $0,500 + 0,250 - 0,167 = 0,583$.

3.3.2 Sõltumatud sündmused

Kui ühe sündmuse toimumine ei mõjuta teise sündmuse toimumise tõenäosust, siis need sündmused on sõltumatud. Järelikult, kaks sündmust A ja B on sõltumatud, kui kehtib võrdus

$$P(A \cap B) = P(A) \cdot P(B).$$

Näide. Eelneva näite põhjal küsime, kas sündmused, geeni olemasolu ja sugu, on sõltumatud?

Vastus. Kaks sündmust on sõltumatud, kui $P(\text{mees ja omab geeni}) = P(\text{mees}) \cdot P(\text{omab geeni}) = 0,5 \cdot 0,25 = 0,125$. Tabelist saame, et $P(\text{mees ja omab geeni}) = 0,167$. Seega $0,167 \neq 0,125$. Järelikult, geeni olemasolu ja sugu ei ole sõltumatud.

3.3.3 Sõltumatute sündmuste korrutamise reegel

Kui A ja B on sõltumatud sündmused, siis nende sündmuste korrutise tõenäosus võrdub tegursündmuste tõenäosuste korrutisega.

$$P(A \cap B) = P(A) \cdot P(B).$$

Näide. Teatavat liiki seemne idanevus on 90%, st kõikidest seemnetest 90% hakkavad idanema. Külvati kaks seemet. Missugune on tõenäosus, et mõlemad seemned idanevad?

Lahendus. $P(\text{mõlemad seemned idanevad}) = P(\text{esimene seeme idaneb}) \cdot P(\text{teine seeme idaneb}) = 0,9 \cdot 0,9 = 0,81$.

Näide. Sama liigi seemneid külvati 10 seemet. Kui suur on tõenäosus, et kõik seemned hakkavad idanema?

Lahendus. Kasutame korrutamise reeglit korduvalt, selle põhjal $P(\text{kõik seemned idanevad}) = P(\text{esimene seemne idaneb}) P(\text{teine seemne idaneb}) \dots$
 $P(\text{kümnes seemne idaneb}) = 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9 \cdot 0,9$
 $= 0,9^{10} = 0,3487$

3.3.4 Tinglik tõenäosus

Tõenäosus selleks, et sündmus A toimub tingimusel, et sündmus B on toimunud, tähistatakse $P(A|B)$.

Märkus. Sõltumatute sündmuste korral $P(A|B) = P(A)$. Tõenäosus ei tohi sõltuda B -st.

3.3.5 Bayes'i teoreem

Oletame, et on toimunud sündmus B ning me teame selle sündmuse toimumise tõenäosust $P(B)$. Nüüd toimus sündmus A , mille tulemusena võime esialgsele sündmusele arvutada täpsustatud tõenäosuse Bayes'i valemiga

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

Näide. Eelpool vaadeldud pärilikkuse näites kindlad indiviidid on mehed. Missugune on tõenäosus, et need indiviidid omavad teatud geeni?

Lahendus. Tabelist näeme, et tõenäosus $P(\text{mees ja omab geeni}) = 0,167$. Tabelist saame ka $P(\text{mees}) = 0,5$. Järelikult tõenäosus, et indiviid omab teatavat geeni, juhul kui ta on mees, on $0,167/0,5 = 0,333$. (Üks kolmandik kõikidest meestest omab teatavat geeni.)

3.3.6 Korrutamise reegel

Kui A ja B on sündmused (ei pea olema sõltumatud), siis tõenäosus, et A ja B toimuvad, arvutatakse

$$P(A \cap B) = P(A) P(B|A).$$

Näide. Pärilikkuse näites on tõenäosus selleks, et indiviid on mees ja omab teatavat geeni, $0,5 \cdot 0,333 = 0,167$ (mida just arvasime). Seda näeme ka ilma igasuguste arvutusteta otse tabelist.



Märkus. Bayes'i teoreem ja korrutamise reegel (lihtsas formuleeringus) on kaks erinevat teed sama asja kirjeldamiseks.

3.4 Ülesanded

3.1

Pärilikkuse näites omab indiviid teatud geeni. Missugune on tõenäosus, et see indiviid on naine?

3.2

Missugune on seemnete näites tõenäosus selleks, et 10 seemne hulgast vähemalt üks seeme hakkab idanema?

3.3

Ajalehes "Aftonbladet" 20.10.1994. võetud artikkel "'Tervel" naisel oli rinnavähk" Vastavalt artiklile said mõned naised, keda uuriti ultraheliga, vale diagnoosi. 4% naistest, kellel diagnoositi rinnavähk, olid tegelikult terved ja 2% naistel, kes olid terveks tunnistatud, oli rinnavähk.

Eeldame, et 3%-l vaadeldud naistest diagnoositi rinnavähk. Kasuta eelpool toodud informatsiooni ning vasta järgmistele küsimustele:

A. Missugune on tõenäosus, et naisel, kes diagnoositi kui "haige", tegelikult on ka rinnavähk?

B. Missugune on tõenäosus, et juhuslikult valitud naisel on rinnavähk?

C. Eeldame, et naisel on rinnavähk. Missugune on tõenäosus, et seda ei ole avastatud?

Peatükk 4

Tõenäosuslikud jaotused

4.1 Sissejuhatus


Juhuslik suurus on suurus, mille väärtused on määratud juhusega. Seda võib kirjeldada tõenäosusfunktsiooni või tõenäosusjaotusega. Matemaatiliselt on tõenäosusjaotus funktsioon, mis iseloomustab juhusliku suuruse tõenäosusliku käitumist. Mõned nendest jaotustest on osutunud sobivateks mudeliteks reaalsete protsesside või nähtuste kirjeldamisel. Järelikult võib tõenäosusfunktsiooni vaadelda kui matemaatilist mudelit üldkogumile, millest on võetud valim.

4.2 Diskreetsed juhuslikud suurused

Diskreetsed juhuslikud suurused kirjeldatakse tema tõenäosusfunktsiooni $f(x)$ abil. Igale juhusliku suuruse väärtusele seab funktsioon $f(x)$ vastu tema esinemistõenäosuse. Tõenäosusfunktsiooni võib esitada tabelina või valemiga, mis näitab juhusliku suuruse ja tema tõenäosuse vahelist seost. Juhusliku suuruse kõikide tõenäosuste summa on 1. Kui tähistame tõenäosusfunktsiooni $f(x)$, siis peab kehtima $\sum f(x_i) = 1$.

Näide Bernoulli jaotuse kohta, kui $p = 0,5$. Vaatleme lihtsat katset mündi viskamise kohta. Kui münt maandub esikülge peal, registreerime selle numbriga 1 ja kui maandub tagapool peal, siis märgime numbriga 0. Järelikult $x = 1$ ja $x = 0$ on kaks võimalikku tulemust. Kui münt on "lennus", on mõlemad tulemused võrdtõenäolised. Tõenäosusjaotuse võime esitada järgmise tabelina ja kujutada graafikul:

x	$f(x)$
0	0,5
1	0,5




$f(x)$ on kasutusel *tõenäosusfunktsioonina*. See näitab, et juhuslik suurus X omandab väärtuse x , mille tõenäosus on: $f(x) = P(X = x)$. Eelnevas lihtsas näites $f(x) = 0,5$, kui $x = 0$ ja $f(x) = 0,5$, kui $x = 1$ ning kõigil teistel juhtudel $f(x) = 0$.

Märkus. Tavaliselt kasutatakse X juhusliku suuruse tähistamiseks ja juhusliku suuruse väärtuse tähistamiseks tähte x . Tähistus $P(X = x)$ tähendab: "Tõenäosus selleks, et juhuslik suurus X omandab väärtuse x ". Seda tähistust kasutame juhtudel, kui on vaja vahet teha suuruse ja väärtuse vahel. Kui kontekstist on selge, siis kasutame väikest tähte.


Näide *üldise Bernoulli jaotuse* kohta. Oletame, et tulemused $x = 0$ ja $x = 1$ ei ole võrdtõenäolised $P(x = 1) = p$ ja $P(x = 0) = 1 - p$. See on Bernoulli jaotus, mis sõltub p väärtusest. Jaotuse *parameeter* on p .

x	$f(x)$
0	$1 - p$
1	p



Näide täisarvulise jaotuse kohta. Kui viskame täringut, siis võime saada 1, 2, 3, 4, 5 või 6 punkti. Kui täring veel veereb, on kõik tulemused võrdtõenäolised. Järelikult võime tõenäosusjaotuse kujutada järgmiselt:

x	$f(x)$
1	1/6
2	1/6
3	1/6
4	1/6
5	1/6
6	1/6




4.2.1 Diskreetse juhusliku suuruse jaotusfunktsioon

Jaotusfunktsioon $F(x)$ näitab iga väärtuse x korral tõenäosust, et diskreetne juhuslik suurus X omandab selle väärtuse või on sellest väiksem. Järelikult *jaotusfunktsioon* on

$$F(x) = P(X \leq x) = \sum_{x_i \leq x} f(x_i).$$


Näide. Järgnevas tabelis ja kõrvaloleval graafikul on esitatud Bernoulli jaotuse korral tõenäosusfunktsioon ja jaotusfunktsioon, kui parameeter on $p = 0,5$.



x	$f(x)$	$F(x)$
0	0,5	0,5
1	0,5	1,0

Näide. Esitame juhusliku suuruse tõenäosusfunktsiooni ja jaotusfunktsiooni, kus numbrid 1 kuni 6 on võrdtõenäolised. Antud olukord vastab soodsatele täringu visetele.

x	$f(x)$	$F(x)$
1	1/6	1/6
2	1/6	2/6
3	1/6	3/6
4	1/6	4/6
5	1/6	5/6
6	1/6	6/6



Statistiliste jaotuste paljud tabelid on jaotusfunktsioonide tabelid.

4.2.2 Diskreetse juhusliku suuruse keskväärtus

Diskreetse juhusliku suuruse keskväärtus on defineeritud kui

$$EX = \sum x f(x),$$

kus summeeritud on üle kõigi x väärtuste.

Näide. Bernoulli jaotuse korral, kus sündmused $x = 0$ ja $x = 1$ on võrdtõenäolised, on keskväärtus $EX = \sum x f(x) = 0 \cdot 0,5 + 1 \cdot 0,5 = 0,5$.

Näide. Üldise Bernoulli jaotuse korral, kus $P(x = 1) = p$ ja $P(x = 0) = 1 - p$, on keskväärtus $EX = \sum x f(x) = 0 \cdot (1 - p) + 1 \cdot p = p$.

Näide. Kui heita täringut, siis keskväärtus on

$$EX = 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + 3 \cdot \frac{1}{6} + 4 \cdot \frac{1}{6} + 5 \cdot \frac{1}{6} + 6 \cdot \frac{1}{6} = 3,5.$$

4.2.3 Diskreetse juhusliku suuruse dispersioon

Diskreetse juhusliku suuruse dispersioon defineeritakse valemiga

$$DX = \sum (x - EX)^2 f(x).$$

Näide. Bernoulli jaotuse korral, kus sündmused $x = 0$ ja $x = 1$ on võrdtõenäolised, arvutatakse dispersioon

$$DX = (0 - 0,5)^2 \cdot 0,5 + (1 - 0,5)^2 \cdot 0,5 = 0,25.$$

Näide. Üldise Bernoulli jaotuse korral

$$DX = (0 - p)^2 \cdot (1 - p) + (1 - p)^2 \cdot p = p(1 - p).$$

Näide. Kui heita täringut, siis

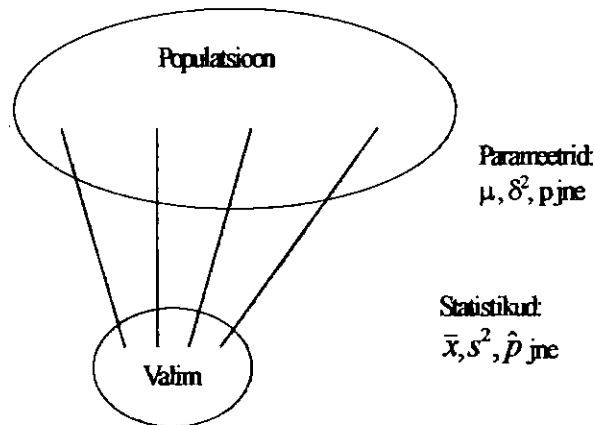
$$DX = (1 - 3,5)^2 \frac{1}{6} + (2 - 3,5)^2 \frac{1}{6} + (3 - 3,5)^2 \frac{1}{6} + (4 - 3,5)^2 \frac{1}{6} + (5 - 3,5)^2 \frac{1}{6} + (6 - 3,5)^2 \frac{1}{6} = \frac{35}{12} \approx 2,9167$$

Märkus. Siin on risk suureks segaduseks. Varem me näitasime, kuidas arvutada keskvärtus ja dispersioon andmestiku valimi jaoks. Nüüd andsime keskvärtuse ja dispersiooni valemid juhusliku suuruse jaoks. Viimati mainitud võib interpreteerida kui mingi üldkogumi keskvärtust ja dispersiooni. Nagu märkisime, on juhusliku suuruse tähendus sageli kasutusel kui mingi üldkogumi mudel. Palun püüa neid eristada:

a) valimi statistikumid: \bar{x} , s^2 jne,

b) üldkogumi (populatsiooni) parameetrid: $EX = \mu$, $DX = \sigma^2$ jne on määratud jaotusega juhusliku suuruse parameetrid. (Kreeka tähed on sageli kasutusel üldkogumi parameetrite tähistamisel.)

Ehk aitab joonis kergendada selle erinevuse arusaamisel:



4.2.4 Binoomjaotus

Näide. Seemnehunnikust võeti 5-st seemnest koosnev valim. Seemnetel oli 70% idanevus (st tõenäosus, et seeme hakkab idanema, on 0,7). Kui suur on tõenäosus, et kõik 5 seemet hakkavad idanema?

Lahendus. Kasutades tõenäosuste korrutamise reeglit, saame tõenäosuse $0,7 \cdot 0,7 \cdot 0,7 \cdot 0,7 \cdot 0,7 = 0,7^5 = 0,16807$

Näeme, et *binoomjaotus* määrab n katse hulgas "edukaks" osutunud katsete jaotuse. Tal on kaks parameetrit: n on katseseeria pikkus (täisarvuline) ja p on "edu" võimalikkus üksikkatsel (väärtus 0 ja 1 vahel).

Näide (järg). Missugune on tõenäosus, et 3 seemet 5-st idanevad?

Lahendus. Tähistame idanevat seemet numbriga 1 ja mitteidanevat seemet numbriga 0. Näiteks üks võimalik tulemus võib olla 1, 1, 1, 0, 0. Sellise järgnevuse tõenäosus on $0,7 \cdot 0,7 \cdot 0,7 \cdot 0,3 \cdot 0,3 = 0,7^3 \cdot 0,3^2 = 0,03087$

Võime valida kuidas iganes kolm idanevat seemet 5 seemne hulgast. Mõned näited on 1, 1, 0, 1, 0; 0, 1, 0, 1, 1; 1, 0, 1, 1, 0 ja nii edasi. Järgnev arvutus näitab erinevate võimaluste arvu 3 idaneva seemne valimiseks 5 seemne seast

$\binom{5}{3} = \frac{5!}{3!(5-3)!} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{3 \cdot 2 \cdot 1 \cdot (2 \cdot 1)} = 10$. Nende hulgast igal on esinemistõenäosus 0,03087. Järelikult, tõenäosus 3 idaneva seemne valimiseks on $10 \cdot 0,03087 = 0,3087$

Märkus. Sümbol $x!$ tähendab, et korrutame x -ga võrdse ja sellest väiksemad positiivsed täisarvud omavahel. Järelikult $5! = 5 \cdot 4 \cdot 3 \cdot 2 \cdot 1 = 120$. $x!$ loetakse " x faktoriaal"

Märkus. Sümbol $\binom{n}{x}$ on defineeritud järgmiselt: $\binom{n}{x} = \frac{n!}{x!(n-x)!}$.


4.2.5 Üldine binoomjaotus

Oletame, et mingi katse võib anda kaks erinevat tulemust, mida märgime koodide 1 ja 0 (näiteks idaneb ja ei idane) abil. Koodiga 1 tähistatud tulemusel on tõenäosus p . Seega, igal katsel on üldine Bernoulli jaotus. Katset korrati n korda. Missugune on tõenäosus, et 1-de arv on x ?

Tõenäosus, et juhuslik suurus X omandab väärtuse x ($0 \leq x \leq n$), on arvutatav järgmise valemiga:

$$P(X = x) = \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x}$$

See on binoomjaotuse tõenäosusfunktsioon $f(x)$. On võimalt näidata, et binoomjaotuse keskväertus ja dispersioon on vastavalt $EX = np$ ja $DX = np(1-p)$. Näitena esitame binoomjaotuse graafiku, kus $n = 10$ ja $p = 0,7$



Binoomjaotuse jaotusfunktsiooni väärtused on esitatud raamatu lisas "Tabelid" tabel 2. Illustreerime näite abil tabeli kasutamist.

Näide. Oletame, et meil on plaanis külvata 10 seemet. Valime need juhuslikult seemnehunnikust, seemnetel on 70% idanevus (st tõenäosus, et seeme hakkab idanema, on 0,7).

A. Missugune on tõenäosus, et rohkem kui 8 seemet 10-st idanevad?

B. Missugune on tõenäosus, et 8 seemet 10-st seemnest idanevad?

Lahendus. Väljavõte binoomjaotuse jaotusfunktsiooni tabelist, kus $n = 10$, on järgmine:

n	x	p=0.1	p=0.2	p=0.25	p=0.3	p=0.4	p=0.5	p=0.6	p=0.7
10	0	0.3487	0.1074	0.0563	0.0262	0.0060	0.0010	0.0001	0.0000
	1	0.7361	0.3758	0.2440	0.1493	0.0464	0.0107	0.0017	0.0001
	2	0.9298	0.6778	0.5256	0.3828	0.1673	0.0547	0.0123	0.0016
	3	0.9872	0.8791	0.7759	0.6496	0.3823	0.1719	0.0548	0.0106
	4	0.9984	0.9672	0.9219	0.8497	0.6331	0.3770	0.1662	0.0473
	5	0.9999	0.9936	0.9803	0.9527	0.8338	0.6230	0.3669	0.1503
	6	1.0000	0.9991	0.9965	0.9894	0.9452	0.8281	0.6177	0.3504
	7	1.0000	0.9999	0.9996	0.9984	0.9877	0.9453	0.8327	0.6172
	8	1.0000	1.0000	1.0000	0.9999	0.9983	0.9893	0.9536	0.8507
	9	1.0000	1.0000	1.0000	1.0000	0.9999	0.9990	0.9940	0.9718
	10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

A. Meie näites $p = 0,7$ Järelikult peame kasutama tulpa, kus $p = 0,7$ Raami sees olev arv on 0,8507 See tähendab, et kui idanevate seemnete arv (x) on 8 või väiksem, on tõenäosus: $P(x \leq 8) = 0,8507$

B. Tõenäosus, et täpselt $x=8$ seemet idanevad on,
 $P(x = 8) = P(x \leq 8) - P(x \leq 7) = 0,8507 - 0,6172 = 0,2335$.

4.2.6 Poisson'i jaotus

Näide. Vaatleme kindlalt liiki väikesi krabisid. Nad püüti piki randa täiesti juhuslikult. Rand jagati $0,5 \times 0,5$ m suurusteks ruutudeks. Loeti üle, mitu krabi on igas ruudus. Keskmiselt oli neid $\mu = 2$. Kui suur on tõenäosus, et kindel ruut sisaldab 3 krabi?

