

**Asiantuntijatiedon ja
automaattisen tietämyksen muodostamisen
vertailu Bayes-sovellusta luotaessa**
Heini Puuska

Helsinki 21. helmikuuta 2002

Älykkäiden järjestelmien tutkimusseminaari

HELSINGIN YLIOPISTO

Tietojenkäsittelytieteen laitos

Tiivistelmä

Parhaiten onnistuneet Bayes-verkkosovellukset on rakennettu käyttäen asiantuntijatietoa. Tämä on työlästä ja aikaa vievää, minkä johdosta viimeaikoina on osoitettu kiinnostusta automaattiseen oppimiseen suoraan datasta. Tässä kirjoituksessa vertaillaan asiantuntijoiden ja automaattisten menetelmien käyttöä. Viitekehyksenä toimii lapsille suunnattu desimaalilukujen opetussovellus.

1. JOHDANTO	1
2. BAYES-AJATTELUN PERUSTEET	2
3. ASiantuntijatietämys	3
4. AUTOMAATTINEN TIETÄMYKSEN MUODOSTAMINEN	5
5. ESIMERKKITAPPAUS: DESIMAALIjärjestelmän Opetussovellus	6
5.1. Aihealue ja sen merkitys	6
5.2. Asiantuntijoiden kehittämä verkko	8
5.3. Automaattisilla menetelmillä kehitetyt verkot	10
5.4. Vertailua	11
6. YHTEENVETO	11

1. Johdanto

Tähän saakka menestyksekkäimmät Bayes-verkkosovellukset on rakennettu asiantuntijoiden avulla. Tähän liittyvien käytännön ongelmien vuoksi on viime aikoina ollut paljon kiinnostusta löytää automaattisia metodeita [Nic01, KKN01]. On ollut myös yrityksiä yhdistää asiantuntijatieto ja automaattiset menetelmät, esimerkiksi “scoring metrics” -metodi [HeG95]. Mutta vielä ei ole muodostunut vakiintunutta tapaa[Nic01].

