



SÄÄTÖTEKNIIKAN LABORATORIO

Neuroverkot ja lingvistiset yhtälöt
jatketiilen tukkeuman ennustuksessa

Jouni Ikäheimonen ja Kauko Leiviskä

Raportti B No 38, Huhtikuu 2002

Neuroverkot ja lingvistiset yhtälöt jatkeitielen tukkeuman ennustuksessa

Jouni Ikäheimonen ja Kauko Leiviskä

Oulun yliopisto, Säätötekniikan laboratorio

Lyhennelmä: Tämä raportti on osa Tekesin ja Rautaruukin rahoittamaa tutkimushanketta 1999-2002. Raportissa verrataan neuroverkkoja ja lingvistisiä yhtälöitä keskenään jatkeitielen tukkeuman ennustuksessa. Malleissa käytetyt mittaukset on kerätty konverttereilta, huuhteluasemilta sekä jatkuvavalukoneilta. Malleja tutkittiin valukoneilla 4, 5 ja 6. Tutkitut aihioaadut olivat kaksinumeroiset 1-, 2-, 3- ja 4-alkuiset laadut, jotka ovat ns. Al-tiivistettyjä laatuja. Jatkeitielen tukkeutumien on tyypillistä em. laaduilla.

Valukoneen 4 tukkeumamalleissa käytetyt sulatukset ovat sulatusnumeroalueelta 38082- 69675. Valukoneilla 5 ja 6 malleissa käytettiin sulatusnumeroaluetta 21241- 69695. Valukoneella 4 mallit opetettiin ja testattiin ajallisesti lyhyemmällä ajanjaksolla. Valukoneen 4 aihioaadun 1 NN-mallit olivat tutkimuksen tarkimmat. Ko. NN-mallilla 73% testipisteissä mallitarkkuus oli +/-60 t sisällä. Vastaavan LE-mallin tarkkuus oli 65%. Valukoneita 5 ja 6 lyhyempi mallinnusjakso selittää osaltaan sen, että mallitarkkuus on verrattain hyvä valukoneen 4 1-aihoilla. Vuonna 2001 NN-mallien onnistumisprosentit olivat välillä 65-90% valukoneilla 5 ja 6. Vuonna 2002 mittauksia saatiin lisää, joiden avulla mallien opetusjoukkoja saatiin kasvatettua merkittävästi. NN-mallien suorituskyky ja onnistumisprosentit kuitenkin laskivat samalla 50-65% välille 5 ja 6 koneilla. LE-mallien tarkkuudet olivat tässä suuressa aineistossa samaa luokkaa. Nämä mallitarkkuudet 50-65% eivät ole riittäviä, jotta malleilla olisi käytännön merkitystä. Jos prosessimuutoksia tehdään paljon, tukkeumamallien käytettävyys on kyseenalaista.

Tässä raportissa esitetyt tukkeumamallit eivät myöskään sovellu yksinään tukkeuman ennustamiseen, vaan ne tarvitsevat lisäinformaatiota, esim. sulkutangon asentotietoja tuekseen. Neuroverkot ja lingvistiset yhtälöt voivat toimia tarkentavana päättelynä vasta, jos niiden tarkkuutta ja luotettavuutta saadaan parannettua nykyisestä. Riittävä onnistumisprosentti voisi olla 80% +/-60t tarkkuutta käytettäessä.

Hakusanat: jatkuvavalu, jatkeitieli, neuroverkot, sumea malli, lingvistiset yhtälöt, vikadiagnostiikka.

Sisällysluettelo

1	JOHDANTO	1
2	PROSESSIKUVAUS	2
3	NEUROVERKOT	4
3.1	Valukone 4	4
3.2	Valukone 5	5
3.3	Valukone 6	5
4	LINGVISTISET YHTÄLÖT	8
5	TULOSTEN TARKASTELU	10
5.1	Neuroverkot	10
5.2	Lingvistiset yhtälöt	10
6	YHTEENVETO	11