Lahendus. Üks võimalus selle probleemi vaatlemisel on mõttes jagada pindala ikka väiksemateks ja väikesemateks ruutudeks. Lõpuks on võimalik, et igas ruudus on mitte rohkem kui üks krabi. Neid ruute võib olla väga suur arv (n) ja krabide igasse ruutu sattumise tõenäosus (p) võib olla väga väike. Selle probleemi lahendamiseks võime kasutada binoomjaotust. Matemaatiliselt on võimalik näidata, et kui binoomjaotuse korral $n \rightarrow \infty$ ja $p \rightarrow 0$, siis np on konstant. Tähistame $np = \lambda s$. Seda tulemusjaotust tuntakse kui *Poisson'i jaotust* ja kirjutatakse

$$f(x) = \frac{\lambda s^x e^{-\lambda s}}{x!}$$

Märkus. Miks tähistasime parameetri λs -ga. Kas ei oleks olnud küllaldane kasutada ainult λ ? Vastus sellele on: Poisson'i jaotus on seotud kasutatavate ühikutega. Kui krabide arv m^2 kohta järgib Poisson'i jaotust parameetriga 3, siis krabide arv $0,5 m^2$ kohta järgib Poisson'i jaotust parameetriga 1,5.

Näiteks kui $\lambda s = 2$, siis tõenäosus, et täpselt $X = 3$ krabi satub ühte ruutu, on $f(3) = \frac{2^3 e^{-2}}{3!} = 0,1804$.

Poisson'i jaotuse keskväärtus $EX = \lambda s$ ja dispersioon $DX = \lambda s$. Järelikult, on keskväärtus ja dispersioon võrdsed.

Poisson'i jaotuse jaotusfunktsiooni tabelist (tabel 3 raamatu lisas) on esitatud väljavõte. Esitame tabeli kasutamise näite.

Oletame, et krabide arv ruutmeetri kohta järgib Poisson'i jaotust keskväärtusega $\lambda s = 3$.

A. Missugune on tõenäosus, et kindel ruut sisaldab mitte rohkem kui 5 krabi?

B. Missugune on tõenäosus, et kindel ruut sisaldab 5 krabi?

Lahendus. Järgnev tabel on Poisson'i jaotuse jaotusfunktsiooni tabeli osa.

x	$\lambda s=0.5$	$\lambda s=1$	$\lambda s=2$	$\lambda s=3$
0	0.607	0.368	0.135	0.050
1	0.910	0.736	0.406	0.199
2	0.986	0.920	0.677	0.423
3	0.998	0.981	0.857	0.647
4	1.000	0.996	0.947	0.815
5		0.999	0.983	0.916
6		1.000	0.995	0.966
7			0.999	0.988

A. Raami sees olev number annab vastuse: $P(X \leq 5) = 0,916$.


B. Nõutav tõenäosus arvutatakse:

$$P(X = 5) = P(X \leq 5) - P(X \leq 4) = 0,916 - 0,815 = 0,101.$$

4.3 Pidevad juhuslikud suurused

4.3.1 Ristkülikjaotus

Mitmed taskuarvutid ja tabelarvutusprogrammid omavad juhuslike arvude funktsiooni, mida sageli tähistatakse $RND()$. Kasutades seda funktsiooni, leiab arvuti juhusliku arvu enamasti 0 ja 1 vahel. Selliste numbrite jaotust nimetatakse *ristkülikjaotuseks*, mille väärtused on: $f(x) = 1$, kui $0 \leq x \leq 1$, ning teistel juhtudel on funktsiooni väärtus 0. Jaotusealune pindala on võrdne 1. Graafik on väga lihtne.



Eelnevalt käsitlesime diskreetseid juhuslikke suurusi. Nüüd käsitletavad juhuslikud suurused on pidevad juhuslikud suurused. Pidev juhuslik suurus võib omandada väärtusi kogu arvteljelt. Tema defineerimiseks kasutatakse tihedusfunktsiooni $f(x)$, mis on alati mittenegatiivne ja tema integraal üle kogu juhusliku suuruse määramispiirkonna on 1. Järelikult on järgnevate juhuslike suuruste korral tõenäosus esitatav pindalana. Näiteks ristkülikjaotuse korral tõenäosus, et X on väiksem kui 0,3, on 0,3. See on eeloleval graafikul vasakpoolne pindala väärtuseni 0,3. See tähendab, et jaotusfunktsioonil $F(x)$ on väärtus 0,3 kui $x = 0,3$.


4.3.2 Normaaljaotus

Normaaljaotus on tähtis kahel põhjusel. Esiteks, järgivad paljud muutujad bioloogilise uurimuse juures normaaljaotust, vähemalt ligikaudselt. Näitena võib tuua inimese pikkuse ja kaalu. Teiseks, valimi keskväärts ja teised statistikud, mis kehtivad valimis, püüavad järgida valimi mahu n kasvades normaaljaotust, mida näitame hiljem.

Normaaljaotus on pidev ja tal on kena kelluka kuju. Teda kirjeldavad kaks parameetrit: keskvärtus μ ja dispersioon σ^2 . Matemaatiline avaldis või tihedusfunktsioon *normaaljaotusele* on esitatav kui

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-0,5\left[\frac{(x-\mu)}{\sigma}\right]^2}$$


Tihedusfunktsioon on punkti μ suhtes sümmeetriline ja omab selles punktis kõige suuremat väärtust. Parameeter σ määrab tunnuse väärtuse hajutatuse keskvärtuse suhtes ja tema väärtus peab olema positiivne, $\sigma > 0$. Normaaljaotust parameetritega $\mu = 0$ ja $\sigma^2 = 1$ nimetatakse standardseks normaaljaotuseks ning tema graafik on järgmine:



Normaaljaotusega suuruste tõenäosus on arvutatav kui pindala, kusjuures kogu jaotusfunktsiooni alune pindala on 1. Pindala saab leida, kui arvutada vastav integraal. Praktiliseks kasutamiseks on valem arvutuslikult keerukas. Seetõttu esitatakse jaotusfunktsiooni (integraali) väärtused tabelis (tabelid 4 ja 5 raamatu lisas). Normaaljaotuse jaotusfunktsiooni tabeleid on sobiv kasutada normaaljaotusega juhusliku suuruse abil defineeritud sündmuste tõenäosuste arvutamiseks.

Näide. Kui suur on tõenäosus, et normaaljaotusega suuruse z väärtus on väiksem kui 1, kui tema keskvärtus on 0 ja dispersioon on 1?

Lahendus. Otsitav tõenäosus on näidatud graafikul väärtusest 1 vasakul pool:



Kasutame normaaljaotuse tabelit ja leiame soovitava tõenäosuse, mis on 0,8413.

Tabel annab igale z positiivsele väärtusele tõenäosuse $F(z)$ omandades väiksema väärtuse kui tabuleeritud, $P(Z < z)$. Kui soovime arvutada tõenäosuse, mis omandab suurema väärtuse, kui on tabelis, kasutame seost. $P(Z > z) = 1 - P(Z < z) = 1 - F(z)$.

Näide. Missugune on tõenäosus, et $Z > 1$?

Lahendus. See tõenäosus kujutab eelneval graafikul väärtusest 1 paremale poole jäävat pindala. $P(Z > 1) = 1 - P(Z < 1) = 1 - 0,8413 = 0,1587$

Negatiivsete z väärtuste korral kasutame fakti

$$P(Z \leq -z) = P(Z \geq z) = 1 - P(Z \leq z).$$

Näide. Missugune on tõenäosus, et $Z \leq -1$?

Vastus. $P(Z \leq -1) = P(Z \geq 1) = 1 - P(Z \leq 1) = 1 - 0,8413 = 0,1587$

Märkus: Matemaatilistele puristidele meeldiks ülaltoodud avaldises näha range võrratuse märki, st $P(Z > z)$. Pideva muutuja jaoks pole tähtsust faktil, et tõenäosus, kus Z omandab väärtuse z , on 0. Järelikult, $P(Z \leq 1) = P(Z < 1)$ nii võime kasutada ükskõik kumba kahest.

Märkus. Üldine nõuanne: kui on vaja arvutada tõenäosust normaaljaotuse jaoks, skitseeri jaotuse graafik ja viiruta otsitav pindala. See kergendab otsutamist, kas vastus on reaalne.

Siiani oleme vaadelnud ainult ühte erilist normaaljaotust, mille keskväär- tus $\mu = 0$ ja dispersioon $\sigma^2 = 1$. Ometi leidub erinevate keskväär- tuste ja dispersioonidega lõpmatult palju teisi normaaljaotusi. Normaaljaotuse sümmeetrilisuse tõttu saame tabeleid lihtsa teisendusega kasutada ka suvalise normaaljaotusega juhusliku suuruse kaudu defineeritud sündmuste tõenäo- suste arvutamiseks.

Kui X järgib normaaljaotust keskvaärtusega μ ja dispersiooniga σ^2 , siis muutuja $Z = \frac{X-\mu}{\sigma}$ järgib normaaljaotust keskvaärtusega 0 ja dispersiooniga 1. Z -i nimetame standardiseeritud normaaljaotuseks. Selle paremaks illustreerimiseks vaatleme näidet.

Oletame, et meeste pikkus üldkogumis (ligikaudu) järgib normaaljaotust $\mu = 175$ ja $\sigma = 10$. Missugune on tõenäosus selleks, et:

- juhuslikult valitud mees on lühem kui 185 cm,
- juhuslikult valitud mees on lühem kui 165 cm,
- juhuslikult valitud mehe pikkus on 165 ja 185 cm vahel?

Lahendus.

$$a) P(X < 185) = P\left(Z = \frac{X-\mu}{\sigma} < \frac{185-175}{10}\right) = P(Z < 1) = 0,8413$$

$$b) P(X < 165) = P\left(Z = \frac{X-\mu}{\sigma} < \frac{165-175}{10}\right) = P(Z < -1) = 0,1587$$

$$c) P(165 < X < 185) = P(-1 < Z < 1) = 0,8413 - 0,1587 = 0,6826.$$

4.3.3 Üldkogumi keskvaärtuse ja dispersiooni reegel

On kindlad reeglid juhusliku suuruse keskvaärtuse (matemaatilise ootuse) ja dispersiooni kasutamiseks. Me ei tõesta seda reeglit, vaid kasutame peagi mõnda nendest. Need reeglid on kokkuvõtvalt esitatud järgmises tabelis:

Funktsioon	Keskvaärtus	Dispersioon	Märkused
$a + bX$	$a + b\mu_x$	$b^2 \delta_x^2$	
$a + bX + cY$	$a + b\mu_x + c\mu_y$	$b^2 \delta_x^2 + c^2 \delta_y^2 + 2bc \cdot Cov(X, Y)$	
$a + bX + cY$	$a + b\mu_x + c\mu_y$	$b^2 \delta_x^2 + c^2 \delta_y^2$	Kui X ja Y on mittekorreleeritud, st $Cov(X, Y) = 0$
$X_1 + X_2 + \dots + X_n$	$\mu_1 + \mu_2 + \dots + \mu_n$	$\delta_1^2 + \delta_2^2 + \dots + \delta_n^2$	Kui X_1, X_2, \dots, X_n on mittekorreleeritud, st $Cov(X_i, X_j) = 0$ iga i, j korral
$X_1 + X_2 + \dots + X_n$	$\mu + \mu + \dots + \mu = n\mu$	$\delta^2 + \delta^2 + \dots + \delta^2$	Vaatlused on mittekorreleeritud võrdse keskvaärtuse μ ja dispersiooni σ^2 korral
$\bar{X} = \frac{\sum X_i}{n}$	μ	$\frac{\delta^2}{n}$	Vaatlused on mittekorreleeritud võrdse keskvaärtuse μ ja dispersiooni σ^2 korral

4.3.4 Juhusliku suuruse valimkeskmise \bar{X} jaotus

Oletame, et mingist üldkogumist (või jaotusest) on moodustatud n vaatlusega juhuslik valim, mille keskvärtus on μ ja dispersioon on σ^2 . Valimi keskvärtuse võime leida tavalisel viisil $\bar{x} = \frac{\sum x_i}{n}$. Valim on saadud sõltuvalt juhusest, kuna vaatluste valik valimisse oli juhuslik. Kui kordame valikut, saame erineva keskvärtusega teise valimi. Järelikult sõltub valimkeskmise \bar{X} juhusest: \bar{X} on juhuslik suurus!

Siin on kontseptsioon, millest on raske aru saada. Teadlane, kes tegi mingi katse, sai näiteks keskvärtuse 10,0. Ta võib intuitsioonivastaselt vaadelda seda kui "juhuslikku". Seejuures väärtus 10,0 oli juba vaadeldud. Trikk on kujutada ette, mis juhtuks, kui katsed korrata: saame terve hulga keskvärtusi. Kui laboratooriumi reeglid seda lubavad, võime katsed korrata ja võime saada lõpmatult palju valimeid. Teooria põhjal võime ennustada valimkeskmise \bar{X} käitumist katse kujutletavates kordustes.

Tuleme tagasi üldkogumi juurde, mille keskvärtus on μ ja dispersioon on σ^2 . Mida võime ennustada üldkogumi kohta, kui vaatleme üldkogumist moodustatud valimit, mille suurus on n ?

"Keskvärtuse ja dispersiooni reeglite" tabeli põhjal saame:

1. $E(\bar{X}) = \mu$ Korduvalt valitud valimkeskmise on üldkogumi keskvärtus.

2. $D(\bar{X}) = \frac{\sigma^2}{n}$ Valimkeskmise dispersioon, kui kasutame korduvat valikut, on üldkogumi dispersiooni ja valimi mahu suhe.

Märkus. Tähtis on seejuures eeldus, et vaatlused valimis peavad olema sõltumatud. See tingimus on täidetud, kui valim on moodustatud juhusliku valiku abil.

Märkus. $\sqrt{D(\bar{X})} = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$ tähendab ka siin valimkeskmise standardviga. (Võrdle seda avaldist kirjeldava statistika peatükis olevaga.)

Kolmas keskvärtuse omadus on esitatud ilma tõestuseta ja seda tuntakse kui tsentraalse piirväärtuse teoreemi:

3. *Valimkeskmise \bar{X} jaotus*, mis on saadud sama üldkogumi korduvate valimite põhjal, läheneb n -i kasvades normaaljaotusele. See avaldub paljudes mittermandunud valikutes, isegi kui X ei ole normaaljaotusega.

Võtame kokku eelneva: kui meil on mingi üldkogumi valim mahuga n , siis võime vaadelda valimkeskmist \bar{X} kui ühte vaatlust üldkogumist (jaotusest), millel on keskvärtus μ ja dispersioon $\frac{\sigma^2}{n}$. Kui valim on suur ja kui jaotus üldkogumis ei ole normaalne, võime lisaks eeldada, et \bar{X} on vähemalt ligikaudu normaaljaotusega. Kui üldkogum on normaaljaotusega, siis on ka

\bar{X} normaaljaotusega isegi juhul, kui n on väike.

Näide. Oletame, et meeste populatsioonis tunnus pikkus järgib (ligikaudu) normaaljaotust, mille $\mu = 175$ ja $\sigma = 10$. Missugune on tõenäosus selleks, et 4-st mehest koosnevas valimis keskmine pikkus on väiksem kui 180 cm?

Lahendus. Vaatleme seda valimit, mis järgib normaaljaotust, mille keskvärtus on $E(\bar{X}) = \mu = 175$ ja dispersioon on $D(\bar{X}) = \frac{\sigma^2}{n} = \frac{100}{4} = 25$, seega keskvärtuse standardviga on $\sqrt{25} = 5$. Nõutava tõenäosuse arvutamiseks kasutame Z teisendust, mille põhjal:

$$P(\bar{X} < 180) = P\left(Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} < \frac{180 - 175}{\sqrt{\frac{100}{4}}}\right) = P(Z < 1) = 0,8413$$

Näide. (Üldkogum, mis ei järgi normaaljaotust.) Oletame, et suurte majapidamiste populatsioonis autode omanike arv on jaotunud järgnevalt:

Autode arv x	Suhe kõikidest majapidamistest $f(x)$
0	0,40
1	0,50
2	0,07
3	0,03

Kui suur on tõenäosus, et 200 majapidamise juhuslikus valimis valimkeskmine on väiksem kui 0,8?

Lahendus. Üldkogumi jaoks võime leida

$\mu = \sum x f(x) = 0 \cdot 0,40 + 1 \cdot 0,50 + 2 \cdot 0,07 + 3 \cdot 0,03 = 0,73$ ja $\sigma^2 = \sum x^2 f(x) - \mu^2 = 0 \cdot 0,40 + 1 \cdot 0,50 + 4 \cdot 0,07 + 9 \cdot 0,03 - 0,73^2 = 1,05 - 0,5329 = 0,5171$. Suure valimi korral ($n=200$) võime oodata \bar{x} , mis vähemalt ligikaudu järgib normaaljaotust, hoolimata faktist, et üldkogum oli defineeritud mittenormaalsetena. Järelikult

$$P(\bar{x} < 0,8) = P\left(z = \frac{\bar{x} - \mu}{\sqrt{\frac{\sigma^2}{n}}} < \frac{0,80 - 0,73}{\sqrt{\frac{0,5171}{200}}}\right) = P(z < 1,38) = 0,9162.$$

4.4 Ülesanded

4.1

Väga suures puuviljade kaubalastis on kaoprotsendiks määratud 0,1%. Kui suur on tõenäosus, et juhuslikult moodustatud 9 puuviljast koosnev valim sisaldab:

- A. ühte riknenud puuvilja,
- B. vähemalt kolme riknenud puuvilja?

4.2

Kõrge amplituudiga lained järgivad sekundis Poissoni jaotust keskväärtusega $\lambda s = 2$ sekundis. Arvuta tõenäosus, et 5-sekundilise perioodi kestel:

- A. ei esinenud selliseid laineid, st $P(X = 0)$,
- B. $P(X \leq 16)$,
- C. $P(X > 19)$?

4.3

Võib eeldada, et lehmade piimatoodang järgib normaaljaotust keskväärtusega $\mu = 24,5$ ja dispersiooniga $\sigma^2 = 30$.

- A. Missugune on tõenäosus, et juhuslikult valitud lehma toodang on alla 18 kg?
- B. Missugune on tõenäosus, et 10 juhuslikult valitud lehma keskmine toodang on väiksem kui 26 kg?
- C. Missugune on tõenäosus, et 10 juhuslikult valitud lehma kogutoodang on rohkem kui 280 kg?
- D. Leia ülemine ja alumine piir lehmade piimatoodangule, eeldades, et 95% kõikide lehmade piimatoodangust on nende piiride vahel. (Piirid peavad olema sümmeetrilised keskväärtuse ümber.)
- E. Leia ülemine ja alumine piir 10 lehma keskmisele piimatoodangule, eeldades, et 95% kõikidest gruppidest, mis koosnevad 10 juhuslikult valitud lehmast, omavad keskväärtust nende piiride vahel.

4.4

Laboratooriumis uuriti alaniini aminotransferaasi (ALT) seerumit. On teada, et korduvate katsete seerias järgib üksiku proovi tulemus normaaljaotust keskväärtusega, mis on võrdne selle katse õige ALT kontsentratsiooniga, ja standardhälbega $\sigma=4$.

- A. Oletame, et ALT kontsentratsioon rohkem kui 40 on vaadeldav kui “ebaharilikult kõrge“ Kui õige ALT kontsentratsioon on 35, missugune on tõenäosus, et tema proov on “ebaharilikult kõrge“?
- B. Oletame, et laboratoorium teeb iga prooviga kaks analüüsi. Missugune

on tõenäosus, et nende kahe mõõtmise keskväärtus \bar{X} on suurem kui 40, kui proovi õige ALT kontsentratsioon on 35?

C. Leia 95% vea usalduspiirid katse tulemustele, kui proovi õige ALT kontsentratsioon on 35, eeldades, et

- i) tehti üks ülesmärkimine,
- ii) tehti kahekordne ülesmärkimine.