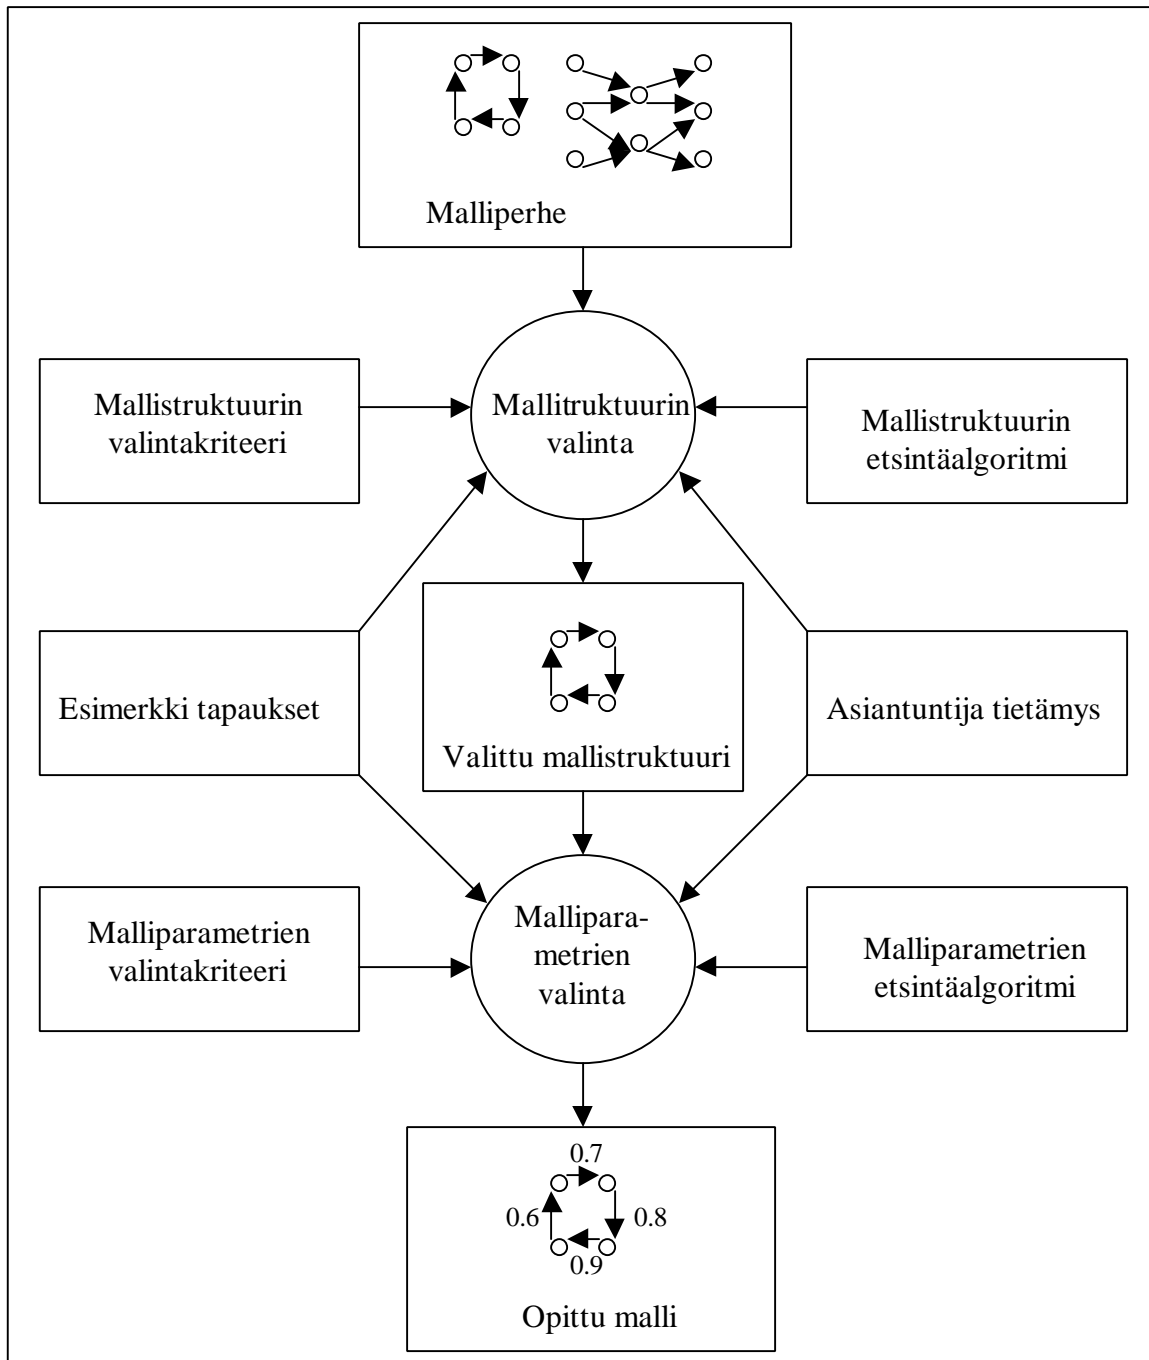
Tässä kirjoituksessa vertaillaan asiantuntijatiedon ja automaattisen tietämyksen muodostamisen käyttöä Bayes-verkkoa rakennettaessa. Ongelmaan perehdytään desimaalilukujen opetussovelluksen kautta. Sovellusta rakennettaessa kokeiltiin molempia lähestymistapoja.

Kappaleessa kaksi kerrataan Bayes-ajattelun perusteet. Kappaleessa kolme luonnehditaan asiantuntijoiden käyttöön liittyviä hyviä ja huonoja puolia. Kappaleessa neljä perehdytään automaattisiin menetelmiin. Kappaleessa viisi tarkastellaan yksityiskohtaisesti menetelmien käyttöä opetussovellusta rakennettaessa. Kappale kuusi sisältää yhteenvedon.

2. Bayes-ajattelun perusteet

Mallistruktuurilla tarkoitetaan rakennetta, joka määrää mallien määrittelemiseen tarvittavat osat. Mallilla tarkoitetaan mallistruktuuria ja siihen kiinnitettyjen parametrien arvoja. Malliperhe on joukko mallistruktuureja. Opetusjoukolla tarkoitetaan ongelmakentästä saatuja esimerkkitapauksia. Oppimisella tarkoitetaan mallin valintaa kiinnitetystä malliperheestä, annettua opetusjoukkoa hyväksi käyttäen.