LIITE

1	Valukoneen 4 korrelaatiot aihioleaduilla 1, 2, 3 ja 4
---	---

MERKINTÖJEN SELITYKSET

Ana-	Valukoneen analyysi, aineen pitoisuus
Etu- Huuht- tai hu-	Konvertterianalyysi, aineen pitoisuus Huuhteluaseman analyysi, aineen pitoisuus
Hu_Al_tot tai huAltot	Alumiinilangan toteutunut määrä huuhtelussa
HU_3M_TOT tai hu3m	Sulan lämpötila huuhteluasemalla 3 min huuhtelun kuluttua
HUJ_TOT tai hujalt	Sulan lämpötila huuhtelun päättyessä
Hukasaik	Huuhteluaika
HuRO_TOT	Jäähdytysromun toteutunut määrä huuhtelussa
Koklev	Kokillin leveys
LE	Lingvististen yhtälöiden malli
Ok+-60t	Mallin antamien oikeinarvausten prosenttiosuus +-60t tarkkuuksilla testiaineistossa
NN	Neuroverkkomalli
S1(etuP-anaP)*	Sarjan ensimmäinen fosforipitoisuuden muutos konvertterilta valukoneelle
S1(etuV-anaV)*	Sarjan ensimmäinen vanadiinipitoisuuden muutos konverttelita valukoneelle
S1(huAO)*	Sarjan 1. sulatuksen huuhteluaseman oksidisen alumiinin pitoisuus
S1(huN)*	Sarjan 1. sulatuksen huuhteluaseman typpipitoisuus
S1vslt*	Sarjan 1. sulatuksen välisenkka lämpötila, ensimmäinen mittaus
Suhvshu*	Suhde, välisenkan keskiarvolämpötila jaettuna lämpötilaerolla huuhtelun ja välisenkan välillä, vskalt / (hujalt - vskalt)
Tukton	Jatketiilen tukkeumatonnit, ennustemallin tavoite- ja lähtösuure

Valunop tai vnop	Valunopeus, [m/min]
Vjno	Valun järjestysnumero
Vk	Valukone
Vnopero*	Valunopeusero ohjeen ja toteutuneen välillä
Vnopm*	Valunopeus kerrottuna kokillin leveydellä, valunop • koklev
Vserohka*	Välisenkan erolämpötila ohjeen ja keskiarvon välillä
Vserohs1*	Välisenkan erolämpötila ohjeen ja sarjan 1. lämpötilan välillä
Vserolika*	Välisenkan erolämpötila likviduksen ja keskiarvon välillä
Vskalt	Välisenkan keskiarvolämpötila
Vs1lt	Välisenkan lämpötila, ensimmäinen mittaus

Tarkenteet:

k1 tai k_1 Valettavaa sulatusta edeltävä sulatus

* Laskennallinen lisämuuttuja

1 JOHDANTO

Tämä raportti on osa Tekesin ja Rautaruukin rahoittamaa tutkimushanketta 1999-2002. Raportti käsittelee neuroverkkoja ja lingvistisiä yhtälöitä jatketiilen tukkeuman ennustuksessa. Raportti on jatkoa edelliselle, joka käsitteli yksinomaan neuroverkkojen käyttöä¹. Tarkoituksena on verrata näitä kahta toisistaan hieman poikkeavaa menetelmää ja mallityyppiä.

Neuroverkkomallit ja lingvististen yhtälöiden mallit muodostettiin valmiiksi kerätyn datan perusteella. Mallinnuksessa käytettiin näihin tarkoituksiin erikseen tehtyjä työkaluohjelmia. Osa datasta varattiin mallin virittämiseen tai opetusta varten ja osa siitä käytettiin mallien testaukseen. Mallinnusperiaatteista voidaan todeta seuraavaa: Mallin tulosuureiksi valittiin sellaisia muuttujia, jotka korreloivat lähtösuureeseen. Tulosuureet eivät saa korreloida keskenään voimakkaasti, ts. ne ovat keskenään riippumattomia. Mallin lähtösuureena on käytetty tonnimäärää, joka on valettu valusarjan alusta lukien tukkeumahetkellä. Mallin tulosuureiksi on valittu 4-6 kpl tukkeumatonneihin korreloivia muuttujia. Käytetyt tulosuureet riippuvat mm. valukoneesta ja ahiolaadusta. Jatketiilen tukkeentumien on erilaista eri valukoneilla ja ahiolaaduilla¹.

Tukkeumamalleja tehtiin 12 erilaiselle prosessiolosuhteelle: valukoneille 4, 5 ja 6 sekä kullekin valukoneelle neljälle ahiolaadulle (1, 2, 3, 4) erikseen. Valukoneen 4 tukkeumamallit esitetään tässä raportissa ensimmäistä kertaa.