4.5

Farmaatsiakompanii korraldas diagnostilise testi X, et uurida inimeste medikamentide kuritarvitamist. Test tehti kõigile, isegi kui inimene ei olnud vaadeldaval ajal ravimit kuritarvitanud. X kõrge väärtus näitab, et inimene on kuritarvitanud ravimeid. Test tehti inimestega, kelle kohta on teada, et nad kuritarvitavad ravimeid, ja kontrollgrupiga. Võib eeldada, et X järgib igas grupis normaaljaotust. Teadaolevad üldkogumi parameetrid on toodud järgnevas tabelis:

	Kuritarvitajad	Kontroll
Keskväärtus μ	5,0	2,5
Standardhälve σ	1,0	0,5

Klassifitseerimise reegel on järgmine: inimene on ravimi kuritarvitaja, kui X-i väärtus on üle 3,5.

Diagnostilise testi tundlikkus on tõenäosus, et haige inimene on ka testi järgi haigeks diagnoositud.

Diagnostilise testi eripära on tõenäosus, et terve inimene on ka testi järgi terveks diagnoositud.

Küsimused:

- A. Arvuta esitatud testi tundlikkus.
- B. Arvuta esitatud testi eripära.
- C. Võib arvata, et kontrollgrupis on inimesi, kes kuritarvitavad ravimeid, aga kellel õnnestus seda varjata. Need on inimesed, kellel X-i väärtus on tõenäoliselt kõrge. Eeldame, et sellised inimesed leitakse ja kustutatakse kontrollgrupist. Mis juhtub siis:

- i) tundlikkusega,
- ii) eripäraga?

4.6

Paljud meditsiinilised katsed baseeruvad niinimetatud “kahe sigma piiridel“. Moodustame vere koostise kohta valimi erinevatest mõõtmistest, milles on andmed kaaliumi, kaltsiumi, kolesterooli jne kohta. “Kahe sigma piirid“ on (keskväärtus) \pm (2-kordne standardhälve). Üldiselt võib öelda, et 95% kõigist tervetest patsientidest omavad väärtusi nende piiride vahel.

“2 sigma“ kolesterooli piirid naistel on:

Vanus	2 sigma piirid
Noorem kui 21	140 – 180
21 kuni 49	140 – 280
50 või üle	180 – 280

Küsimused.

A. Leia iga vanusegrupi korral, missuguse keskvaartuse μ ja standardhälbe σ korral on tabelis esitatud piirid määratud.

B. Missugune on tõenäosus, et indiviid on väljaspool kolme sigma piire?

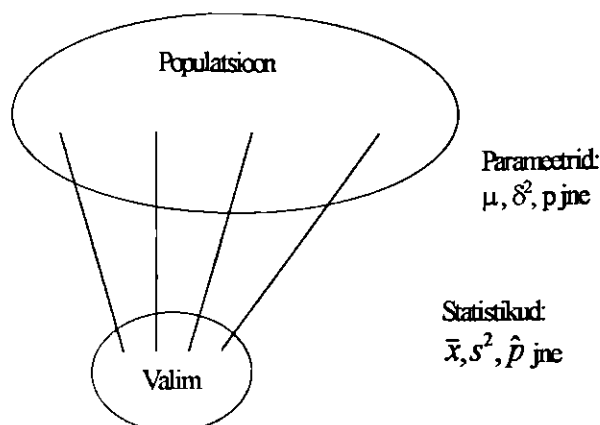
C. 18-aastase tüdruku kolesterooli tase on 225. Missugune on tõenäosus, et tüdruk on terve, kui ta kolesterooli tase on 225 või suurem?

Peatükk 5

Statistiline järeldus: hindamine

Enamike teaduslike andmete kogumise eesmärk on teha järeldusi, mida saab üldistada. Veterinaar või arst on tavaliselt huvitatud üksikust patsiendist. Statistiline järeldus tehakse mingi kogumi kohta: "Katses raviti tüsedaid patsiente ravimiga A, mille tulemusena vähenes nende kaal (keskmiselt) 3 kg. Teisi patsiente raviti ravimiga B ning nende keskmine kehakaal vähenes 1.7 kg" Arstid kasutavad sageli selliseid tulemusi, otsustades, missugust ravimit määrata. Nad võivad eeldada, et patsient on "sarnane" patsiendiga, keda kasutati katses, ning ravim A on tema jaoks katsetulemuse põhjal parim.

Paljude statistiliste otsuste kujunemine on järgmine. Eeldame, et eksisteerib üldkogum, mille jaoks ongi vaja tulemusi üldistada. Kui eeldame, et üldkogumis on mingil tunnusel mingi jaotus, siis selle jaotuse võib kindlaks määrata mingite jaotusparameetrite abil: tunnuse keskvaartuse μ , tunnuse dispersiooni σ^2 , tunnuse osakaalu p jne järgi. Üldkogumi tunnuste parameetrid on üldiselt tundmatud ja andmete kogumise üheks eesmärgiks on hinnata neid parameetreid. Järelikult tuleb moodustada üldkogumist valim. Saame arvutada valimi statistikud, mis kirjeldavad valimit: keskvaartus \bar{x} ; dispersioon s^2 ; osakaal \hat{p} jne. Seda vaadet võib illustreerida järgmiselt:



Valimit kasutatakse selleks, et teha järeldusi üldkogumi kohta. Neid järeldusi nimetakse statistilisteks järeldusteks.

Näide. 1000 valija seast valiti juhuslikult 350 valijat. Nad ütlesid, et valivad sotsiaaldemokraate, kui valimised oleksid täna. Mida võib öelda sotsiaaldemokraatide poolt hääletajate proportsiooni (suhte) kohta kõigi valijate hulgast?

Näide. Instrumenti kasutati viis korda, et kindlaks määrata laktoosi taset lahuses. Iga kord saadi veidi erinev tulemus, kuna mõõtmisel esineb alati mingi viga. Võime arvutada viie mõõtmise keskväärtuse $\bar{x} = 3,22$ ja dispersiooni $s^2 = 0,047$. Missugune on "õige" laktoosi tase lahuses?

Näide. A sorti nisu kasvatati 10 põllul ja B sorti nisu 10 teisel põllul. A sorti nisu andis keskmiselt saaki 8,0 ja B sorti nisu andis saaki 7,4. Kas võime julgesti soovitada, et A sorti nisu on parem?

5.1 Märkus

Märkisime juba varem, et on kasulik kasutada erinevaid sümboleid üldkogumi parameetriteks ja valimi statistikuteks. Kokkuvõtvalt on järgnevas tabelis esitatud mõned sageli kasutatavad sümبولid.

	Üldkogumi parameetrid		Valimi statistikud	
Ühikute arv	N		n	
Keskvärtus	μ		\bar{x}	
Dispersioon	σ^2		s^2	
Standardhälve	σ		s	
Proportsioon	p	või p_X	\hat{p}	või \hat{p}_X

5.2 Punkthinnang

Üldkogumi parameetri hinnang on mingi valimi parameetri lähendfunktsioon. Saadud väärtust nimetakse hinnanguks. Hinnangut võib esitada üksikväärtusena, punkthinnanguna või usalduspiiridena.

Tavaliselt lisatakse hindamisel mingi märk vastavale tähisele, \wedge (“katus”) sümboli kohale. Keskväertuse μ hinnangut tähistatakse $\hat{\mu}$, dispersiooni σ^2 hinnangut tähistatakse $\hat{\sigma}^2$

Näide. \bar{x} on (punkt-)hinnang μ . Järelikult kehtib võrdus $\hat{\mu} = \bar{x}$ Kui arvutame valimi põhjal keskmise $\bar{x} = 12,4$, siis 12,4 on (punkt-)hinnang μ .

Näide. s^2 on (punkt-)hinnang σ^2 Järelikult $\hat{\sigma}^2 = s^2$ Kui valimist saame $s^2 = 3,5$, siis 3,5 on (punkt-)hinnang σ^2

5.3 Hinnangu omadused

Soovime, et hinnangud oleksid mingis mõttes “lähedased” tegelikule parameetri väärtusele. Hinnangus sisaldub alati mingi süstemaatiline viga, st hinnang üle- või alahindab hinnatava parameetri õiget väärtust. Esitame mõned hinnangu omadused Need on: nihutamatus, efektiivsus ja ruutkeskmise viga.

5.3.1 Nihutamatus

Mingi parameetri θ hinnang $\hat{\theta}$ on nihketa, kui hinnang on keskmiselt õige, st $E(\hat{\theta}) = \theta$.

Näide. Võib näidata, et $E(\bar{X}) = \mu$. Järelikult valimi keskväertus on üldkogumi keskväertusele μ nihketa hinnanguks.

Näide. Võib näidata, et $E(s^2) = \sigma^2$ Järelikult valimi dispersioon on üldkogumi dispersioonile σ^2 nihketa hinnanguks.

Näide. Üldiselt, $E(s) \neq \sigma$ Järelikult valimi standardhälve ei ole üldkogumi standardhälbe nihketa hinnanguks.

Nihe hinnangule on defineeritud järgmiselt $Bias(\hat{\theta}) = E(\hat{\theta}) - \theta$.

5.3.2 Efektiivsus

Mõnikord hinnatakse ühte ja sama parameetrit erineval viisil. Üks võimalus hinnangute võrdlemiseks on võrrelda nende dispersioone. Võib öelda, et hin-

ning $\hat{\theta}_1$ on efektiivsem kui hinnang $\hat{\theta}_2$, kui $D(\hat{\theta}_1) < D(\hat{\theta}_2)$. Suhteline efektiivsus $\hat{\theta}_1$ ja $\hat{\theta}_2$ vahel defineeritakse $\frac{D(\hat{\theta}_2)}{D(\hat{\theta}_1)}$.

Näide. Tähistame valimi mediaani Md . Saab näidata, et normaaljaotuse korral $D(Md) = \frac{\pi}{2} \frac{\sigma^2}{n}$ Teame, et $D(\bar{X}) = \frac{\sigma^2}{n}$. Mediaani suhteline efektiivsus, kui võrrelda seda valimi keskväärtusega, on järelikult $\frac{D(Md)}{D(\bar{X})} = \frac{\pi}{2} \approx 1,57$ \bar{X} on 57% efektiivsem kui mediaan. Teisti öeldes, sama täpsusega μ hindamiseks vajame 57% võrra suuremat valimit, kui kasutame Md asemel.

5.3.3 Ruutkeskmise viga

Mõnikord võime leida kaks erinevat hinnangut: nihutatud hinnangu, millel on väike dispersioon, ning mingi teise nihutamata hinnangu, millel on suur dispersioon. Missugust hinnangut valida? Hinnangu valimise kriteeriumiks defineerime hinnangu $\hat{\theta}$ ruutkeskmise vea järgmiselt: $MSE = E \left[(\hat{\theta} - \theta)^2 \right]$

Valime hinnangu, millel on väiksem MSE. See näitab, et $MSE(\hat{\theta}) = D(\hat{\theta}) + [Bias(\hat{\theta})]^2$

5.4 Vahemikhinnang

5.4.1 Keskväärtuse μ usalduspiirid, kui σ^2 on teada

Usaldusvahemik on avaldis üldkogumi parameetri kohta. Avaldis on esitatud kui vahemik: "Vahemik 2,5 kuni 5,9 katab keskväärtuse μ õige väärtuse" Väide on esitatud 95% usaldusnivool. Me võime 95% kindlad olla, et see väide on õige.

Sissejuhatav näide. Instrumenti kasutati viis korda, et määrata kindlaks laktoosi tase lahuses. Iga kord saadi veidi erinev tulemus, kuna mõõtmisel esineb alati mingi viga.. Mõõtmised olid järgmised:

3,4; 3,3; 3,1; 2,9; 3,4.

Tööjuhises on lubatud instrumendi mõõtmisviga dispersiooniga $\sigma^2 = 0,05$. Arvuta 95% usaldusvahemik laktoosi õigele tasemele lahuses.

Teame järgmist:

- 1) valimi keskväärtus on $\bar{x} = 3,22$,
- 2) valim sisaldab $n = 5$ vaatlust,

3) üldkogumi dispersiooni $\sigma^2 = 0,05$,

4) me ei tea x jaotust, aga eeldame, et x järgib normaaljaotust (mõõtmise vead järgivad sageli normaaljaotust),

5) ei tea, kas vaatlused on tehtud sõltumatult, aga eeldame, et on.

Nendele faktidele ja oletustele toetudes peab vaadeldav väärtus \bar{X} näitama ühte vaatlust, mis järgib normaaljaotust keskväärtusega μ (mis on teadmata) ja dispersiooniga $\frac{\sigma^2}{n}$ (meie juhul on teada). Järelikult:

$\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$. Võime teisendada selle standardnormaaljaotuseks:

$$Z = \frac{\bar{X} - E(\bar{X})}{\sqrt{Var(\bar{X})}} = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}}$$

Standardnormaaljaotus Z näitab, et tõenäosus, omandada z -i väärtust vahemikus $-1,96$ ja $+1,96$,

on $0,95$ (st 95%). Märkus. Selle väärtuse leiad raamatu lõpus tabelist 5 viimaselt realt veerust $0,975$.

Järelikult võime öelda, et

$$P\left(-1,96 < \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} < 1,96\right) = 0,95. \text{ Teisendame seda avaldist:}$$

$$P\left(\bar{X} - 1,96 \sqrt{\frac{\sigma^2}{n}} < \mu < \bar{X} + 1,96 \sqrt{\frac{\sigma^2}{n}}\right) = 0,95. \text{ Kui asetame oma näite}$$

väärtused avaldisse, saame vahemiku $3,22 - 1,96 \cdot \sqrt{\frac{0,05}{5}} < \mu < 3,22 + 1,96 \cdot$

$\sqrt{\frac{0,05}{5}}$, millest

$$3,22 - 0,196 < \mu < 3,22 + 0,196 \text{ ning lõpuks saame } (3,024 < \mu < 3,416).$$

Oleme 95% veendunud, et vahemik $(3,024; 3,416)$ sisaldab μ õige väärtuse. Neid arve nimetatakse keskväärtuse μ 95% usalduspiirideks.

Järelikult, keskväärtuse μ 95% usalduspiirid arvutatakse järgmiselt:

$$\bar{x} \pm z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}.$$

Suurusele z saame väärtuse t -jaotuse tabelist raamatu lõpus. 95% usalduspiiride jaoks kasutame veergu $0,975$.

Usaldusvahemiku laius sõltub kolmest parameetrist:

- 1) suurem σ väärtus annab laiema vahemiku,
- 2) suurem n väärtus annab väiksema vahemiku (kui suurendame valimi mahtu, saame väiksema juhusliku varieeruvuse),
- 3) kui muudame usaldusnivood, muutub ka vahemik. Näiteks 99% usaldusvahemik on laiem kui 95% usaldusvahemik.

5.4.2 Keskväertuse μ usalduspiirid, kui σ^2 ei ole teada

Kui üldkogumi dispersioon ei ole teada, siis ei saa enam arvutada nii nagu eelpool. Z -i avaldises ei tea me σ väärtust. Sel juhul kasutame Dublini Guinnessi õllefabriku ärisaladust. Aastal 1908 avaldas üks Guinnessi töötaja W. S. Gossett tõestuse, et teatava eelduse korral järgib statistik $\frac{\bar{X}-\mu}{\sqrt{\frac{s^2}{n}}}$ niinimetatud t -jaotust. Fabriku juhatus ei lubanud Gossett'il artiklit teaduslikus ajakirjas avaldada, nii avaldas ta oma tulemused pseudonüümi Student all. Sellepärast kutsutakse seda jaotust sageli kui Student'i t -jaotuseks.

Teeme t -jaotuse korral järgmised eeldused:

1. Vaatlused peavad olema vastastikku sõltumatud. Lihtsaim viis selle saamiseks on valida andmestikust lihtne juhuslik valim.

2. X -i jaotus peaks olema normaaljaotus. See eeldus sobib suuremale valimile.

Kui need eeldused on täidetud, siis järgib statistik $\frac{\bar{X}-\mu}{\sqrt{\frac{s^2}{n}}}$ t -jaotust. Jaotus on määratud parameetriga, mida nimetatakse vabadusastmete arvuks. Sel juhul märgime tõestuseta, et vabadusastmete arv on $(n-1)$. (See on s^2 avaldise nimetaja.) Osa tabelist 5 on t -jaotuse tabel.

Näide. Vaatleme eelnevas punktis esitatud näidet, kuid nüüd ei tea üldkogumi dispersiooni σ^2 . Arvuta 95% usalduspiirid laktoosi õigele tasemele lahuses.

Näites olevate andmete põhjal võime arvutada keskväertuse $\bar{x} = 3,22$ ja dispersiooni

$$s^2 = \frac{\sum x^2 - \frac{(\sum x)^2}{n}}{n-1} = \frac{52,03 - \frac{(16,1)^2}{5}}{4} = \frac{0,188}{4} = 0,047$$

Meil on $n = 5$ vaatlust, seega vabadusastmete arv on $n - 1 = 4$. Leiame t -jaotuse tabelist, et t väärtusele tõenäosusega 95% vastab $t = 2,776$. Võime arvutada tõenäosuse

$$P\left(-2,776 < \frac{\bar{X}-\mu}{\sqrt{\frac{s^2}{n}}} < 2,776\right) = 0,95. \text{ Teisendame avaldist}$$

$P\left(\bar{X} - 2,776 \sqrt{\frac{s^2}{n}} < \mu < \bar{X} + 2,776 \sqrt{\frac{s^2}{n}}\right) = 0,95.$ Peale teadaolevate väärtuste asetamist avaldisse saame usaldusvahemiku

$$3,22 - 2,776 \sqrt{\frac{0,047}{5}} < \mu < 3,22 + 2,776 \sqrt{\frac{0,047}{5}},$$

$$3,22 - 0,269 < \mu < 3,22 + 0,269; \quad (2,95 < \mu < 3,49).$$

Võime 95% kindlusega öelda, et vahemik $(2,95; 3,49)$ sisaldab μ õiget väärtust.

Keskväertuse μ usalduspiirid (kui üldkogumi σ on teadmata) arvutatakse valemist

$$\bar{x} \pm t \frac{s}{\sqrt{n}}$$

t väärtus saadakse t -jaotuse tabelist. 95% usalduspiiride jaoks kasutame veergu 0,975. t -jaotuse vabadusastmete arv on $n - 1$.

Maksimaalne vabadusastmete arv (γ) t -jaotuse tabelis on 100. Suurema γ väärtuse korral peame kasutama z väärtust kui head lähendit. Nagu näeme t väärtus 100 vabadusastmega (veerus 0,975) on võrdne 1,984 ning vastav z -i väärtus on 1,96. Püüdlükud tudengid kasutavad suurte valimite korral γ väärtusena tabelis toodud väärtuste interpolaatsiooni, samal ajal kui paljud tudengid kasutavad lihtsalt ligilähedast väärtust.

5.4.3 Kui suur peab valim olema?

Sissejuhatav näide. Kasutame punkti 5.4.1 näidet.

Soovime teha uusi mõõtmisi ja vajame valimit nii, et keskväertuse μ 95% usalduspiirid oleksid kitsamad kui $\pm 0,10$. Kui suurt valimit vajame?

Eelduse kohaselt teame, et $\sigma^2 = 0,05$. Eespool on juba arvutatud nende andmete keskväertuse μ 95% usalduspiirid: $3,22 \pm 1,96\sqrt{\frac{0,05}{5}}$; $3,22 \pm 0,196$.

Uue valimi jaoks peame jälgima, et $1,96\sqrt{\frac{\sigma^2}{n}} \leq 0,10$, millest

$1,96^2\sigma^2 \leq 0,10^2 \cdot n$; $n \geq \frac{1,96^2\sigma^2}{0,10^2}$ Kuna teame, et $\sigma^2 = 0,05$, siis järelikult $n \geq \frac{1,96^2 \cdot 0,05}{0,10^2}$ Ümardame ülespoole ja saame valimi mahuks $n = 20$.

5.4.4 Valimi mahu määramise üldine valem

Valime $n = \frac{z^2\sigma^2}{L^2}$, kus L on soovitatav täpsus. (Järelikult L on usalduspiiride pool pikkust.) Ümardame n lähima täisarvuni ülespoole.