Bayesläinen lähestyminen tarjoaa todennäköisyyslaskentaan perustuvan formaalin menetelmän oppivien ja älykkäiden järjestelmien rakentamiseksi. Lähtökohtana on suunnitella probabilistinen malli ongelmakentän yhteistodennäköisyysjakaumalle. Todennäköisyyksien tulkinnassa käytetään subjektiivista näkökantaa, jonka mukaan todennäköisyys on subjektiivinen epävarmuuden mitta, erotukseksi perinteisestä objektiivisestä "toistokoefrekvenssistä". Bayesiläisessä tavassa erotetaan eksplisiittisesti mallinvalintakriteeri, jonka perusteella päätetään mitkä mallit ovat sopivia käytettäväiksi eri ongelmakentissä, ja etsintäalgoritmi, jonka avulla pyritään löytämään mallinvalintakriteerin mielessä hyviä malleja. Kun mallistruktuuri on valittu, on seuraava tehtävä valita malliparametrit, ks. kuva 1 [MyT98].



Kuva1: Bayes-verkon rakentamisen vaiheet [MyT98]

3. Asiantuntijatietämys

Parhaiten onnistuneet Bayes-verkkosovellukset on rakennettu käyttäen asiantuntijätietoa. Menestyneitä sovelluksia on rakennettu mm. lääketieteellisissä diagnooseissa ja

ennustuksissa, suunnittelussa, konenäössä ja luonnollisten kielten käsittelyssä. Hollannin syöpäinstituutissa on kehitetty probabilistiseen malliin perustuva taudin tilan määrittelysovellus. Noin 86%:lle potilaista pystytään sovelluksen avulla määrittelemään taudin oikea tila [DrG01, Gaa01].

Käytännössä tiettyyn aihepiiriin liittyvän Bayes-verkon rakentaminen jakaantuu kolmeen osaan. Ensimmäiseksi täytyy identifioida tärkeät muuttujat ja niiden mahdolliset arvot. Toisena tehtävänä on identifioida muuttujien väliset suhteet, jotka ilmaistaan graafisena rakenteena. Kolmantena tehtävänä on hankkia tarvittavat todennäköisyydet, eli parametrisoida verkko. Kolmas vaihe on usein vaativa ja herättääkin kysymyksen “Mistä numerot tulevat?”. Periaatteessa nämä kolme vaihetta tulisi suorittaa peräkkäin, mutta usein niitä joudutaan käymään läpi iteratiivisesti yhä uudestaan ja uudestaan, kunnes verkko vastaa vaatimuksia [DrG01].

Asiantuntijoita voidaan menestyksekkäästi käyttää tarvittavien todennäköisyyksien määrittelyssä. He ovat myös omiaan hienosäätämään ja tarkastamaan muilla tavoin saatuja arvoja [DrG01].

Ongelmia asiantuntijoiden käytössä aiheuttavat heidän epätäydellinen tietonsa ongelmakentästä ja vaikeudet määrittellä todennäköisyyksiä. Myös arkiset seikat, kuten asiantuntijan tavoitettavuus, voivat olla ongelmallisia [KKN01]. Asiantuntijoiden toiminta ei ole myöskään aina objektiivista, vaan siihen voivat vaikuttaa asenteet. Metodit asiantuntijatietämyksen hyväksikäyttöön on alunperin kehitetty pienille muuttujamäärille. Ne sisältävät mm. haastatteluja ja ovat yleensä hyvin aikaavieviä. Yhden numeron löytäminen saattaa kestää jopa 30 minuuttia. Ja nykyaikaisissa verkoissa on usein kymmeniä tai satoja muuttujia ja satoja tai tuhansia todennäköisyyksiä. Edellä mainitun syöpäsovelluksen kehitystyö kesti kaksi vuotta. Ongelmat helposti vielä korostuvat kehistysprosessin ollessa iteratiivinen [DrG01, Gaa01].

4. Automaattinen tietämyksen muodostaminen

Automaattisen tietämyksen muodostamisen menetelmät tarjoavat lupaavia mahdollisuuksia Bayes-verkon rakentamiseksi. Verkon rakentaminen on yleensä iteratiivinen prosessi, joten luonteeltaan nopeampi automaattinen menetelmä antaa parempia mahdollisuuksia kokeilla erilaisia vaihtoehtoja mahdollisimman hyvän lopputuloksen aikaansaamiseksi.