Valimi mahu määramisel on probleemiks, et peame teadma dispersiooni σ^2 Praktikas teame harva dispersiooni väärtust, eriti enne andmete kogumist. Järgnevad meetodid annavad vähemalt mingi hinnangu dispersioonile.

1. Kui üldkogumi dispersioon on teada, kasuta muidugi seda.
2. Kui üldkogumi dispersioon on teadmata, võib kasutada mõne varajase samatüübilise andmestiku valimi dispersiooni.

3. Kui isegi see ei ole võimalik, järgi oma töös "kiiret ja musta" meetodit. Püüa (oletuse ja ettekujutuse abil) leida suurim x (x_{max}) ja vähim x (x_{min}) väärtus, mida nendest muutujatest võib võtta. Paljude korralike jaotuste korral võib see olla $(x_{max} - x_{min}) \approx 4s$. (Kui jaotus ei ole hea, võib kasutada selle asemel 5s.) See teeb võimalikuks oletada dispersiooni σ suurust, mis on sageli valimi mahu määramisel küllaldane.

5.5 Ülesanded

5.1

McIntosh (ära aja segi arvuti margiga) sorti õunte hindade valim koguti juhuslikult erinevatest kauplustest. Hinnad olid (dollarites):

2,31 2,50 2,30 2,40 2,34 2,20 2,42
 2,46 2,30 2,25

A. Arvuta keskväärtus ja dispersioon.

B. Arvuta keskväärtuse μ 95% usalduspiirid.

C. Mitu protsenti valimi vaatlustest on usalduspiiride vahel? Kommenteeri vastust.

5.2

Juhuslikult valitud ülikooli 10 meesõppejõu vere kolesterooli tase oli (grammi liitri kohta):

3,0 1,8 2,1 1,4 2,5 1,6 1,9 2,8 2,2 2,7

A. Arvuta keskväärtus ja dispersioon.

B. Arvuta ja interpreteeri keskväärtuse μ 95% usalduspiirid.

5.3

On teada, et 90% normaalkaaluliste kanade tapakaal on 1,9 ja 2,1 vahel. Tehti katse, kus kontrolliti uut toitumisskeemi. Arvuta soovitatav valimimaht nii, et keskväärtuse μ 95% usalduspiirid ei oleks laiemad kui ± 20 grammi (st $\pm 0,02$ kg). Eeldame, et standardhälve on sama suur kui normaalkaaluliste kanade korral.

5.4

Mingil kindlal maal on teada, et seal elab 35000 fertiilsuseas naist. Terviseprogrammi planeerimiseks on vaja informatsiooni. Sellel maal on vaja hinnata (0 - 6 aastaste) laste arvu. Moodustati juhuslik valim $n=400$ naisest ning küsiti nendelt, mitu 0 - 6 aasta vanuses last on neil. Tulemused on esitatud tabelis:

Laste arv x	0	1	2	3	4	Kokku
Naiste arv f	40	100	120	110	30	400

A. Arvuta keskväärtus ja dispersioon laste arv/ naiste valimis.

B. Arvuta keskväärtuse μ 95% usalduspiirid, keskmine laste arv ühe naise kohta.

C. Arvuta 95% usalduspiirid 0- kuni 6-aastaste laste üldarvule sellel maal.

D. Küsitlust tahetakse korrata ning sellel juhul keskväärtuse μ usalduspiirid ei tohi olla laiemad kui $\pm 0,05$. Mitu naist on nüüd valimisse vaja?

Peatükk 6

Hüpoteeside kontrollimine

6.1 Sissejuhatav näide

(R.A. Fisheri, kes on üheks suureks meheks statistikas, klassikaline näide).

"Daam ütleb, et ta võib tee maitse järgi määrata, kas tassi valati esimesena tee või piim. Testimine kinnitas seda. Valmistati ette viis teetassi. Mõnda valati esimesena tee ja mõnda tassi esimesena piim. Katsealune määras iga tassi kohta, mida sinna esimesena valati. Daam määras viis korda järjest õigesti.

Testi hüpotees on, et daam oskab vahet teha tee kahe valmistamisviisi vahel."

On ilmne, et kunagi ei saa kindlalt öelda, kas meil on õigus daami uskuda või mitte. Võime kehtestada mingisuguse "otsuse reegli" nii, et teeksime võimalikult vähem vigu.

Teaduslik lähenemine on alustada daami umbusaldamisega. Esimese hüpoteesina oletame, et daam ei tunne erinevust, mis tähendab, et edu tõenäosus iga tassi korral on 0,5. Seda nimetatakse nullhüpoteesiks:

$$H_0 : p = 0,5.$$

Tegelikult, kui daam tunneb erinevust kahte liiki tee vahel, siis nullhüpotees on vale. Võime olla suuremeelsed ja möönda, et daam tunneb erinevust, seepärast on tal edu tõenäosus suurem kui 0,5. Sellepärast kasutame alternatiivset ehk sisukat hüpoteesi:

$$H_1 : p > 0,5.$$

Teaduslik ülesanne on valida nende kahe hüpoteesi vahel. Selleks peame enne katse sooritamist kehtestama otsustusreeglid näiteks järgmiselt:

- a) kui daam määrab õigesti vähem kui 5 tassi, siis usaldame H_0 ;
 b) kui daam määrab õigesti 5 tassi 5-st, siis usaldame H_1 .

Mõlemal juhul võib otsus olla vale. Puhta õnne korral võib daam viis korda järjest õigesti ära arvata, isegi kui $p = 0,5$, mis tähendab, et lükkame tagasi H_0 , isegi kui see on õige. Sellist tüüpi vea tegemise tõenäosust tähistatakse sageli α .

Ja isegi kui daam tunneb erinevust (näiteks, isegi kui tal on õigete otsuste tegemise tõenäosus 0,8), võib ta teha aegajalt vigu. Ta võib õigesti arvata näiteks 4 korral ja 1 korral eksida, mis tähendab otsustamise reegli järgi, et ei tohi usaldada H_1 , ehkki ta on õige. Tähistame seda liiki vea tegemise tõenäosuse β -ga.

Katse võimalikud tulemused on:


	Võetakse vastu H_0	Võetakse vastu H_1
Kehtib H_0	Korrektne otsus. Tõenäosus = $1 - \alpha$	"Esimest liiki viga" Tõenäosus = α
Kehtib H_1	"Teist liiki viga" Tõenäosus = β	Korrektne otsus. Tõenäosus = $1 - \beta$

Praktikas on kogetud, et esimest liiki viga on raskemate tagajärgedega kui teist liiki viga. Seetõttu valitakse otsuse langetamiseks kriitiline piir nii, et esimest liiki vea tegemise tõenäosus ei ületaks meie valitud tõket. Uurija poolt kehtestatud tõket nimetatakse olulisuse nivooks, mida tähistatakse α -ga. Teist liiki vea tõenäosus on $\beta \leq 1 - \alpha$. Testi olulisuse nivoo väärtus määratakse, lähtudes konkreetsest ülesande sisust. Sagedamini kasutatakse väärtusi 0,1; 0,05 ja 0,01. Mida väiksem on olulisuse nivoo, seda rangem on kriteerium ning seda raskem on sisukat hüpoteesi tõestada.

Meie näites $\alpha = 0,5^5 = 0,031$.

Kui näiteks $p = 0,75$, siis $\beta = P(x < 5) = 1 - P(x = 5) = 1 - 0,75^5 = 0,763$.

Sageli nimetatakse $1 - \beta$ testi võimsuseks. Võimsus (samuti ka β) näitab, kui vale on H_0 . On võimalik teha võimsuse graafik, niinimetatud võimsuse funktsioon, mis näitab, kuidas $(1 - \beta)$ sõltub p õigest väärtusest:



6.2 Hüpoteesid üldkogmi keskväärtuse kohta

Sissejuhatav näide. Instrumenti kasutati viiel erineval korral, et määrata laktoosi taset lahuses. Saadi järgmised tulemused:

3,4 3,3 3,1 2,9 3,4.

Instrumenti tööjuhis lubab mõõtmisviga dispersiooniga $s^2 = 0,05$. Nüüd väidab ettevõtja, et lahus, mida parajasti analüüsiti, on standardlahus, millel on teada õige laktoosi sisaldus $\mu = 3,0$. Kui instrument näitab süstemaatilist kõrvalekallet sellest väärtusest, vajab seade kordaseadmist. Kas instrument vajab kordaseadmist?

Püstitame hüpoteesid:

$H_0 : \mu = 3,0$ (nullhüpotees) üldkogumi keskväärtus on 3,

$H_1 : \mu \neq 3,0$ (sisukas hüpotees).

Hüpoteeside kontrollimiseks kasutatakse statistikut, mis on valimi keskväärtuse \bar{X} ja standardse väärtuse μ_0 normeeritud vahe Z , kus $Z = \frac{\bar{X} - \mu_0}{\sqrt{\frac{\sigma^2}{n}}}$. Kui H_0 on õige, siis Z jaotus peab olema standardiseeritud normaaljaotus, st $Z \sim N(0,1)$. μ_0 on μ väärtus vastavalt nullhüpoteesile. Kaks hüpoteesi on õiged, kui kehtivad järgmised eeldused:


1. Jaotus peab olema normaaljaotus.

See kehtib, kui x jaotus on normaaljaotus (sõltumata valimi mahust n) või x jaotus läheneb normaaljaotusele ja n on mõistlikult suur (vastavalt tsentraalsele piirteoreemile).

2. Valimis peavad olema vaatlused vastastikku sõltumatud. See on tagatud, kui on moodustatud juhuslik valim.

Nende kahe eelduse põhjal võime püstitada järgmise otsustusreegli. Arvutame z väärtuse. Kui z on arvuliselt suur, siis kummutame H_0 . Vastasel juhul jääme H_0 juurde. Reegel põhineb väitel, et on vähetõenäoline saada z -i suurt väärtust, kui H_0 on õige. Seega kaotame usu H_0 suhtes, kui z on arvuliselt suur.

Mida peaksime mõistma "suure" või "väikese" z -i väärtuse all? Näiteks võime valida H_0 kummutamiseks piirid, mis vastavad 5% tõenäosusele, seega olulisuse nivoo α on 0,05.



Järelikult võime otsustuse reegli põhjal öelda:

kui $z < -1,96$, loeme H_1 tõestatuks;

kui $z > 1,96$, loeme samuti H_1 tõestatuks;

kui z on vahemikus $-1,96 \leq z \leq 1,96$ jääme H_0 juurde.


Kasutades seda otsustusreeglit, on risk teha "esimest liiki viga" $\alpha = 0,05$, st lükata tagasi H_0 , kuigi H_0 on õige.

Meie andmete korral arvutame statistiku Z väärtuse $z = \frac{\bar{X} - \mu_0}{\sqrt{\frac{\sigma^2}{n}}} = \frac{3,22 - 3,0}{\sqrt{\frac{0,05}{5}}} = 2,20$

Kui $z > 1,96$, siis ütleme, et tulemus on oluline, ning kummutame H_0 . Me ei usu enam, et $\mu = 3$. Sisukat hüpoteesi vastu võttes teeme esimest liiki vea, eksimise risk ei ole suurem kui 5%. Kuna sisuka hüpoteesi vastuvõtmisega kaasnev risk on meie poolt ette määratud, loetakse sisukas hüpotees tõestatuks.

6.3 Testi p (tõenäosus-)väärtus

Selle asemel, et kummutada H_0 määratud z piiride korral, võime kasutades normaaljaotuse tabelit arvutada, kui tõenäoline on vaadeldav z väärtus. Sealt leiame, et $P(z > 2,20) = 0,0139$ ja $P(z < -2,20) = 0,0139$. Kokkuvõttes oleme saanud tulemuse, kus tõenäosus on $0,0139 + 0,0139 = 0,0278$, kui H_0 on õige. Seda nimetatakse p -väärtuseks. "Tõenäosus saada tulemust valimis, kui H_0 on õige, on 0,0278"



Mõnel juhul on p väärtust raskem arvutada kui anda ainult olulisuse nivoo. Aga arvutiprogrammid saavad p väärtuse arvutamise ja esitamise kergelt hakkama. Järgnev on programmipaketi Minitab analüüs meie näite andmete põhjal:

Z-Test

Test of $\mu = 3.000$ vs $\mu \text{ not} = 3.000$
The assumed sigma = 0.224

Variable	N	Mean	StDev	SE Mean	Z	P-Value
X	5	3.220	0.217	0.100	2.20	0.028

6.3.1 "Tähe süsteem"

Teaduslikes publikatsioonides on vaja avaldada p väärtust iga kord, kui olulisuse test on tehtud. Siis võib lugeja otsustada, missugune tulemus vastab tema olulisuse nivoole. "Test näitab, et keskvärtus ei ole 3,0 ($p=0,028$)" On kasulik mees pidada järgnevat süsteemi:

Kui $p > 0,05$, siis tulemus on "mitte oluline"

Kui $0,01 < p \leq 0,05$, siis tulemus on "oluline 5% tasemel", märgitakse *

Kui $0,001 < p \leq 0,01$, siis tulemus on "oluline 1% tasemel", märgitakse **

Kui $p \leq 0,001$, siis tulemus on "oluline 0,1% tasemel", märgitakse ***

Paljud toimetajad ja retsensendid tõrguvad tunnistamast väljendeid nagu: "oluline 9% tasemel", "peaaegu oluline" jne. 5% tase on muutunud standardiks, kui nimetame midagi "oluliseks"


6.4 Ühepoolsed alternatiivsed hüpoteesid

Mõnel juhul oleme huvitatud ainult erilistes suundades erinevuse näitamisest. Näiteks võime demonstreerida, et uue toiduratsiooni kasutamine annab suuremat kaalu kasvu kui mingi varajasem või öelda, et kindel keskvärtus on suurem kui 3,0. Need on ühepoolsed hüpoteesid. Oletame, et meie näites võib olla μ suurem kui 3. Selle uurimiseks püstitame järgmised hüpoteesid:

$H_0: \mu = 3,0$ (samuti võime kirjutada $H_0: \mu \leq 3,0$; tähtis on, et H_0 sisaldaks võrdusmärki),

$H_1: \mu > 3,0$.

Sel korral peaksime H_0 -i kummutama vaid juhul, kui z väärtus on suur:



Normaaljaotuse tabeli põhjal näeme, et H_0 -i peaks tagasi lükkama olulisusnivoo $\alpha = 0,05$ korral, kui $z > 1,645$. Arvutatud z -i väärtus on $z = 2,20$. Kuna see on suurem kui piir 1,645, on tulemus oluline ja kummutame H_0 .

Alternatiivselt võime arvutada p väärtuse. See on $P(z > 2,20) = 0,0139$.

6.5 Hüpoteesi kontrollimine, kui σ on teadmata

Sissejuhatav näide.

Instrumenti kasutati viiel erineval korral, et määrata laktoosi taset lahuses. Saadi järgmised tulemused:

3,4 3,3 3,1 2,9 3,4.

Ettevõtja väidab, et lahus, mida parajasti analüüsiti, on standardlahus, millel on teada laktoosi õige sisaldus $\mu = 3,0$. Kui instrument näitab süstemaatilist kõrvalekallet sellest väärtusest, on vaja seade korda seada. Vajab instrument seda?

Püstitame oma hüpoteesid:

$$H_0 : \mu = 3,0,$$

$$H_1 : \mu \neq 3,0.$$

Kuna me ei tea populatsiooni dispersiooni σ^2 , kasutame sama ideed nagu usalduspiiride korral. Kasutame tõsiasja, et $t = \frac{\bar{x} - \mu_0}{\sqrt{\frac{s^2}{n}}}$ järgib t -jaotust ($n - 1$) vabadusastmega, samadel eeldustel kui vastavate usaldusvahemike juhul. Kahepoolse testi korral näeme t -jaotuse tabelist ($\alpha = 0,05$), et peame H_0 tagasi lükkama, kui $t > 2,776$ või $t < -2,776$. Meie andmete korral $s^2 = 0,047$, nii saame $t = \frac{3,22 - 3,0}{\sqrt{\frac{0,047}{5}}} = 2,269$. Kuna vaadeldav t väärtus on väiksem kui piir 2,776, siis jõuame järeldusele, et tulemus ei ole oluline ja jääme H_0 juurde.

Meie t -jaotuse tabel ei ole küllalt täiuslik, et leida t -jaotuse testi põhjal p väärtusi. Analüüsi tegemiseks on mõistlik kasutada mõnda arvutiprogrammi, p väärtus arvutatakse siis järgmiselt:

T-Test of the Mean

Test of mu = 3.0000 vs mu not = 3.0000

Variable	N	Mean	StDev	SE Mean	T	P-Value
X	5	3.2200	0.2168	0.0970	2.27	0.086

Kui alternatiivne hüpotees on ühepoolne, siis tulemus peab olema oluline ($p = 0,043$).

Märkused.

1. Isegi kui oleme suutnud näidata, et miski "on oluline", ei tähenda see, et oleme absoluutselt veendunud, et H_0 on vale. On risk (α), et me eksime.

2. Isegi kui oleme suutnud näidata, et "ei ole oluline", ei tähenda see, et H_0 on õige. Isegi siin on risk (β), et järeldus on vale. β võib olla üsna suur, eriti kui valim on väike.

Parameeter; hüpotees	Punkthinnang	Test statistik	Eeldused, kommentaarisid
$H_0: \Theta = \Theta_0$	$\hat{\Theta}$	$\begin{cases} t \\ \text{või} \\ z \end{cases} = \frac{\hat{\Theta} - \Theta_0}{\sqrt{D(\hat{\Theta})}}$	z kui populatsioonis on $D(\hat{\Theta})$ teada, mis on praktikas ebatavaline; z kasutame lähendina, kui $D(\hat{\Theta})$ on hinnatud valimist ja valim on suur; t kui $D(\hat{\Theta})$ on teadmata ja on hinnatud valimist.

Testid põhinevad normaaljaotusel. (Vaata eraldi lehte erinevate võimaluste kohta raamatu lõpus.)

6.6 Ülesanne

6.1

Juhuslik valim koosneb 10-st ülikooli meesõppejõust. Nendel mõõdeti kolesterooli taset veres ja saadi järgmised tulemused (grammi liitri kohta):

3,0 1,8 2,1 1,4 2,5 1,6 1,9 2,8 2,2 2,7.

Üldises meeste populatsioonis kolesterooli keskmine tase on 2,0. Kontrolli hüpoteesi, et ülikooli meesõppejõudude populatsiooni kolesterooli keskväärts on 2,0.

Peatükk 7

Osade suhe tervikusse - järelused

7.1 Tõenäosuse p usalduspiirid

Sissejuhatav näide. Hääletajatest on moodustatud juhuslik valim, kus $n = 1000$. Nendest 350 (35%) teatasid, et nad hääletaksid sotsiaaldemokraatide poolt, kui hääletus toimuks täna. Kui ebakindel on see väide, st missugune on piiri viga?

Parameeter, mida soovime hinnata, on p . See on sotsiaaldemokraatide poolt hääletajate suhe kõikide hääletajate hulgast. Tõenäosuse p hinnanguks on selle suhteline sagedus $\hat{p} = \frac{350}{1000} = 0,35$. Olgu valimis hääletajate arv x . Elementide väärtused valimis on kas "0" või "1", sest nad on poolt või ei ole. Seega x (ja seepärast samuti $\hat{p} = x/n$) on binoomjaotusega juhuslik suurus (vaata peatükk 4). Kuna meil on suur valim, siis binoomjaotusega juhusliku suuruse jaotus läheneb normaaljaotusele (piirteoreemi põhjal). Erinevates õpikutes on erinevad hinnangud, mida nimetame "suureks valimiks". Sageli on rusikareegel, et nii np kui ka $n(1 - p)$ peavad olema suuremad kui 10. Mõned õpikud ütlevad isegi, et nad peavad olema suuremad kui 5. Sama reeglit kasutatakse juhul, kui p on teadmata. Tema asemel kasutame siis tõenäosuse p hinnangut \hat{p} . Meie näites on $n\hat{p} = 350$ ja $n(1 - \hat{p}) = 650$, mis on kindlasti normaaljaotusele lähendamiseks küllaldane.

Kui lisame eelduse, et vaatlused on sõltumatud (mis järeldeb juhuslikust valikust), võime kasutada käsitletud usalduspiiride leidmise üldist reeglit. See on:

(Parameeter) = (Hinnang) \pm t või z Hinnangu standardviga

$$\theta = \hat{\theta} \pm t \text{ või } z \sqrt{D(\hat{\theta})}$$

Parameeter on p ja selle parameetri hinnang on \hat{p} . On vaja teada \hat{p} dispersiooni. Võib näidata, et $D(\hat{p}) = \frac{p(1-p)}{n}$. Probleemiks on, et valem sisaldab tundmatut p väärtust. Paneme lihtsalt \hat{p} selle asemele ja saame dispersioonile mõistliku lähendi $D(\hat{p}) \approx \frac{\hat{p}(1-\hat{p})}{n}$. Järelikult võime tõenäosuse p usalduspiiride valemi kirjutada järgmiselt:

$$\hat{p} \pm z \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$$

Eelnev valem on seotud tõsiasjaga, et meil on suur valim: siis võib \hat{p} jaotust lähendada normaaljaotusele ning võime kasutada valemis z -i.

Sissejuhatava näite andmeid ja normaaljaotuse z väärtust $z = 1,96$ (95%-le vastav vahemik) kasutades saame $0,8 \pm 1,96 \sqrt{\frac{0,8(1-0,8)}{100}}$, st $0,35 \pm 0,0296$. Saadud tulemuse põhjal võime 95 juhul sajast öelda, et tegelik tõenäosuse protsent asub vahemikus (0,32; 0,38). "Piiri viga" on umbes 3%, st kui kasutame valimi põhjal saadud hinnangut 35%, pole tehtud viga 95 juhul sajast suurem kui 3%.

7.1.1 Kui suur valim on vajalik tõenäosuse p usalduspiiride leidmiseks?

Kui suurt valimit vajame sotsiaaldemokraatide poolt hääletajate suhte leidmiseks tõenäosusega p 95%-liste usalduspiiride jaoks eeldusel, et usaldusvahemik oleks lühem kui 0,02?

Eelpool arvasime tõenäosuse p 95% usalduspiirid valemiga $\hat{p} \pm z \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$ Saime tulemuse $0,35 \pm 0,03$. Kui soovime leida piire, mis oleksid lühemad kui 0,02, siis eeldame, et tõenäosus p on ligikaudu sama suur kui varem. Saame $1,96 \sqrt{\frac{0,35(1-0,35)}{n}} \leq 0,05$. Leiame lahendi n jaoks: $n \geq \frac{1,96^2 \cdot 0,35 \cdot (1-0,35)}{0,05^2} = 2184,91$ Järelikult antud tingimuste korral vajame valimisse vähemalt 2185 hääletajat.

Selles arvutuses kasutasime vana andmestiku väärtust $\hat{p} = 0,35$. Kerkib küsimus: mida teeme siis, kui meil ei ole ühtegi vastavat vana andmestikku. Tegelikult on võimalik arvutada nõutav valimi suurus ka juhul, kui pole teada p (või \hat{p}). Kehtib, et $\frac{p(1-p)}{n}$ suurim väärtus $p = 0,5$. Kasutades seda väärtust, saame kindlasti valimimahu, mis ei olegi nii väike. Kasutame seda

meie näites, saame $n \geq \frac{1,96^2 \cdot 0,5 \cdot (1-0,5)}{0,05^2} = 2401$. Kui moodustame valimi üle 2400 hääletajaga, on vea piir väiksem kui 0,02 hoolimata hääletajate õigest suhtest.

7.2 Hüpoteesi $H_0 : p = p_0$ kontrollimine

Sissejuhatav näide. Ostsime koti seemneid, mille idanevus oli 90%. Selle kontrollimiseks moodustasime juhusliku valimi $n = 200$ seemnest, millest $x = 166$ seemet idanes.

Soovime kontrollida hüpoteese:

$$H_0: p = 0,90,$$

$$H_1: p \neq 0,90.$$

Soovime teha järeldusi parameetri p kohta, mis on tõenäosus selleks, et juhuslikult valitud seeme idaneb. Tõenäosuse p parim hinnang on $\hat{p} = \frac{x}{n} = \frac{166}{200} = 0,83$. Kui vaatlused on sõltumatud, siis x (ja samuti \hat{p}) järgib binoomjaotust, aga kuna meie "rusikareegel" on rahuldatud, siis võime jaotust normaaljaotusega lähendada. Sel juhul $n p_0 = 180$ ja $n(1 - p_0) = 20$. Mõlemad on suuremad kui 10, seega võime kasutada $Z = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$, mis on (ligikaudu) standardnormaaljaotus.

Märkused. Kasutame p_0 väärtust (nullhüpoteesist) murru nimetajas, sest usume H_0 kehtivust seni, kuni (kuidagi) tõestame, et ta on väär. Kui kasutada sama normaaljaotuse lähendit usalduspiiride leidmisel, siis kasutame seda hinnangu \hat{p} asemel lugejas.

Kahepoolse testi korral, kui olulisuse nivoo on 5%, kummutame H_0 , kui $|z| > 1,96$. Kui me valime testi 1%-lise olulisuse nivoo, siis vastavad piirid on $|z| > 2,576$. Meie näites saame $z = \frac{0,83 - 0,9}{\sqrt{\frac{0,9 \cdot 0,1}{200}}} = -3,30$. Saadud tulemus on oluline mõlemal juhul, 5% tasemel ja 1% tasemel. Võtame vastu sisuka hüpoteesi H_1 . p väärtus (kahepoolse testi puhul) on $p = 2 \cdot 0,0005 = 0,001$. Tulemus on koguni "****" tähtsusega.

7.3 $(p_A - p_B)$ usalduspiirid

Sissejuhatav näide. On tehtud katse, selgitamaks kahe erineva pestitsiidi mõju lutikatele. 200 lutikat töödeldi pestitsiidiga A ja 180 lutikat samal ajal pestitsiidiga B. Lutikatest, keda töödeldi A-ga, suri 140 ja teistest, keda

töödeldi B-ga, suri 100. Tähistame lutikate surmatõenäosused, vastavalt p_A ja p_B . Arvuta ja interpreteeri 95%-lised $(p_A - p_B)$ usalduspiirid.

Parameeter, mille kohta soovime järeldusi teha, on $p_A - p_B$. Mõistlik hinnang on $\hat{p}_A - \hat{p}_B$. Selleks, et saaks kasutada usalduspiiride standardset meetodit, peame teadma:

1. Missugune on $\hat{p}_A - \hat{p}_B$ jaotus?

Hinnangu avaldises mõlemad (st \hat{p}_A ja \hat{p}_B) järgivad binoomjaotust. Eespool näitasime, et binoomjaotust võime lähendada normaaljaotusele, kui n on suur, nagu see hetkel ongi. Niisiis, kui eeldame, et iga \hat{p}_A ja \hat{p}_B järgib normaaljaotust (vähemalt ligikaudu), siis ka $\hat{p}_A - \hat{p}_B$ jaotus järgib ligikaudu normaaljaotust. Normaaljaotusega muutujate summad ja vahed on samuti normaaljaotusega.

2. Missugune on $\hat{p}_A - \hat{p}_B$ dispersioon?

Kehtib $D(\hat{p}_A - \hat{p}_B) = D(\hat{p}_A) + D(\hat{p}_B)$, kui \hat{p}_A ja \hat{p}_B on sõltumatud. Järelikult, $D(\hat{p}_A - \hat{p}_B) = D(\hat{p}_A) + D(\hat{p}_B) = \frac{p_A(1-p_A)}{n_A} + \frac{p_B(1-p_B)}{n_B}$. Me ei tea p_A ja p_B . Peame tegema teise lähendi: kasutama hinnanguid \hat{p}_A ja \hat{p}_B dispersiooni avaldises, siis saame dispersiooni hinnangu: $\hat{D}(\hat{p}_A - \hat{p}_B) = \frac{\hat{p}_A(1-\hat{p}_A)}{n_A} + \frac{\hat{p}_B(1-\hat{p}_B)}{n_B}$

Usalduspiirid võib nüüd kirjutada järgmiselt

$$\hat{p}_A - \hat{p}_B \pm z \sqrt{\frac{\hat{p}_A(1-\hat{p}_A)}{n_A} + \frac{\hat{p}_B(1-\hat{p}_B)}{n_B}}$$

Kasutame sissejuhatava näite andmeid $\hat{p}_A = 140/200 = 0,7$ ja $\hat{p}_B = 100/180 = 0,56$. 99%-lised usalduspiirid võib arvutada valemist

$0,70 - 0,56 \pm 2,576 \sqrt{\frac{0,70 \cdot 0,30}{200} + \frac{0,56 \cdot 0,44}{180}}$, millest saame $0,14 \pm 0,127$. Oleme 99 juhul sajast veendunud, et vahemik $(0,013; 0,267)$ sisaldab õiget $p_A - p_B$ väärtust. Kuna vahemik ei sisalda väärtust 0, siis see tähendab, et kahel töötlusel on lutikatele erinev mõju.

7.4 Hüpoteesi $H_0: p_A = p_B$ kontrollimine

Sissejuhatav näide. Tehti katse, kus võrreldi kahe erineva pestitsiidi mõju lutikatele. 200 lutikat töödeldi pestitsiidiga A ja 180 lutikat pestitsiidiga B. Lutikatest, keda töödeldi A-ga, suri 140 ja lutikatest, keda töödeldi B-ga, suri 100. Kontrollime hüpoteesi $H_0: p_A = p_B$.

Situatsioon on sarnane usalduspiiride leidmisega. Soovime teha järeldust parameetri $p_A - p_B$ kohta. Hinnangu $\hat{p}_A - \hat{p}_B$ jaotust võib lähendada nor-

maaljaotusega, kui valim on suur. Dispersiooni avaldis hinnangule $\hat{p}_A - \hat{p}_B$ on: $D(\hat{p}_A - \hat{p}_B) = D(\hat{p}_A) + D(\hat{p}_B) = \frac{p_A(1-p_A)}{n_A} + \frac{p_B(1-p_B)}{n_B}$. Eelpool dispersiooni avaldises usalduspiiride arvutamisel lihtsalt asendasime p_A ja p_B vastavalt \hat{p}_A ja \hat{p}_B . Selline lähenemine töötab üsna hästi testide jaoks, aga hüpoteeside kontrollimisel on võimalik leida veel parem hinnang.

Kui kontrollime hüpoteesi, siis kasutame teststatistikut eeldusel, et nullhüpotees on õige. Sel juhul võime eeldada, et $p_A = p_B = p$, kuni oleme veendunud, et see on vale. Kui H_0 on õige, siis võime leida parima p hinnangu, mis saadakse kombineerides andmeid kahest valimist ühte hinnangusse: $\hat{p}_0 = \frac{n_A \hat{p}_A + n_B \hat{p}_B}{n_A + n_B}$ (see on surnud lutikate summaarne arv jagatud lutikate kogu arvuga). Asendame dispersiooni avaldises \hat{p}_A ja \hat{p}_B \hat{p}_0 -ga, saame $\hat{D}(\hat{p}_A - \hat{p}_B) = \frac{\hat{p}_0(1-\hat{p}_0)}{n_A} + \frac{\hat{p}_0(1-\hat{p}_0)}{n_B} = \hat{p}_0(1-\hat{p}_0) \left(\frac{1}{n_A} + \frac{1}{n_B} \right)$. Hüpoteesi H_0 kontrollimiseks arvutame $z = \frac{\hat{p}_A - \hat{p}_B}{\sqrt{\hat{p}_0(1-\hat{p}_0) \left(\frac{1}{n_A} + \frac{1}{n_B} \right)}}$ ja lükkame H_0 tagasi valitud usaldusnivoo juures, kui z on väljaspool kriitilise väärtuse piire.

Meie näite korral $\hat{p}_0 = \frac{140+100}{200+180} = 0,63$. Teststatistik on $z = \frac{0,70-0,56}{\sqrt{0,63(1-0,63) \left(\frac{1}{200} + \frac{1}{180} \right)}} = 2,91$. See on väljaspool 5%-lisi piire (1,96), väljaspool 1%-lisi piire (2,576), aga seespool 0,1%-lisi piire (3,291). p väärtus on 0,0036. Tulemus on "***" tähtsusega, mis näitab kahe pestitsiidi efektiivsuse erinevust.

7.5 Ülesanded

7.1

Uusim saavutus akne ravimiseks on ravim, mida kutsutakse “retinoidhape”. Testis uuriti selle ravimi mõju 20 patsiendil, kellel oli äge akne. 20-st testitud patsiendist 14-l märgati ravimi kasutamisel paranemist.

Küsimused:

A. Arvuta 99%-lised tõenäosuse p usalduspiirid, st ravimit tarvivate paranevate patsientide suhe üldkogumis. Samuti selgita oma arvutuste aluseks olevaid oletusi.

B. Arvatakse, et usalduspiirid ülesandes A on liiga laiad. Seetõttu planeeri uus katse. Selles peaks valimi maht n olema nii suur, et 95%-lise tõenäosuse p usalduspiiride laius oleks väiksem kui 0,1. Leia valimi maht n .

Peatükk 8

Kahe keskväärtuse võrdlemine

8.1 Sissejuhatus

Sagedane probleem bioloogilise andmestiku uurimisel on kahe keskväärtuse võrdlemine. Mõned näited: eksperimentaalne grupp koos kontrollgrupiga, ühe nisu sordi saagi võrdlemine mõne teise nisusordi saagiga, patsiendi vere-rõhu näitaja võrdlemine enne ja peale ravikuuri. Parameeter, mida niisuguste näidete korral soovime uurida, on $\mu_1 - \mu_2$. Kasutatavate meetodite valik sõltub seejuures sellest, mil viisil on andmed kogutud. Põhimõtteliselt võime eristada kahte olukorda:

1. Paarikaupa andmed

Paarikaupa andmed tähendavad seda, et andmestiku väärtused kuuluvad paarikaupa kokku ("plokid"). Mõned näited:

- Ühel ja samal indiviidil tehti üks mõõtmine (x) enne ravimist, teine mõõtmine (y) peale ravimist.
- Ühel ja samal isikul tehti mõõtmised vasakul käel (x) ja paremal käel (y).
- 20-st katseloomast moodustati 10 paari. Iga paari loomad olid ühe ema järglased.
- 10 erinevat põldu jagati kahte ossa. Igal põllul kasvatati liiki A ühel osal ja liiki B teisel osal.

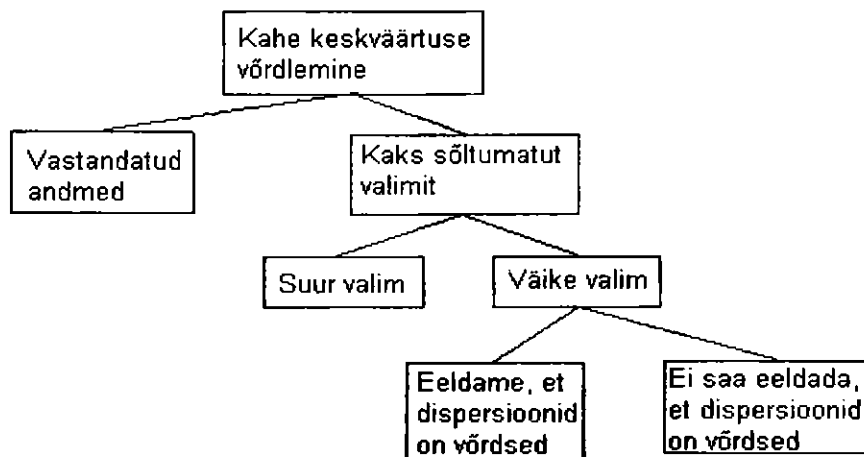
2. Kaks sõltumatut gruppi

Katseühikute rühmitamine on sel juhul tehtud täiesti juhuslikult. Mõned näited:

- Liiki A kasvatati 10-l põllul, liiki B 10-l teisel põllul.

- 10 katselooma on juhuslikult määratud sööma sööta A, 10 teist looma söövad sööta B.

Kui tegemist on kahe sõltumatu grupiga, siis võib andmeanalüüsi jagada alajaotusteks. Järgmisel skeemil esitame kokkuvõtvalt erinevad võimalused:



8.2 Usalduspiirid ja hüpoteesid $\mu_1 - \mu_2$ korral

8.2.1 Paarikaupa andmed

Sissejuhatav näide. 1. peatükis vaatlesime andmestikku, mis oli avaldatud Charles Darwini poolt 1876. aastal. Darwin püüdis näidata, et taimed, mida paljundati risttolmeldamise teel, olid kiirema kasvuga kui taimed, mida paljundati isetolmeldamise teel. Darwin tegi taimepaaridega katse, kus igast paarist üks oli isetolmeldatud ja teine oli risttolmeldatud. Kõiki taimepaare kasvatati koos ühesugustes tingimustes. Sageli on see hea katseplaan, sageli viitab plokk katseplaanile.

Taimepaaride kõrgused (tollides) on esitatud järgmises tabelis:

Paari nr	x_k risttolmeldatud	x_s isetolmeldatud	$d = x_k - x_s$
1	23,5	17,4	6,1
2	12,0	20,4	-8,4
3	21,0	20,0	1,0
4	22,0	20,0	2,0
5	19,1	18,4	0,7
6	21,5	18,6	2,9
7	22,1	18,6	3,5
8	20,4	15,3	5,1
9	18,3	16,5	1,8
10	21,6	18,0	3,6
11	23,3	16,3	7,0
12	21,0	18,0	3,0
13	22,1	12,8	9,3
14	23,0	15,5	7,5
15	12,0	18,0	-6,0

Kas Darwini väide oli õige? Sellele küsimusele võime vastata, kui arvutame ja interpreteerime usalduspiirid kahe keskväärtuse erinevusele ($\mu_k - \mu_s$) või kontrollime hüpoteesi $H_0: \mu_k - \mu_s = 0$. See on sama, kui teha järeldus iga paari x_k ja x_s vahelise erinevuse d jaoks.

d keskväärtus on $\bar{d} = \frac{39,1}{15} = 2,607$ ja dispersioon $s_d^2 = \frac{\sum d^2 - \frac{(\sum d)^2}{n}}{(n-1)} = \frac{412,9 - \frac{39,1^2}{15}}{14} = 22,21$.

Meie parameeter on $\mu_k - \mu_s = \mu_d$, kus μ_d tähendab üldkogumi paarikaupa väärtuste erinevuse d keskväärtust. Kontrollime hüpoteesi, et kahel erinevalt paljundatud taimel on võrdne keskmine kõrgus. Võime kontrollida kahepoolset hüpoteesi:

$$H_0: \mu_d = 0,$$

$$H_1: \mu_d \neq 0;$$

või kontrollida ühepoolset hüpoteesi:

$$H_1: \mu_d > 0 \text{ (või } H_1: \mu_d < 0).$$

Hüpoteesi valik sõltub küsimusest, aga mitte andmestikust. Antud juhul võib olla eelistatud ühepoolne hüpotees. Darwin soovis näidata, et risttolmeldatud taimed on kõrgemad. Hüpoteesi kontrollimiseks arvutame t -statistiku $t = \frac{\bar{d} - 0}{\sqrt{\frac{s_d^2}{n}}} = \frac{2,607}{\sqrt{\frac{22,21}{15}}} = 2,142$. Kahepoolse t -test korral on piirid $\pm 2,145$, kui

olulisuse nivoo $\alpha = 0,05$ ja vabadusastmed on $(n - 1) = 14$. Hetkel on arvutatud t väärtus just nende piiride vahel. Vastav ühepoolne piir on 1,761.