Tärkeimmät mahdollisuudet automaattisten menetelmien käyttöön sisältyvät verkon struktuurin ja sen parametrien oppimiseen. Ensinmainitussa tapauksessa pyritään automaattisesti kehittämään verkolle suotuisa rakenne ja jälkimmäisessä tapauksessa määrittelemään sopivat parametrien arvot. Menetelmiä voi yhdistää sekä keskenään että asiantuntijoiden käyttöön.

Tunnettuja aiheeseen liittyviä sovelluksia ovat esimerkiksi CaMML ja Netica. Näistä CaMML perustuu “Minimum Message Length” –periaatteeseen, ja sitä on käytetty menestyksekkäästi mm. meri-ilmavirtoja ja lasten oppimisvaikeuksia ennustavien Baeyes-verkkojen rakenteen muodostamiseen. Neticaa taas voidaan käyttää verkon parametrien oppimiseen [KKN01, Nic01].

Automaattisten menetelmien haittapuolena on tarve riittävän suureen ja laadukkaaseen data-aineistoon, josta oppiminen suoritetaan. Lisäksi saadun verkon laadun arvioiminen on usein hankalaa, koska sen tuottamia arvioita ei voida verrata asiantuntijan vastaavassa tilanteessa tekemiin päätelmiin [Nic01].

5. Esimerkkitapaus: desimaalijärjestelmän opetussovellus

Tässä kappaleessa esitetään vertailu asiantuntijatiedon ja automaattisen tietämyksen muodostamisen käytöstä. Viitekehyksenä toimii lapsille suunnattu desimaalilukujen opetussovellus. Selostus perustuu pääasiassa Nicholson et al. artikkeliin “A Case Study in Knowledge Discovery and Elicitation in an Intelligent Tutoring Application” [Nic01].

5.1. Aihealue ja sen merkitys

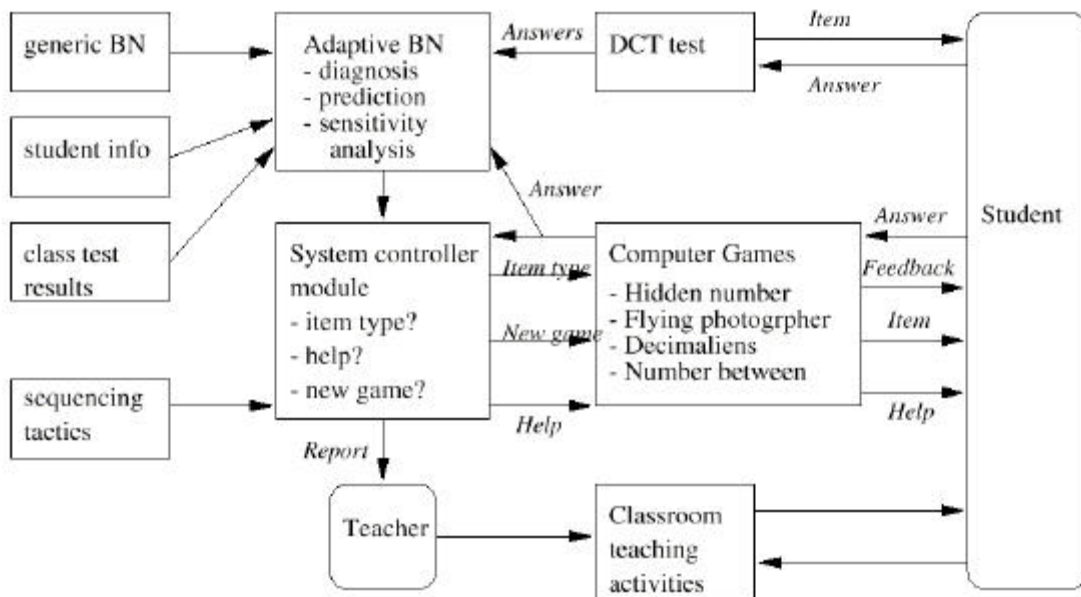
Desimaaliluvut ovat laajalti käytettyjä yhteiskunnassamme, mutta alle 70% 15-vuotiaista koululaisista osasi varmasti arvioida desimaalilukujen suhteellista kokoa. Testiin osallistui 5383 oppilasta. Toisaalta yli 30% kymmenen vuotiaista koululaisista selviytyi tehtävästä. Esimerkkinä nuorempien koululaisten yleisestä väärinymmärryksestä on että oppilas päättelee 0.4:n olevan pienempi kuin 0.35 koska jälkinmäinen luku on pidempi. Koululaisten ymmärtämystä on testattu lyhyellä testillä {Decimal Comparison Test (DCT)}. Jossa testattavien on pitänyt valita suurempi desimaaliluku 24 lukuparista. Lukuparit on pyritty valitsemaan siten, että ymmärtäminen ja väärinymmärtäminen on voitu jaotella numeroituihin kategorioihin.