Järelikult hüpoteesi H_1 võib lugeda tõestatuks ka ühepoolse testi põhjal. Minitabi väljatrükist loeme välja sama järelduse.

T-Test of the Mean

Test of mu = 0.0000 vs mu > 0.0000

Variable	N	Mean	StDev	SE Mean	T	P
D	15	2.61	4.71	1.22	2.14	0.025

Järelikult võime toetada Darwini väidet, et risttolmeldatud taimed on keskmiselt kõrgemad kui isetolmeldatud taimed.

Võime arvutada ka μ_d usalduspiirid. Illustratsiooniks leiame kahepoolsed piirid. Arvutame usaldusvahemiku $2,607 \pm t_{0,975;14} \sqrt{\frac{22,21}{15}}$; $2,607 \pm 2,61$; (0,00; 5,22). Sama tulemust näeme järgnevas Minitab'i väljatrükis:

Confidence Intervals

Variable	N	Mean	StDev	SE Mean	95.0 % CI
D	15	2.61	4.71	1.22	(-0.00, 5.22)

Siin on usalduspiirid kahepoolsed, nad vastavad kahepoolsele testile. Näeme, et usaldusvahemik sisaldab väärtust 0, mille põhjal võime järeldada, et erinevus kahe grupi vahel ei ole oluline.

8.2.2 Sõltumatud valimid

Oletame, et soovime võrrelda kahe töötuse keskväärtusi. Katseplaan on randomiseeritud (vt ptk 9) st ei ole kasutatud andmete sobitamist, mis tähendab, et katse ühikud on juhuslikult määratud kahele töötusele.

Soovime teha otsustusi parameetri $\mu_1 - \mu_2$ kohta. Kasutame valimi keskmiste erinevust $\bar{x}_1 - \bar{x}_2$ kui hinnangut $\mu_1 - \mu_2$ kohta. Kehtib $E(\bar{x}_1 - \bar{x}_2) = \mu_1 - \mu_2$. Järelikult meie hinnang on nihketa. Usalduspiiride leidmiseks ja hüpoteeside kontrollimiseks vajame dispersiooni hinnangut ning hinnangu jaotust.

Dispersiooni jaoks kehtib $D(\bar{x}_1 - \bar{x}_2) = 1^2 D(\bar{x}_1) + (-1)^2 D(\bar{x}_2) =$
(eeldades sõltumatust rühmade vahel)

$$= \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2} \text{ (eeldades sõltumatust rühmade sees).}$$

Kui üldkogumid on mõlemas grupis normaaljaotusega, siis ka vastavad keskvaartused \bar{x}_1 ja \bar{x}_2 on normaaljaotusega, st meie hinnang $\bar{x}_1 - \bar{x}_2$ järgib normaaljaotust. Kui üldkogumid ei ole normaaljaotusega, siis suurte valimite korral hinnangu $\bar{x}_1 - \bar{x}_2$ jaotus on lähendatud normaaljaotusele. See järeldub tsentraalsest piirteoreemist. Missugust valimit peaksime vaatlema suure valimina, on otsustuse asi.

Kui dispersioon on teada ning kasutame normaaljaotust, võime arvutada $\mu_1 - \mu_2$ usalduspiirid

$$\begin{aligned} \underline{\mu_1 - \mu_2} &= (\bar{x}_1 - \bar{x}_2) - z \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}, \\ \overline{\mu_1 - \mu_2} &= (\bar{x}_1 - \bar{x}_2) + z \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \end{aligned}$$

Samal viisil võime kontrollida hüpoteesi $H_0 : \mu_1 - \mu_2 = 0$, arvutades $z = \frac{(\bar{x}_1 - \bar{x}_2) - 0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$. Tegelikus elus me ei tea üldkogumi dispersiooni. Lahendame selle probleemi kahel viisil. Lihtsam lahendus on see, kui eeldame, et üldkogumi dispersioonid on võrdsed.

8.2.3 Võrdsed dispersioonid, väike valim

Näide. Võrreldi kahte erinevalt toidetud pullide rühma. 8 looma jaotati nii, et nendest 4 said sööta A ja 4 said sööta B. Märgiti üles kaalu juurdekasv:

sööt 1	sööt 2
330	290
360	320
400	340
350	370

Selle andmestiku põhjal saame arvutada hetkel vajalikud valimi statistikud:

sööt 1: $n_1 = 4$; $\bar{x}_1 = 360$; $s_1 = 29,44$,

sööt 2: $n_2 = 4$; $\bar{x}_2 = 330$; $s_2 = 33,67$

Meid huvitav parameeter on $\mu_1 - \mu_2$, mis näitab kaalu juurdekasvu keskmist erinevust. Selle parameetri hinnang on $\bar{x}_1 - \bar{x}_2$ ning hinnangu dispersioon on

$$D(\bar{x}_1 - \bar{x}_2) = D(\bar{x}_1) + D(\bar{x}_2) = \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$$

Paljudel juhtudel on sobiv eeldada, et dispersioonid on võrdsed ning ei sõltu tööstusest. Dispersioon võib kirjeldada näiteks loomulikku juhuslikku varieeruvust loomade vahel, mis ei ole mõjutatud sööda tüübist. On ka kindel tehniline põhjus võrdse dispersiooni eeldamiseks. Näeme, et siis on võimalik üsna lihtsal viisil leida dispersiooni hinnangu vabadusastmete arvu.

Kui eeldame võrdset dispersiooni, siis vajame dispersiooni hinnangut, mis on mõlemal rühmitaval tunnusel ühine. Dispersiooni tähistame σ^2 . Eeldame, et $\sigma_1^2 = \sigma_2^2 = \sigma^2$. Saab näidata, et dispersiooni σ^2 hinnang on $\hat{\sigma}^2 = \frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}$, kus vabadusastmete arv on $(n_1 + n_2 - 2)$.

Kasutades neid põhimõtteid t-testi jaoks, kontrollime hüpoteese:

$$H_0 : \mu_1 = \mu_2 \text{ (st } H_0 : \mu_1 - \mu_2 = 0),$$

$$H_1 : \mu_1 - \mu_2 \neq 0.$$

$$\text{Kasutame teststatistikut } t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\hat{\sigma}^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}, \text{ kus } \hat{\sigma}^2 = \frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}.$$

Test statistikul t on $(n_1 + n_2 - 2)$ vabadusastet.

Meie näites saame dispersiooni hinnangu $\hat{\sigma}^2 = \frac{3 \cdot 866,67 + 3 \cdot 1133,33}{4+4-2} = \frac{6000}{6} = 1000$, mille põhjal arvutame t väärtuse: $t = \frac{360 - 330}{\sqrt{1000 \left(\frac{1}{4} + \frac{1}{4} \right)}} = 1,34$. Kriitiline väärtus 6 vabadusastme juures on 2,447 (olulisuse nivoo on 5%). Järelikult oleme tõestanud H_1 . Ei saa öelda, et kaks erinevat sööta annavad keskmiselt ühesuguse kaalu juurdekasvu.

Minitabi väljatrükk selle kohta on järgmine:

Two Sample T-Test and Confidence Interval

Two sample T for Fodder A vs Fodder B			
	N	Mean	StDev SE Mean
Fodder A	4	360.0	29.4 15
Fodder B	4	330.0	33.7 17

95% C.I. for mu Fodder A - mu Fodder B: (-25, 85)

T-Test mu Fodder A = mu Fodder B (vs not =): T= 1.34 P=0.23 DF= 6

Both use Pooled StDev = 31.6

Näeme, et väljatrükk sisaldab teststatistikut ja samuti ka $\mu_1 - \mu_2$ usalduspiire. Usaldusvahemik arvutatakse valemi $\bar{x}_1 - \bar{x}_2 \pm 2,447 \sqrt{\hat{\sigma}^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}$ põhjal, kus (nagu ennegi) $\hat{\sigma}^2 = \frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}$. Arv 2,447 on 6 vabadusastmega kriitiline t väärtus 95%-liste usalduspiiride jaoks (tabeli põhjal).

8.2.4 Valim on väike ning dispersioonid ei ole võrdsed

Kui ei ole võimalik eeldada, et dispersioonid on kahes grupis võrdsed, võime kasutada lähendamist, mis on tuntud erinevate nimedega: Behrens-Fisher'i probleem, Satterwaite'i lähendamine ja teised.

Meid huvitav parameeter on ikka $\mu_1 - \mu_2$, millele kasutame hinnangut $\bar{x}_1 - \bar{x}_2$. Suure valimi korral on hinnangu dispersioon $\hat{D}(\bar{x}_1 - \bar{x}_2) = \frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}$. Selle arvutamiseks pole teada vabadusastmete arv. Saab näidata, et selle saab leida valemi $\gamma = \frac{[s_1^2/n_1 + s_2^2/n_2]^2}{\frac{[s_1^2/n_1]^2}{n_1-1} + \frac{[s_2^2/n_2]^2}{n_2-1}}$ põhjal. See on üsna komplitseeritud avaldis, aga arvutid saavad sellega lihtsalt hakkama. Kui eeldame, et valimite dispersioonid ei ole võrdsed, siis Minitab annab järgmise tulemuse:

Two Sample T-Test and Confidence Interval

Two sample T for Fodder A vs Fodder B

	N	Mean	StDev	SE Mean
Fodder A	4	360.0	29.4	15
Fodder B	4	330.0	33.7	17

95% CI for mu Fodder A - mu Fodder B: (-27, 87)

T-Test mu Fodder A = mu Fodder B (vs not =): T= 1.34 P=0.24 DF= 5

Nagu näeme, saime praegu 5 vabadusastet 6 asemel. See on hind, et loobusime võrdsete dispersioonide eeldusest. Kuid järeldused on samad, mis eespool.

8.2.5 Valimid on suured

Suure valimi korral võime kasutada lähendamist, kui soovime kiiresti otsustada, kas erinevus kahe töötamise vahel on oluline või mitte.

Sissejuhatav näide. Võrreldakse kahe erinevat tõugu põrsaste keskmist sünnikaalu. Kummastki tõust on põrsaste arv juhuslikult valitud ning nende valimite kohta on antud arvutatavad statistikud:

tõug 1: $n_1 = 61$; $\bar{x}_1 = 1,33$; $s_1 = 0,25$;

tõug 2: $n_2 = 40$; $\bar{x}_2 = 1,58$; $s_2 = 0,19$.

Parameeter, mida soovime hinnata, on $\mu_1 - \mu_2$, mis väljendab keskmist erinevust sünnikaalus. Selle parameetri hinnanguna kasutame $\bar{x}_1 - \bar{x}_2$. Kuna meil on suured valimid, võime arvata, et \bar{x}_1 ja \bar{x}_2 on ligikaudu normaaljao-

tusega, isegi kui kaalud ise ei ole normaaljaotusega. Eeldamegi, et hinnang $\bar{x}_1 - \bar{x}_2$ järgib normaaljaotust.

Esitame hinnangu dispersiooni $D(\bar{x}_1 - \bar{x}_2) = D(\bar{x}_1) + D(\bar{x}_2) = \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$. Dispersiooni hinnang on $\hat{D}(\bar{x}_1 - \bar{x}_2) = \frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}$. Me ei tea, mitu vabadusastet on haaratud sellesse dispersiooni, aga kuna valim on suur, võime lihtsalt öelda "paljud" vabadusastmed ning kasutada z -jaotust. Kontrollime hüpoteese $H_0 : \mu_1 = \mu_2$, $H_1 : \mu_1 \neq \mu_2$. Arvutame $z = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} = \frac{1,33 - 1,58}{\sqrt{\frac{0,25^2}{61} + \frac{0,19^2}{40}}} = 5,69$.


See on oluline võrreldes 1,96 (5%); 2,576 (1%) või 3,291 (0,1%). p väärtus on tegelikult null.

95%-lised usalduspiirid sünnikaalude erinevuse jaoks on $\bar{x}_1 - \bar{x}_2 \pm 1,96 \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$, millest saame $-0,25 \pm 0,086$.

8.2.6 Kahe üldkogumi keskväärtuse võrdlemine Minitab'iga

Kahe üldkogumi keskväärtuse võrdlemiseks vaatleme järgmist näidet. Katses olid kaks ämblikuliiki: Dinopis ja Menneus. Sooviti võrrelda, kumma liigi ämblikud püüavad keskmiselt suuremat saaki. Kummastki liigist valiti 10 ämblikku ja mõõdeti nende poolt püütud saagi suurus (mm-tes). Tulemused on esitatud järgnevas tabelis. Andmestikust esimese mulje saamiseks joonistame mõlema liigi jaoks karpdiagrammi.

Dinopis	Menneus
12,9	10,2
10,2	6,9
7,4	10,9
7,0	11,0
10,5	10,1
11,9	5,3
7,1	5,3
9,9	7,5
14,4	10,3
11,3	9,28,8



Kasutame Minitabi ja teeme kaks analüüsi. Esimesel korral eeldame, et üldkogumite dispersioonid on võrdsed.

Two Sample T-Test and Confidence Interval

Twosample T for Dinopis vs Menneus

	N	Mean	StDev	SE Mean
Dinopis	10	10.26	2.51	0.79
Menneus	10	9.02	1.90	0.60

95% C.I. for mu Dinopis - mu Menneus: (-0.85, 3.33)

T-Test mu Dinopis = mu Menneus (vs not =): T= 1.25 P=0.23 DF= 18

Both use Pooled StDev = 2.23

Teisel korral ei eeldata dispersioonide võrdsust.

Two Sample T-Test and Confidence Interval

Twosample T for Dinopis vs Menneus

	N	Mean	StDev	SE Mean
Dinopis	10	10.26	2.51	0.79
Menneus	10	9.02	1.90	0.60

95% C.I for mu Dinopis - mu Menneus: (-0.87, 3.35)

T-Test mu Dinopis = mu Menneus (vs not =): T= 1.25 P=0.23 DF= 16

Mõlemad analüüsid on kooskõlas: ükskõik missuguse eelduse teeme, võime järeldada, et vaadeldes keskmist saagi suurust ($p = 0,23$), ei ole erinevus ämblike liikide vahel oluline. Järelikult meil ei ole mingit põhjust öelda, et kaks erinevat liiki ämblikku püüavad erineva suurusega saaki.

8.3 Ülesanded

8.1

Mõõdeti kahe erinevat tõugu lehmade keskmist piimatoodangut:

Tüüp	Keskmine	St.hälve	n
A	18,8	2,4	106
B	17,2	5,2	54

Kontrolli hüpoteesi, kas kahe erinevat tõugu lehmade keskmine piimatoodang on võrdne. Missuguseid eeldusi on vaja teha analüüsi käigus?

8.2

Katses kasvatati kahte erinevat sorti otra. Tulemused (vakk/aakri kohta) on esitatud järgnevas tabelis:

Liik								
Trebi	41,2	19,3	45,5	63,9	63,8	44,2	42,5	53,0
Svanota	39,4	30,8	44,5	51,5	41,1	26,5	35,7	

A. Kontrolli hüpoteesi, et kahel erineval odrasordil on keskmine saagikus ühesugune.

B. Arvuta 95%-lised usalduspiirid kahe sordi keskmise saagikuse erinevusele.

8.3

Kui tõsine mõju lapse arengule enne sündi on ema alkoholi tarvitamine?¹ Selles, et uurida seda küsimust, leiti kuus naist kes olid olnud kroonilised alkohoolikud raseduse ajal. Nende lastele tehti 7-aastaselt IQ test järgmiste tulemustega:

78 102 64 84 100 70

A. Arvuta keskväärtus ja dispersioon IQ testi tulemuste kohta.

B. 46 naisest koosneva kontrollgrupi, kes ei olnud alkohoolikud, laste IQ testi tulemused on: $\bar{X} = 99$ ja $\sum(X_i - \bar{X})^2 = 11520$. Kontrolli hüpoteesi, et kahel naiste grupil on laste IQ testi tulemused keskmiselt võrdsed.

C. Kas võib eelnevat näidet pidada katseks? Selgita miks/miks mitte. Samuti arutle, kas ülesande B testi lõppjärelused sõltuvad katsest tulenevatest andmetest.

8.4

Järgnev andmestik on uurimuse tulemus, mis selgitab, kas malaaria esineb võrdselt kahes ökoloogiliselt erinevas piirkonnas A ja B. Vere valimid on võetud juhuslikult valitud indiviididelt iga piirkonna 7-st erinevast kohast. Iga koha valimi protsendid näitavad, mil määral malaaria kindlaks määrati. Tulemused olid:

¹Võetud Jones et al, Lancet, June 1974

Koht	Piirkond A	Piirkond B
1	5	13
2	12	18
3	13	11
4	2	17
5	4	14
6	3	11
7	8	21

- A. Kontrolli, kas malaaria esineb võrdselt kahes piirkonnas.
 B. Arvuta 95%-lised usalduspiirid kahe piirkonna erinevusele.
 C. Missuguseid eeldusi on vaja analüüsiks?

8.5

Troopilisel maal kasutatakse pühvleid või härgi suhkru väljapressimise tööriista juures. Loomad töötavad 90 minutit. Sel ajal kõnnivad nad ringjoonelisel, kinnitatuna hoova külge. 10 pühvlit ja 8 härga osalesid katses, mille käigus mõõdeti nende südame tööd enne ja pärast tööperioodi. Tulemused olid järgmised:

Pühvel		Härg	
Südamelöögid enne tööd	Südamelöögid pärast tööd	Südamelöögid enne tööd	Südamelöögid pärast tööd
50	52	65	68
50	58	65	72
56	55	59	65
54	59	65	70
43	46	63	71
48	55	53	63
53	52	56	64
46	48	61	68
51	55		
47	50		

- A. Kontrolli hüpoteesi, et südame töö muutus on kahel loomaliigil ühesugune.
 B. Missuguseid eeldusi on vaja analüüsiks?

8.6

Claes Lilja² artiklis olid andmed, kus oli mõõdetud jaapani vuti mune kahelt erinevalt liinilt. Üks liin ("P-liin") oli valitud vuti kasvatamise ajal kindlast generatsioonist nii, et iga generatsiooni kõrgeima kehakaaluga nelja nädala vanustel indiviididel lubati paljuneda. Teine liin ("C-liin") oli tavaline, selekteerimata

²Scand J agric res 17:149-151, 1987

grupp. Järgnevas tabelis on esitatud liinide kohta mõned muutujad (esimesena P-liin, siis C-liin):

Muutuja	keskmine	SD	n	keskmine	SD	n
Värskete munade kaal	14,1	1,88	30	10,2	0,61	29
Kuiva koore kaal	0,816	0,0931	30	0,699	0,0774	29
Ca-sisaldus kooses	0,259	0,0035	10	0,256	0,0056	10

Tabelis on esitatud keskväärtuse, standardhälbe (SD) ja vaatluste arvu (n) väärtused kolmele muutujale: värskete munade kaal; kuiva koore kaal; Ca-sisaldus kooses.