Expert Class	Item type						
	1	2	3	4	5	6	
	0.4	5.736	4.7	0.452	0.4	0.42	
	0.35	5.62	4.08	0.45	0.3	0.35	
A {	ATE	H	H	H	H	H	H
	AMO	H	H	H	L	H	H
	MIS	L	L	L	L	L	L
	AU	H	H
L {	IWH	L	H	L	H	H	H
	LZE	L	H	H	H	H	H
	LRV	L	H	L	H	H	L
	LU	L	H
S {	SDF	H	L	H	L	H	H
	SRN	H	L	H	L	L	L
	SU	H	L
	UN

Kuva 2: Väärinymmärryskategoriat ja asiantuntijoiden arviot oppilaan vastauksien oikeellisuudesta.

DCT-testiä käyttämällä identifioitiin 12 oppilaiden väärinymmärryskategoriaa. Nämä ryhmiteltiin edelleen neljäksi suuremmaksi kokonaisuudeksi. Ryhmä R ajattelee että pidemmät desimaaliluvut ovat isompia numeroita, ryhmä S ajattelee että lyhyemmät desimaaliluvut ovat isompia numeroita, ryhmä A ovat “melkein asiantuntijat” ja ryhmä UN ovat muut.. Kuvasta kaksi ilmenee kategorioiden lisäksi asiantuntijoiden arviot siitä, millä todennäköisyydellä tietyn kategorian oppilas vastaa oikein. Korkeaa todennäköisyyttä merkitään H:lla ja matalaa todennäköisyyttä L:llä.

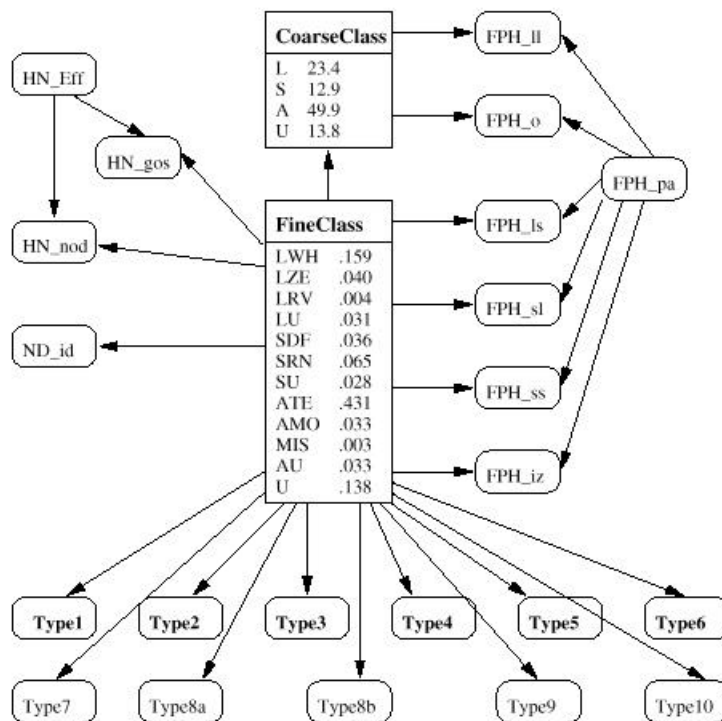
Oppilaiden väärinymmärrysten poistamiseksi kehitettiin opetussovellus, jonka arkkitehtuuri esitetään kuvassa kolme. Se perustuu erilaisiin desimaalejärjestelmää opettaviin peleihin, joiden vaikeustaso ja esitysjärjestys määräytyvät oppilaan pelisuorituksen mukaan. Sovelluksen ytimen muodostaa Bayes-verkko, jonka avulla oppilas pyritään kategorisoimaan ja ennustamaan hänen suorituksensa. Ohjelma mukautuu dynaamisesti oppilaan saavuttamiin tuloksiin.