Küsimused:

A. Arvuta P-liini muutuja “värskete munade kaal” keskväärtuse standardviga (SEM).

B. Kas esineb olulisi erinevusi muutuja “kuiva koore kaal” P-liini ja C-liini keskväärtuse vahel?

C. Kontrolli, kas on mõistlik eeldada, et P-liinil ja C-liinil on võrdne dispersioon muutujale “värskete munade kaal”?

AINEREGISTER

Termin (eesti keel)	Inglise keel	Rootsi keel	lk
alternatiive e sisukas hüpotees	alternative hypothesis	mothypotesen	65
aritmeetiline keskmine	arithmetic mean	aritmetiskt medelvärde	7
Bayes'i teoreem	Bayes' theorem	Bayes sats	33
binoomjaotus	binomial distribution	bionomialfördelning	41
diskreetne juhuslik suurus	discrete random variable	diskret slumpvariabel	37, 40
dispersioon	variance	varians	9
efektiivsus	efficiency	effektivitet	57
esimesst liiki viga	error of the first kind	fel av första slaget	66
esindatav	representative	representativ	3
hajuvusdiagramm	scatter plot	punktdiagram	18
hindamine	estimation	estimation	55
hinnang	estimate	estimat	57
hinnang	estimator	estimator	57
histogramm, tulpdiaagramm	histogram, bar chart	histogram	16
hüpoteesi kontrollimine	testing the hypothesis	hypotesprövning	65
intervallskaala	interval scale	intervallskala	7
jaotusfunktsioon	distribution function	Fördelningsfunktion	39
juhuslik katse	random experiment	slumpmässig experiment	29
juhuslik muutuja	random variable	slumpvariabel	37
juhuslik valik	random sampling	slumpmässig sampling	3
juhusliku muutuja dispersioon	variance of random variable	varians för en slumpmässig variabel	40
juhusliku muutuja keskväärtus	mean value of random variable	medelvärde (förväntat värde) för en slumpvariabel	40

kahe keskväärtuse võrdlemine	compare two mean values	jämföra två medelvärden	81
kaks sõltumatut gruppi	two independent groups	två oberoende grupper	81
karpdiagramm	box plot	box plot, lådogram	14
keskruudu viga	mean square error	felkvadratsumma	58
keskväärtus	mean	medelvärde	7
keskväärtuse standardviga	standard error of the mean	medelvärdets medelfel	11
kohendatud keskmine	trimmed mean	trimmat medelvärde	8
korutamise reegel	multiplication rule	multiplikationssatsen	32, 33
kvalitatiivne muutuja	qualitative variable	kvalitativ variabel	6
kvanitatiivne muutuja	quantitative variable	kvantitativ variabel	6
kvartiil	quartile	kvartil	11
kvartiilide vahe	inter-quartile range	kvartilavstånd	12
liitmise reegel	addition rule	additionssatsen	31
mediaan	median	median	8
Minitab	Minitab	Minitab	12
mudel	model	modell	1
muutuja	variable	Variabel	7
nihketa	unbiased	väntvärderiktig	57
nihutamatus	unbiasedness	väntvärderiktighet	57
nominaalne skaala	nominal scale	nominalskala	7
normaaljaotus	normal distribution	normalfördelning	46
nullhüpotees	null hypothesis	nollhypotesen	65
oluline	significant	signifikans	66
ootusväärtus	expected value	förväntat värde	40
ordinaalne skaala	ordinal scale	ordinalskala	7
otsustused osakaalu kohta	inference on proportions	inferens om proportioner	75
paarikaupa võrdlemine	pairwise comparison	Parvisa jämförelser	81
pidev muutuja	continuous variable	kontinuerlig variabel	6
Poissoni jaotus	Poisson distribution	Poissonfördelning	44

proportsionaalne skaala	ratio scale	kvotskala	7
protsentiil	percentile	percentil	11
punkthinnang	point estimation	punktestimation	57
ringdiagramm	pie chart	tårtdiagram	24
ristkülikjaotus	rectangular distribution	rektangulärfördelning	46
risttabel	cross table	korstabelle	21
sagedustabel	frequency table	frekvenstabell	15, 21
segatud andmed	matched data	matchade data	81
SEM	SEM	SEM	11
sisemised aiad	inner fences	övre och undre gränsen	15
sõltumatu grupp	independent group	oberoende grupper	81
sõltumatu sündmus	independent events	oberoende händelser	32
standardhälve	standard deviation	standardavvikelse	10
standardiseeritud normaaljaotus	standardized normal distribution	standardiserad normalfördelning	49
statistiline otsustus	statistical inference	statistisk inferens	4, 55
Student'i t-test	Student's t	Student's t	60
suhteline sagedus	relative frequency	relativ frekvens	30
sündmus	event	händelse	29
täiend	complement	komplement	30
teist liiki viga	error of the second kind	fel av andra slaget	66
tinglik tõenäosus	conditional probability	betingad sannolikhet	33
t-jaotus	t distribution	t-fördelning	60, 71
tõenäosus	probability	sannolikhet	30
tõenäosuse usalduspiirid	confidence interval for p	konfidensintervall för p	75
tõenäosusfunktsioon	probability function	sannolikhetsfunktion	37, 38
tõenäosusjaotus	probability distribution	sannolikhetsfördelning	38
tõenäosuslik	probabilistic	probabilistisk	1

tõenäosusväärtus	p value	p-värde	69
tõenäosusväärtus	prob-value	prob-värde, p-värde	30
tsentraalne piirteoreem	central limit theorem	Centrala gränsvärdessatsen	50
t-test	t test	t-test	71
tulemus, tagajärg	outcome	utfall	29
tulpdiagramm	bar chart	stolpdiagram	23
tüvi- leht diagramm	stem-and-leaf displays	stem-and-leaf-diagram (stam-och-löv...)	14
ühepoolne hüpotees	single sided hypothesis	enkelsidig hypotes	70
üldkogum, populatsioon	population	population	3
üldkogumi parameetrid	population parameters	populationsparametrar	41
usalduspiirid	confidence interval	konfidensintervall	58
vabadusaste	degrees of freedom	frihetsgrader	60
vahemik	range		10
vahemikhinnang	interval estimation	intervallestimation	58
valim	sample	sampel	3
valimi statistikud	sample statistics	stickprovsstorheter	41
valimkeskmine	distribution of \bar{X}	fördelning för \bar{X}	50
variatsioonikoefitsent	coefficient of variation	variationskoefficient	11
varieeruvus (muutlikkus)	variation	variation	1
võimsus	power	power, styrka	66

TABELID

1. Juhuslike arvude tabel.....	98
2. Binoomjaotuse jaotusfunktsiooni tabel.....	99
3. Poissoni jaotuse jaotusfunktsioon	103
4. Normaaljaotuse tabel.....	104
5. t-jaotusfunktsiooni tabel.....	105
6. χ^2-jaotuse tabel.....	106
6. χ^2-jaotuse tabel (järg)	107
7. F-jaotuse tabel (1 – p = 0,90)	108
8. F-jaotuse tabel (1 – p = 0,95)	109
9. F-jaotuse tabel (1 – p = 0,99)	110
10. F-jaotuse tabel (1 – p = 0,999)	111

1. Juhuslike arvude tabel

Juhuslikud arvud on valitud tabelisse nii, et igal arvul on ühesugune tõenäosus olla valitud.

Ri da	Veera																													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	8	7	8	6	7	4	5	9	1	3	2	0	1	9	6	7	6	6	1	3	0	0	7	0	8	9	9	1	2
2	9	6	0	2	0	7	3	9	8	3	5	5	0	0	9	0	4	4	0	0	0	8	2	1	1	4	3	8	8	5
3	4	6	4	3	2	6	4	4	5	4	6	0	7	4	8	1	7	0	0	5	4	1	6	3	1	4	9	4	2	5
4	7	2	3	2	0	6	4	6	2	8	6	2	2	7	5	4	5	6	0	8	0	3	6	4	9	6	2	8	9	4
5	1	0	0	8	6	2	5	4	5	1	1	4	9	8	5	5	3	7	0	4	8	7	9	1	1	0	9	7	3	5
6	1	8	2	7	6	3	6	8	0	8	5	3	4	0	4	8	9	4	3	9	1	8	9	8	0	6	8	7	7	1
7	6	7	8	8	3	5	2	9	6	7	4	5	8	7	5	9	7	9	4	9	7	4	3	8	9	0	9	8	7	4
8	9	5	6	5	5	1	5	8	5	2	1	6	1	2	0	1	8	3	5	7	3	1	4	9	4	5	4	2	9	4
9	8	0	0	1	6	2	5	4	2	5	9	0	2	9	4	7	3	8	7	8	7	0	6	6	5	5	7	0	1	8
10	4	4	4	8	8	6	2	7	5	8	2	5	9	0	3	7	9	4	1	9	4	0	0	0	9	9	0	9	7	5
11	8	7	8	2	1	6	3	5	7	2	3	2	2	3	2	3	7	0	8	1	1	0	7	7	0	2	8	2	5	8
12	0	4	8	5	4	5	2	8	2	3	9	5	1	8	3	6	4	8	7	4	1	3	7	6	4	1	6	1	1	3
13	1	3	4	8	5	0	7	7	6	6	0	3	3	1	5	0	8	8	7	7	3	5	9	7	1	3	1	4	0	2
14	3	2	9	5	6	2	8	8	7	4	3	1	7	5	2	4	8	0	6	3	7	5	3	0	8	7	1	8	2	8
15	7	1	1	7	4	5	9	7	3	5	7	2	2	3	6	5	3	6	6	3	1	0	3	9	5	9	0	1	7	9
16	2	2	0	4	2	4	7	4	0	7	8	8	8	1	5	5	3	6	2	7	9	1	0	0	4	0	9	1	1	8
17	4	2	6	5	8	2	8	7	0	3	8	0	3	1	0	7	9	4	6	6	2	8	7	3	2	5	0	4	1	2
18	4	8	4	1	2	4	6	0	7	2	6	8	6	7	6	3	1	3	9	5	7	1	5	9	2	2	3	0	2	8
19	7	6	2	0	4	0	9	1	8	3	8	3	5	7	8	9	0	4	1	8	5	6	2	7	7	8	2	7	2	4
20	3	7	3	8	3	2	3	9	0	9	6	9	6	3	5	0	1	0	5	1	1	0	4	1	9	7	8	0	2	5
21	0	9	9	0	9	2	4	0	0	6	5	7	2	2	5	1	0	0	7	1	9	8	4	5	8	0	1	3	4	6
22	7	9	4	7	2	2	3	7	4	4	0	2	9	7	5	2	5	7	6	6	6	5	2	5	3	2	9	5	1	6
23	9	6	2	9	8	3	7	2	2	8	5	6	7	2	1	5	4	7	6	8	7	1	3	5	1	3	5	2	8	5
24	9	9	4	4	0	7	6	4	4	3	1	7	6	6	8	1	8	3	1	1	1	2	2	9	3	9	3	2	4	2
25	5	3	7	2	3	6	8	0	1	6	6	3	1	1	5	2	5	9	6	1	9	8	4	2	8	2	5	9	4	5
26	5	8	2	0	3	8	7	1	8	4	7	0	4	6	5	7	4	3	4	3	6	8	5	9	2	5	2	5	2	6
27	0	7	1	2	2	9	3	3	6	0	7	1	6	2	0	5	8	8	0	6	9	6	4	8	9	6	5	2	2	1
28	6	6	7	8	4	2	0	1	5	5	8	0	7	5	2	3	2	4	9	7	0	1	7	8	4	9	9	8	6	5
29	1	7	5	3	2	4	1	1	2	0	9	5	0	8	0	0	0	7	5	1	7	8	6	6	4	9	4	2	9	1
30	4	0	9	9	9	0	1	4	2	1	0	0	2	5	4	4	1	4	2	1	2	3	1	1	7	4	9	8	8	1
31	7	6	9	9	2	8	0	9	9	8	2	0	3	3	9	4	9	6	4	7	4	1	6	0	1	3	3	1	2	5
32	9	6	5	3	1	3	4	0	2	8	6	5	1	0	2	0	6	7	7	7	2	2	3	5	7	7	8	2	8	0
33	3	4	6	8	9	8	2	2	7	3	4	4	2	3	2	6	3	5	3	3	4	0	8	6	5	3	8	8	9	5
34	3	1	9	0	3	9	2	5	1	8	9	0	3	9	1	6	0	7	9	7	8	8	9	6	5	7	1	0	9	2
35	5	3	1	0	4	0	0	3	1	0	0	8	4	6	9	7	5	3	9	1	5	2	7	1	1	2	6	4	2	8
36	8	8	6	1	6	1	3	9	3	9	0	8	3	1	4	5	0	1	1	2	8	5	4	3	0	0	9	8	4	9
37	6	9	1	0	3	9	5	9	7	7	6	6	0	1	6	4	8	1	2	9	5	8	9	3	3	3	3	5	6	1
38	9	0	7	5	1	8	9	1	4	8	8	6	7	0	5	0	0	9	1	7	9	2	1	6	8	0	9	7	2	4
39	0	7	0	1	8	7	7	6	9	9	6	8	7	8	3	1	8	5	0	9	3	3	1	2	3	2	9	5	6	4
40	5	3	6	3	0	9	0	9	0	9	2	3	7	6	2	6	9	0	8	6	0	5	9	0	9	3	3	6	2	1
41	0	6	9	2	4	3	9	7	5	2	4	0	7	1	2	9	2	3	3	8	1	9	5	5	7	8	0	7	0	0
42	6	5	3	3	8	7	4	3	3	1	3	2	9	6	6	9	2	7	0	0	2	1	0	4	2	0	9	8	8	9
43	8	8	3	6	3	1	4	9	4	0	0	8	5	9	3	5	6	2	9	3	4	3	0	4	4	8	4	2	9	5
44	0	9	0	5	6	4	0	2	8	1	5	1	2	7	6	5	2	7	5	4	9	3	7	8	8	1	5	6	7	0
45	1	3	5	0	8	5	6	3	1	4	2	9	7	5	0	1	9	6	1	4	9	2	8	3	1	2	0	2	6	3

4. Normaaljaotuse tabel

z	Viimane kümnendkoht									
	0	1	2	3	4	5	6	7	8	9
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1.0	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2.0	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3.0	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998
3.5	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998
3.6	0.9998	0.9998	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.7	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.8	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
4.0	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

Tabel annab normaaljaotuse jaotusfunktsiooni $F(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$ väärtused

vahemikus $z = 0,00(0,01)4,09$. Negatiivsete väärtuste korral kasuta teisendust $F(z) = 1 - F(-z)$.

5. t-jaotusfunktsiooni tabel


d.f.	F(t)								
	0.75	0.90	0.95	0.975	0.99	0.995	0.9975	0.999	0.9995
1	1.000	3.078	6.314	12.706	31.821	63.657	127.321	318.309	636.619
2	0.816	1.886	2.920	4.303	6.965	9.925	14.089	22.327	31.599
3	0.765	1.638	2.353	3.182	4.541	5.841	7.453	10.215	12.924
4	0.741	1.533	2.132	2.776	3.747	4.604	5.598	7.173	8.610
5	0.727	1.476	2.015	2.571	3.365	4.032	4.773	5.893	6.869
6	0.718	1.440	1.943	2.447	3.143	3.707	4.317	5.208	5.959
7	0.711	1.415	1.895	2.365	2.998	3.499	4.029	4.785	5.408
8	0.706	1.397	1.860	2.306	2.896	3.355	3.833	4.501	5.041
9	0.703	1.383	1.833	2.262	2.821	3.250	3.690	4.297	4.781
10	0.700	1.372	1.812	2.228	2.764	3.169	3.581	4.144	4.587
11	0.697	1.363	1.796	2.201	2.718	3.106	3.497	4.025	4.437
12	0.695	1.356	1.782	2.179	2.681	3.055	3.428	3.930	4.318
13	0.694	1.350	1.771	2.160	2.650	3.012	3.372	3.852	4.221
14	0.692	1.345	1.761	2.145	2.624	2.977	3.326	3.787	4.140
15	0.691	1.341	1.753	2.131	2.602	2.947	3.286	3.733	4.073
16	0.690	1.337	1.746	2.120	2.583	2.921	3.252	3.686	4.015
17	0.689	1.333	1.740	2.110	2.567	2.898	3.222	3.646	3.965
18	0.688	1.330	1.734	2.101	2.552	2.878	3.197	3.610	3.922
19	0.688	1.328	1.729	2.093	2.539	2.861	3.174	3.579	3.883
20	0.687	1.325	1.725	2.086	2.528	2.845	3.153	3.552	3.850
21	0.686	1.323	1.721	2.080	2.518	2.831	3.135	3.527	3.819
22	0.686	1.321	1.717	2.074	2.508	2.819	3.119	3.505	3.792
23	0.685	1.319	1.714	2.069	2.500	2.807	3.104	3.485	3.768
24	0.685	1.318	1.711	2.064	2.492	2.797	3.091	3.467	3.745
25	0.684	1.316	1.708	2.060	2.485	2.787	3.078	3.450	3.725
26	0.684	1.315	1.706	2.056	2.479	2.779	3.067	3.435	3.707
27	0.684	1.314	1.703	2.052	2.473	2.771	3.057	3.421	3.690
28	0.683	1.313	1.701	2.048	2.467	2.763	3.047	3.408	3.674
29	0.683	1.311	1.699	2.045	2.462	2.756	3.038	3.396	3.659
30	0.683	1.310	1.697	2.042	2.457	2.750	3.030	3.385	3.646
40	0.681	1.303	1.684	2.021	2.423	2.704	2.971	3.307	3.551
50	0.679	1.299	1.676	2.009	2.403	2.678	2.937	3.261	3.496
60	0.679	1.296	1.671	2.000	2.390	2.660	2.915	3.232	3.460
80	0.678	1.292	1.664	1.990	2.374	2.639	2.887	3.195	3.416
100	0.677	1.290	1.660	1.984	2.364	2.626	2.871	3.174	3.390
∞	0.674	1.282	1.645	1.960	2.326	2.576	2.807	3.092	3.291

Näide: t -jaotuse 10 vabadusastmega
(d.f.) suuruse jaoks

$$F(1.812) = P(t \leq 1.812) = 0.95.$$

Jaotus on sümmeetriline, st
 t -jaotuse 10 vabadusastmega
(d.f.) suuruse jaoks kehtib

$$F(-1.812) = P(t \leq -1.812) = 0.05.$$



6. χ^2 -jaotuse tabel

d.f.	1-p								
	0.0005	0.001	0.0025	0.005	0.01	0.025	0.05	0.1	0.5
1	0.000	0.000	0.000	0.000	0.000	0.001	0.004	0.016	0.455
2	0.001	0.002	0.005	0.010	0.020	0.051	0.103	0.211	1.386
3	0.015	0.024	0.045	0.072	0.115	0.216	0.352	0.584	2.366
4	0.064	0.091	0.145	0.207	0.297	0.484	0.711	1.064	3.357
5	0.158	0.210	0.307	0.412	0.554	0.831	1.145	1.610	4.351
6	0.299	0.381	0.527	0.676	0.872	1.237	1.635	2.204	5.348
7	0.485	0.598	0.794	0.989	1.239	1.690	2.167	2.833	6.346
8	0.710	0.857	1.104	1.344	1.646	2.180	2.733	3.490	7.344
9	0.972	1.152	1.450	1.735	2.088	2.700	3.325	4.168	8.343
10	1.265	1.479	1.827	2.156	2.558	3.247	3.940	4.865	9.342
11	1.587	1.834	2.232	2.603	3.053	3.816	4.575	5.578	10.341
12	1.934	2.214	2.661	3.074	3.571	4.404	5.226	6.304	11.340
13	2.305	2.617	3.112	3.565	4.107	5.009	5.892	7.042	12.340
14	2.697	3.041	3.582	4.075	4.660	5.629	6.571	7.790	13.339
15	3.108	3.483	4.070	4.601	5.229	6.262	7.261	8.547	14.339
16	3.536	3.942	4.573	5.142	5.812	6.908	7.962	9.312	15.338
17	3.980	4.416	5.092	5.697	6.408	7.564	8.672	10.085	16.338
18	4.439	4.905	5.623	6.265	7.015	8.231	9.390	10.865	17.338
19	4.912	5.407	6.167	6.844	7.633	8.907	10.117	11.651	18.338
20	5.398	5.921	6.723	7.434	8.260	9.591	10.851	12.443	19.337
21	5.896	6.447	7.289	8.034	8.897	10.283	11.591	13.240	20.337
22	6.404	6.983	7.865	8.643	9.542	10.982	12.338	14.041	21.337
23	6.924	7.529	8.450	9.260	10.196	11.689	13.091	14.848	22.337
24	7.453	8.085	9.044	9.886	10.856	12.401	13.848	15.659	23.337
25	7.991	8.649	9.646	10.520	11.524	13.120	14.611	16.473	24.337
26	8.538	9.222	10.256	11.160	12.198	13.844	15.379	17.292	25.336
27	9.093	9.803	10.873	11.808	12.879	14.573	16.151	18.114	26.336
28	9.656	10.391	11.497	12.461	13.565	15.308	16.928	18.939	27.336
29	10.227	10.986	12.128	13.121	14.256	16.047	17.708	19.768	28.336
30	10.804	11.588	12.765	13.787	14.953	16.791	18.493	20.599	29.336
40	16.906	17.916	19.417	20.707	22.164	24.433	26.509	29.051	39.335
50	23.461	24.674	26.464	27.991	29.707	32.357	34.764	37.689	49.335
60	30.340	31.738	33.791	35.534	37.485	40.482	43.188	46.459	59.335
80	44.791	46.520	49.043	51.172	53.540	57.153	60.391	64.278	79.334
100	59.896	61.918	64.857	67.328	70.065	74.222	77.929	82.358	99.334

6. χ^2 -jaotuse tabel (järg)

d.f.	1-p								
	0.75	0.9	0.95	0.975	0.99	0.995	0.9975	0.999	0.9995
1	1.323	2.706	3.841	5.024	6.635	7.879	9.141	10.828	12.116
2	2.773	4.605	5.991	7.378	9.210	10.597	11.983	13.816	15.202
3	4.108	6.251	7.815	9.348	11.345	12.838	14.320	16.266	17.730
4	5.385	7.779	9.488	11.143	13.277	14.860	16.424	18.467	19.997
5	6.626	9.236	11.070	12.833	15.086	16.750	18.386	20.515	22.105
6	7.841	10.645	12.592	14.449	16.812	18.548	20.249	22.458	24.103
7	9.037	12.017	14.067	16.013	18.475	20.278	22.040	24.322	26.018
8	10.219	13.362	15.507	17.535	20.090	21.955	23.774	26.124	27.868
9	11.389	14.684	16.919	19.023	21.666	23.589	25.462	27.877	29.666
10	12.549	15.987	18.307	20.483	23.209	25.188	27.112	29.588	31.420
11	13.701	17.275	19.675	21.920	24.725	26.757	28.729	31.264	33.137
12	14.845	18.549	21.026	23.337	26.217	28.300	30.318	32.909	34.821
13	15.984	19.812	22.362	24.736	27.688	29.819	31.883	34.528	36.478
14	17.117	21.064	23.685	26.119	29.141	31.319	33.426	36.123	38.109
15	18.245	22.307	24.996	27.488	30.578	32.801	34.950	37.697	39.719
16	19.369	23.542	26.296	28.845	32.000	34.267	36.456	39.252	41.308
17	20.489	24.769	27.587	30.191	33.409	35.718	37.946	40.790	42.879
18	21.605	25.989	28.869	31.526	34.805	37.156	39.422	42.312	44.434
19	22.718	27.204	30.144	32.852	36.191	38.582	40.885	43.820	45.973
20	23.828	28.412	31.410	34.170	37.566	39.997	42.336	45.315	47.498
21	24.935	29.615	32.671	35.479	38.932	41.401	43.775	46.797	49.011
22	26.039	30.813	33.924	36.781	40.289	42.796	45.204	48.268	50.511
23	27.141	32.007	35.172	38.076	41.638	44.181	46.623	49.728	52.000
24	28.241	33.196	36.415	39.364	42.980	45.559	48.034	51.179	53.479
25	29.339	34.382	37.652	40.646	44.314	46.928	49.435	52.620	54.947
26	30.435	35.563	38.885	41.923	45.642	48.290	50.829	54.052	56.407
27	31.528	36.741	40.113	43.195	46.963	49.645	52.215	55.476	57.858
28	32.620	37.916	41.337	44.461	48.278	50.993	53.594	56.892	59.300
29	33.711	39.087	42.557	45.722	49.588	52.336	54.967	58.301	60.735
30	34.800	40.256	43.773	46.979	50.892	53.672	56.332	59.703	62.162
40	45.616	51.805	55.758	59.342	63.691	66.766	69.699	73.402	76.095
50	56.334	63.167	67.505	71.420	76.154	79.490	82.664	86.661	89.561
60	66.981	74.397	79.082	83.298	88.379	91.952	95.344	99.607	102.695
80	88.130	96.578	101.879	106.629	112.329	116.321	120.102	124.839	128.261
100	109.141	118.498	124.342	129.561	135.807	140.169	144.293	149.449	153.167

7 F-jaotuse tabel (1 – p = 0,90)

v_2	v_1														
	1	2	3	4	5	6	8	10	12	16	20	30	40	60	120
1	39,863	49,500	53,593	55,833	57,240	58,204	59,439	60,195	60,705	61,350	61,740	62,265	62,529	62,794	63,061
2	8,526	9,000	9,162	9,243	9,293	9,326	9,367	9,392	9,408	9,429	9,441	9,458	9,466	9,475	9,483
3	5,538	5,462	5,391	5,343	5,309	5,285	5,252	5,230	5,216	5,196	5,184	5,168	5,160	5,151	5,143
4	4,545	4,325	4,191	4,107	4,051	4,010	3,955	3,920	3,896	3,864	3,844	3,817	3,804	3,790	3,775
5	4,060	3,780	3,619	3,520	3,453	3,405	3,339	3,297	3,268	3,230	3,207	3,174	3,157	3,140	3,123
6	3,776	3,463	3,289	3,181	3,108	3,055	2,983	2,937	2,905	2,863	2,836	2,800	2,781	2,762	2,742
7	3,589	3,257	3,074	2,961	2,883	2,827	2,752	2,703	2,668	2,623	2,595	2,555	2,535	2,514	2,493
8	3,458	3,113	2,924	2,806	2,726	2,668	2,589	2,538	2,502	2,455	2,425	2,383	2,361	2,339	2,316
9	3,360	3,006	2,813	2,693	2,611	2,551	2,469	2,416	2,379	2,329	2,298	2,255	2,232	2,208	2,184
10	3,285	2,924	2,728	2,605	2,522	2,461	2,377	2,323	2,284	2,233	2,201	2,155	2,132	2,107	2,082
12	3,177	2,807	2,606	2,480	2,394	2,331	2,245	2,188	2,147	2,094	2,060	2,011	1,986	1,960	1,932
14	3,102	2,726	2,522	2,395	2,307	2,243	2,154	2,095	2,054	1,998	1,962	1,912	1,885	1,857	1,828
16	3,048	2,668	2,462	2,333	2,244	2,178	2,088	2,028	1,985	1,928	1,891	1,839	1,811	1,782	1,751
18	3,007	2,624	2,416	2,286	2,196	2,130	2,038	1,977	1,933	1,875	1,837	1,783	1,754	1,723	1,691
20	2,975	2,589	2,380	2,249	2,158	2,091	1,999	1,937	1,892	1,833	1,794	1,738	1,708	1,677	1,643
24	2,927	2,538	2,327	2,195	2,103	2,035	1,941	1,877	1,832	1,770	1,730	1,672	1,641	1,607	1,571
28	2,894	2,503	2,291	2,157	2,064	1,996	1,900	1,836	1,790	1,726	1,685	1,625	1,592	1,558	1,520
32	2,869	2,477	2,263	2,129	2,036	1,967	1,870	1,805	1,758	1,694	1,652	1,590	1,556	1,520	1,481
36	2,850	2,456	2,243	2,108	2,014	1,945	1,847	1,781	1,734	1,669	1,626	1,563	1,528	1,491	1,450
40	2,835	2,440	2,226	2,091	1,997	1,927	1,829	1,763	1,715	1,649	1,605	1,541	1,506	1,467	1,425
50	2,809	2,412	2,197	2,061	1,966	1,895	1,796	1,729	1,680	1,613	1,568	1,502	1,465	1,424	1,379
60	2,791	2,393	2,177	2,041	1,946	1,875	1,775	1,707	1,657	1,589	1,543	1,476	1,437	1,395	1,348
70	2,779	2,380	2,164	2,027	1,931	1,860	1,760	1,691	1,641	1,572	1,526	1,457	1,418	1,374	1,325
80	2,769	2,370	2,154	2,016	1,921	1,849	1,748	1,680	1,629	1,559	1,513	1,443	1,403	1,358	1,307
100	2,756	2,356	2,139	2,002	1,906	1,834	1,732	1,663	1,612	1,542	1,494	1,423	1,382	1,336	1,282

8. F-jaotuse tabel ($1 - p = 0,95$)

v_2	v_1														
	1	2	3	4	5	6	8	10	12	16	20	30	40	60	120
1	161,45	199,50	215,71	224,58	230,16	233,99	238,88	241,88	243,91	246,46	248,01	250,10	251,14	252,20	253,25
2	18,513	19,000	19,164	19,247	19,296	19,330	19,371	19,396	19,413	19,433	19,446	19,462	19,471	19,479	19,487
3	10,128	9,552	9,277	9,117	9,013	8,941	8,845	8,786	8,745	8,692	8,660	8,617	8,594	8,572	8,549
4	7,709	6,944	6,591	6,388	6,256	6,163	6,041	5,964	5,912	5,844	5,803	5,746	5,717	5,688	5,658
5	6,608	5,786	5,409	5,192	5,050	4,950	4,818	4,735	4,678	4,604	4,558	4,496	4,464	4,431	4,398
6	5,987	5,143	4,757	4,534	4,387	4,284	4,147	4,060	4,000	3,922	3,874	3,808	3,774	3,740	3,705
7	5,591	4,737	4,347	4,120	3,972	3,866	3,726	3,637	3,575	3,494	3,445	3,376	3,340	3,304	3,267
8	5,318	4,459	4,066	3,838	3,687	3,581	3,438	3,347	3,284	3,202	3,150	3,079	3,043	3,005	2,967
9	5,117	4,256	3,863	3,633	3,482	3,374	3,230	3,137	3,073	2,989	2,936	2,864	2,826	2,787	2,748
10	4,965	4,103	3,708	3,478	3,326	3,217	3,072	2,978	2,913	2,828	2,774	2,700	2,661	2,621	2,580
12	4,747	3,885	3,490	3,259	3,106	2,996	2,849	2,753	2,687	2,599	2,544	2,466	2,426	2,384	2,341
14	4,600	3,739	3,344	3,112	2,958	2,848	2,699	2,602	2,534	2,445	2,388	2,308	2,266	2,223	2,178
16	4,494	3,634	3,239	3,007	2,852	2,741	2,591	2,494	2,425	2,333	2,276	2,194	2,151	2,106	2,059
18	4,414	3,555	3,160	2,928	2,773	2,661	2,510	2,412	2,342	2,250	2,191	2,107	2,063	2,017	1,968
20	4,351	3,493	3,098	2,866	2,711	2,599	2,447	2,348	2,278	2,184	2,124	2,039	1,994	1,946	1,896
24	4,260	3,403	3,009	2,776	2,621	2,508	2,355	2,255	2,183	2,088	2,027	1,939	1,892	1,842	1,790
28	4,196	3,340	2,947	2,714	2,558	2,445	2,291	2,190	2,118	2,021	1,959	1,869	1,820	1,769	1,714
32	4,149	3,295	2,901	2,668	2,512	2,399	2,244	2,142	2,070	1,972	1,908	1,817	1,767	1,714	1,657
36	4,113	3,259	2,866	2,634	2,477	2,364	2,209	2,106	2,033	1,934	1,870	1,776	1,726	1,671	1,612
40	4,085	3,232	2,839	2,606	2,449	2,336	2,180	2,077	2,003	1,904	1,839	1,744	1,693	1,637	1,577
50	4,034	3,183	2,790	2,557	2,400	2,286	2,130	2,026	1,952	1,850	1,784	1,687	1,634	1,576	1,511
60	4,001	3,150	2,758	2,525	2,368	2,254	2,097	1,993	1,917	1,815	1,748	1,649	1,594	1,534	1,467
70	3,978	3,128	2,736	2,503	2,346	2,231	2,074	1,969	1,893	1,790	1,722	1,622	1,566	1,505	1,435
80	3,960	3,111	2,719	2,486	2,329	2,214	2,056	1,951	1,875	1,772	1,703	1,602	1,545	1,482	1,411
100	3,936	3,087	2,696	2,463	2,305	2,191	2,032	1,927	1,850	1,746	1,676	1,573	1,515	1,450	1,376

9. F-jaotuse tabel ($1 - p = 0,99$)

v ₂	v ₁														
	1	2	3	4	5	6	8	10	12	16	20	30	40	60	120
1	4052,2	4999,5	5403,4	5624,6	5763,6	5859,0	5981,1	6055,8	6106,3	6170,1	6208,7	6260,6	6286,8	6313,0	6339,4
2	98,503	99,000	99,166	99,249	99,299	99,333	99,374	99,399	99,416	99,437	99,449	99,466	99,474	99,482	99,491
3	34,116	30,817	29,457	28,710	28,237	27,911	27,489	27,229	27,052	26,827	26,690	26,505	26,411	26,316	26,221
4	21,198	18,000	16,694	15,977	15,522	15,207	14,799	14,546	14,374	14,154	14,020	13,838	13,745	13,652	13,558
5	16,258	13,274	12,060	11,392	10,967	10,672	10,289	10,051	9,888	9,680	9,553	9,379	9,291	9,202	9,112
6	13,745	10,925	9,780	9,148	8,746	8,466	8,102	7,874	7,718	7,519	7,396	7,229	7,143	7,057	6,969
7	12,246	9,547	8,451	7,847	7,460	7,191	6,840	6,620	6,469	6,275	6,155	5,992	5,908	5,824	5,737
8	11,259	8,649	7,591	7,006	6,632	6,371	6,029	5,814	5,667	5,477	5,359	5,198	5,116	5,032	4,946
9	10,561	8,022	6,992	6,422	6,057	5,802	5,467	5,257	5,111	4,924	4,808	4,649	4,567	4,483	4,398
10	10,044	7,559	6,552	5,994	5,636	5,386	5,057	4,849	4,706	4,520	4,405	4,247	4,165	4,082	3,996
12	9,330	6,927	5,953	5,412	5,064	4,821	4,499	4,296	4,155	3,972	3,858	3,701	3,619	3,535	3,449
14	8,862	6,515	5,564	5,035	4,695	4,456	4,140	3,939	3,800	3,619	3,505	3,348	3,266	3,181	3,094
16	8,531	6,226	5,292	4,773	4,437	4,202	3,890	3,691	3,553	3,372	3,259	3,101	3,018	2,933	2,845
18	8,285	6,013	5,092	4,579	4,248	4,015	3,705	3,508	3,371	3,190	3,077	2,919	2,835	2,749	2,660
20	8,096	5,849	4,938	4,431	4,103	3,871	3,564	3,368	3,231	3,051	2,938	2,778	2,695	2,608	2,517
24	7,823	5,614	4,718	4,218	3,895	3,667	3,363	3,168	3,032	2,852	2,738	2,577	2,492	2,403	2,310
28	7,636	5,453	4,568	4,074	3,754	3,528	3,226	3,032	2,896	2,716	2,602	2,440	2,354	2,263	2,167
32	7,499	5,336	4,459	3,969	3,652	3,427	3,127	2,934	2,798	2,618	2,503	2,340	2,252	2,160	2,062
36	7,396	5,248	4,377	3,890	3,574	3,351	3,052	2,859	2,723	2,543	2,428	2,263	2,175	2,082	1,981
40	7,314	5,179	4,313	3,828	3,514	3,291	2,993	2,801	2,665	2,484	2,369	2,203	2,114	2,019	1,917
50	7,171	5,057	4,199	3,720	3,408	3,186	2,890	2,698	2,562	2,382	2,265	2,098	2,007	1,909	1,803
60	7,077	4,977	4,126	3,649	3,339	3,119	2,823	2,632	2,496	2,315	2,198	2,028	1,936	1,836	1,726
70	7,011	4,922	4,074	3,600	3,291	3,071	2,777	2,585	2,450	2,268	2,150	1,980	1,886	1,785	1,672
80	6,963	4,881	4,036	3,563	3,255	3,036	2,742	2,551	2,415	2,233	2,115	1,944	1,849	1,746	1,630
100	6,895	4,824	3,984	3,513	3,206	2,988	2,694	2,503	2,368	2,185	2,067	1,893	1,797	1,692	1,572

10. F-jaotuse tabel ($1 - p = 0,999$)

v ₂	v ₁														
	1	2	3	4	5	6	8	10	12	16	20	30	40	60	120
1	405284	499999	540379	562500	576405	585937	598144	605621	610668	617045	620908	626099	628712	631337	633972
2	998,50	999,00	999,17	999,25	999,30	999,33	999,37	999,40	999,42	999,44	999,45	999,47	999,47	999,48	999,49
3	167,03	148,50	141,11	137,10	134,58	132,85	130,62	129,25	128,32	127,14	126,42	125,45	124,96	124,47	123,97
4	74,137	61,246	56,177	53,436	51,712	50,525	48,996	48,053	47,412	46,597	46,100	45,429	45,089	44,746	44,400
5	47,181	37,122	33,202	31,085	29,752	28,834	27,649	26,917	26,418	25,783	25,395	24,869	24,602	24,333	24,060
6	35,507	27,000	23,703	21,924	20,803	20,030	19,030	18,411	17,989	17,450	17,120	16,672	16,445	16,214	15,981
7	29,245	21,689	18,772	17,198	16,206	15,521	14,634	14,083	13,707	13,226	12,932	12,530	12,326	12,119	11,909
8	25,415	18,494	15,829	14,392	13,485	12,858	12,046	11,540	11,194	10,752	10,480	10,109	9,919	9,727	9,532
9	22,857	16,387	13,902	12,560	11,714	11,128	10,368	9,894	9,570	9,154	8,898	8,548	8,369	8,187	8,001
10	21,040	14,905	12,553	11,283	10,481	9,926	9,204	8,754	8,445	8,048	7,804	7,469	7,297	7,122	6,944
12	18,643	12,974	10,804	9,633	8,892	8,379	7,710	7,292	7,005	6,634	6,405	6,090	5,928	5,762	5,593
14	17,143	11,779	9,729	8,622	7,922	7,436	6,802	6,404	6,130	5,776	5,557	5,254	5,098	4,938	4,773
16	16,120	10,971	9,006	7,944	7,272	6,805	6,195	5,812	5,547	5,205	4,992	4,697	4,545	4,388	4,226
18	15,379	10,390	8,487	7,459	6,808	6,355	5,763	5,390	5,132	4,798	4,590	4,301	4,151	3,996	3,836
20	14,819	9,953	8,098	7,096	6,461	6,019	5,440	5,075	4,823	4,495	4,290	4,005	3,856	3,703	3,544
24	14,028	9,339	7,554	6,589	5,977	5,550	4,991	4,638	4,393	4,074	3,873	3,593	3,447	3,295	3,136
28	13,498	8,931	7,193	6,253	5,656	5,241	4,695	4,349	4,109	3,795	3,598	3,321	3,176	3,024	2,864
32	13,117	8,639	6,936	6,014	5,429	5,021	4,485	4,145	3,908	3,598	3,403	3,128	2,983	2,831	2,670
36	12,832	8,420	6,744	5,836	5,260	4,857	4,328	3,992	3,758	3,451	3,258	2,984	2,839	2,686	2,524
40	12,609	8,251	6,595	5,698	5,128	4,731	4,207	3,874	3,642	3,338	3,145	2,872	2,727	2,574	2,410
50	12,222	7,956	6,336	5,459	4,901	4,512	3,998	3,671	3,443	3,142	2,951	2,679	2,533	2,378	2,211
60	11,973	7,768	6,171	5,307	4,757	4,372	3,865	3,541	3,315	3,017	2,827	2,555	2,409	2,252	2,082
70	11,799	7,637	6,057	5,201	4,656	4,275	3,773	3,452	3,227	2,930	2,741	2,469	2,322	2,164	1,991
80	11,671	7,540	5,972	5,123	4,582	4,204	3,705	3,386	3,162	2,867	2,677	2,406	2,258	2,099	1,924
100	11,495	7,408	5,857	5,017	4,482	4,107	3,612	3,296	3,074	2,780	2,591	2,319	2,170	2,009	1,829