Kuva 3: Opetussovelluksen arkkitehtuuri.

5.2. Asiantuntijoiden kehittämä verkko

Oppilaiden väärinymmärrykset on esitetty kahdella tasolla, kahden eri muuttujan avulla. *coarseClass*-solmun arvot voivat olla L, S, A ja UN isompien luokittelukokonaisuuksien mukaisesti. *fineClass*-solmun arvot voivat olla tarkemman luokittelun mukaiset 12 väärinymmärrystä. Jokaisesta DCT:n testialkiosta (vertailtavasta kuudesta lukuparityypistä) tehdään muuttuja Bayes-verkkoon edustamaan oppilaiden suoritusta kussakin tyypissä. Edellä mainitulle muuttujan arvolle harkittiin kahta vaihtoehtoista esitystapaa. Muuttujan arvo voisi olla kokonaisluku väliltä 1-N, missä N oppilaan oikdeiden vastausten lukumäärä. Toinen vaihtoehto on, että muuttujan arvot voisivat olla High, Medium tai Low sen mukaisesti kuinka oppilaat ovat pärjänneet [Nic01].



Kuva 4: Bayes-verkon rakenne.

Verkkoa parametrisoitaessa otettiin huomioon “huolimattomuusvirheet”, ts. tilanteet joissa oppilas tietää oikean vastauksen, mutta vastaa vahingossa väärin. Aina verkon muuttamisen jälkeen sen laatua arvioitiin. Arviointi perustui mm. siihen, miten hyvin

verkko pystyi asiantuntijan mielestä ennustamaan tiettyyn virhekkategoriaan kuuluvan oppilaan antamia vastauksia.

Lopullisen Bayes-verkon suorittaman oppilaan kategorisoinnin onnistuminen nähdään kuvasta neljä. Huomataan, että Bayes-verkko onnistui kategorisoinnissa n. 80-90% todennäköisyydellä. Mielenkiintoinen seikka on, että suppeampi tyyppimuuttujien arvoalue tuotti paremman tuloksen kuin vastausten oikeaan lukumäärään perustuva. Verkon kyky ennustaa oppilaan vastaus tietyn tyyppiseen tehtävään nähdään kuvasta viisi. Myös tässä huomataan, että suppeampi arvoalue oli edullinen.

Method	Type values		Match	Des. change	Undes. change
Expert BN	0-N	0.22	77.88	20.39	1.72
		0.11	82.93	15.63	1.44
		0.03	84.37	11.86	3.78
	H/M/L	0.22	80.47	18.71	0.82
		0.11	83.91	13.66	2.42
		0.03	90.40	6.48	3.12
SNOB	24 DCT		79.81	17.60	2.49
	0-N		72.06	16.00	11.94
	H/M/L		72.51	17.03	10.46
EBN learned	0-N	Avg	95.97	2.36	1.66
	H/M/L	Avg	97.63	1.61	0.75
CaMML constr.	0-N	Avg	86.51	5.08	8.41
	H/M/L	Avg	83.48	8.12	8.34
CaMML uncons.	0-N	Avg	86.15	5.87	7.92
	H/M/L	Avg	92.63	4.61	2.76

Kuva 4: Oppilaiden kategorisointi Bayes-verkon avulla.

Method	Type values		Avg Pred. Accuracy	Avg Pred. Prob.
Expert BN	0-N	0.22	0.34	0.34
		0.11	0.83	0.53
		0.03	0.82	0.70
	H/M/L	0.22	0.89	0.69
		0.11	0.89	0.80
		0.03	0.88	0.83
EBN learned	0-N	Avg	0.83	0.74
	H/M/L	Avg	0.89	0.83
CaMML constr.	0-N	Avg	0.83	0.72
	H/M/L	Avg	0.88	0.79
CaMML uncons.	0-N	Avg	0.83	0.74
	H/M/L	Avg	0.89	0.83

Kuva 5: Oppilaiden vastauksen ennustaminen Bayes-verkon avulla.

5.3. Automaattisilla menetelmillä kehitetyt verkot

Automaattisia menetelmiä sovellettiin DCT-datan luokitteluun sekä Bayes-verkon struktuurin että parametrien oppimiseen.

DCT-testiaineiston automaattiseen luokitteluun käytettiin SNOB-ohjelmaa [WaD00]. MML-menetelmään perustuva sovellus onnistui tietyin edellytyksin löytämään suurimman osan kahdestatoista väärinymmärryskategoriasta. Näinollen automaattinen luokittelu voi toimia asiantuntijalle apuna luokittelumuuttujien identifioimisessa.

Parametrien oppimiseen käytettiin luvussa kolme mainittua Netica-ohjelmistoa. Koska verkon struktuuri oli valittu asiantuntijoiden toimesta, oli kyseessä eräänlainen yhdistelmämenetelmä. Verkon tulokset oppilaiden luokittelussa ja näiden vastausten ennustamisessa olivat samaa luokkaa kuin asiantuntijoiden rakentamalla verkolla, ks. kuvat neljä ja viisi. Samansuuntaisia tuloksia on saatu myös muiden alueiden Bayes-sovelluksissa [KKN01].

Kolmantena automaattisena menetelmänä kokeiltiin verkon struktuurin muodostamista CaMML-ohjelmistolla. Muodostamista testattiin sekä antamalla joitain reunaehtoja verkon rakenteelle, että kokonaan ilman ehtoja. Saatu verkko edelleen parametrisoitiin

Netican avulla. Menetelmällä saadut tulokset olivat vertailukelpoisia muiden menetelmien kanssa, ks. kuvat neljä ja viisi.

Kaikki automaattiset menetelmät tuottivat parempia tuloksia, kun tyyppisolmujen arvoalue pidettiin suppeana.

5.4. Vertailua

Kuten kuvista neljä ja viisi on käynyt ilmeiseksi, tuottivat asiantuntijoihin perustuvat, automaattiset ja puoliautomaattiset menetelmät suunnilleen yhtä hyviä Bayes-verkkoja. Samansuuntaisia tuloksia on saatu myös muissa tutkimuksissa [KKN01].

Tietyt tekijät, kuten valittu arvoalueen suuruus, vaikuttivat jokaisen menetelmän tulokseen. Syy tähän ei ole vielä selvä.

6. Yhteenveto

Asiantuntijoiden rakentamat Bayes-verkot eivät näytä enää olevan merkittävästi laadukkaampia kuin automaattisilla tai puoliautomaattisilla menetelmillä aikaansaadut. Vaikuttaa siltä, että syyt jonkin tietyn menetelmän valitsemiseen voivatkin olla itse Bayes-ajattelutapaan liittymättömiä ulkoisia syitä, kuten asiantuntijoiden tai datan saatavuus. Todennäköisimmin hedelmällisin vaihtoehto on sellainen, jossa asiantuntija käyttää joitain automaattisia menetelmiä oman työnsä helpottamiseen ja nopeuttamiseen.

Lähteet

- DrG01 Druzdzel, M.J., van der Gaag, L.C., Building probabilistic networks: where do the numbers come from? – A guide to the literature. *IEEE Trans. on Knowledge and Data Engineering*, 12(4), 2001, 481-486.
- Gaa01 Gaag, L.C. et al., Evaluation of a probabilistic model for staging of oesophageal carcinoma. *Medical Infobahn for Europe: Proc. of MIE2000 and GMDS2000*, 2000, 772-776.
- HeG95 Heckerman, D., Geiger, D., Learning Bayesian networks. *Proc. of the 11th Conf. on Uncertainty in Artificial Intelligence*, 1995, 274-278.
- KKN01 Kennett, R.J., Korb, K.B., Nicholson, A.E., Seabreeze prediction using Bayesian networks. *Proc. of the 4th Pacific-Asia Conf. on Knowledge Discovery and Data Mining*, 2001, 148-153.
- MyT98 Myllymäki, P., Tirri, H., Bayes-verkkojen mahdollisuudet. *Teknologian Kehittämiskeskus*, 1998.
- Nic01 Nicholson, A. et al., A case study in knowledge discovery and elicitation in an intelligent tutoring application. *Proc. of the 17th Conference on Uncertainty in Artificial Intelligence*, 2001.
- WaD00 Wallace, C. S., Dowe, D.L., MML mixture modelling of multi-state, Poisson, von Mises circular and Gaussian distributions. *Statistics and Computing*, 10(1), 2000, 73-83.