Tässä raportissa esitetyt tukkeumamallit eivät sovellu yksinään tukkeuman ennustamiseen, vaan ne tarvitsevat lisäinformaatiota tuekseen. Yksi menetelmä on mitata sulkutangon asento valun lopussa ja päätellä asennon perusteella, onko tukkeentuminen todennäköistä kuluvan valusarjan aikana. Vasta asennonmittauksen jälkeen voidaan päättelyä tarkentaa tässä raportissa esitetyillä neuroverkoilla tai lingvististen yhtälöiden malleilla. Sulkutangon asennon käyttömahdollisuuksia tukkeentumisen ennustamisessa käsiteltiin aiemmassa raportissa².


¹ Ikäheimonen J, Leiviskä K & Ruuska J. Jatketiilen tukkeentumisen mallintaminen neuroverkoilla. Raportti B No 32. Helmikuu 2001. Oulun yliopisto, säätötekniikan laboratorio.

² Ikäheimonen J, Leiviskä K & Ruuska J. Sulkutangon asennon ja valunopeuden käyttö jatketiilen tukkeentumisen ennustamisessa. Raportti B No 33. Maaliskuu 2001. Oulun yliopisto, säätötekniikan laboratorio.

2 PROSESSIKUVAUS

Rautaruukin Raahen terästehtaalla on viisi jatkuvavalukonetta, joista kolme on ns. kaarevia valukoneita. Kaarevista valukoneista käytetään numerotunnuksia 4, 5 ja 6. Jatketiilen tukkeutumista tutkittiin nimenomaan näillä valukoneilla.

Jatketiili sijaitsee välialtan pohjassa välialtan ja kokillin välissä (kuva 1). Se on halkaisijaltaan noin 15 cm putki ja sen päässä on tavallisesti kaksi purkaussuuntaa molemmille sivuille. Purkaus ei tapahdu kohtisuoraan alaspäin, koska silloin olisi muun muassa vaara, että kuona-aineet eivät erottuisi kokilliin yläosassa valanteen pinnalle, vaan jäisivät valuaihion sisään. Jatketiili johtaa sulavirtauksen kokilliin sekä eristää sulan ja ilma-atmosfäärin toisistaan. Terässulassa on kuona-aineita, jotka pyrkivät kertymään jatketiilen seinämille. Alumiinioksidin (Al_2O_3) oletetaan olevan pääasiallinen kuona-aine, joka tukkii jatketiiltä. Kuvassa 1 on esitetty jatkuvavaluprosessiin kuuluvat pääasialliset osat.



Kuva 1. Jatkuvavaluprosessin pääosat ja jatketiilen sijainti.

Tukkeentuminen ei tapahdu silmänräpäyksessä, vaan alkanutta tukkeumaa voidaan poistaa sulkutankoa edestakaisin liikuttamalla. Näin on usein mahdollista valaa sarja loppuun ilman jatketiilen vaihtoa. Erilaisia jatketiilimateriaaleja on olemassa useita, samoin kuin mitoiltaan ja rakenteiltaan erilaisia jatketiiliä.

Edellisessä tutkimuksessa¹ kerrottiin, mitkä eri tekijät todennäköisesti vaikuttavat jatkeilun tukkeentumisilmiöön data-analyysin perusteella. Data-analyysi osoitti, että tukkeentuminen on yleistä AI-tiivistetyillä sulatuksilla. Ahiolaadut, joilla tukkeentumien on yleistä ovat kaksinumeroiset 1-, 2-, 3- ja 4-alkuiset laadut. Lanssihuuhtelun havaittiin lisäävän ainakin jossain määrin tukkeentumista pohjahuuhteluun verrattuna. Lisäksi valuhäiriöt, kuten terässenkan happiaukaisut ja avosuihkuvalut lisäävät tukkeentumista toisiohapettumisen seurauksena. Data-aineisto rajattiin em. tekijöiden mukaan tukkeumamalleja varten. Vain tukkeentuneiden valusarjojen mittauksia voitiin käyttää mallinnuksen perustana, koska onnistuneissa valusarjoissa ei voida sanoa tarkkaan, missä tonnimäärässä nämä valusarjat olisivat tukkeentuneet, jos valua olisi jatkettu pidempään.

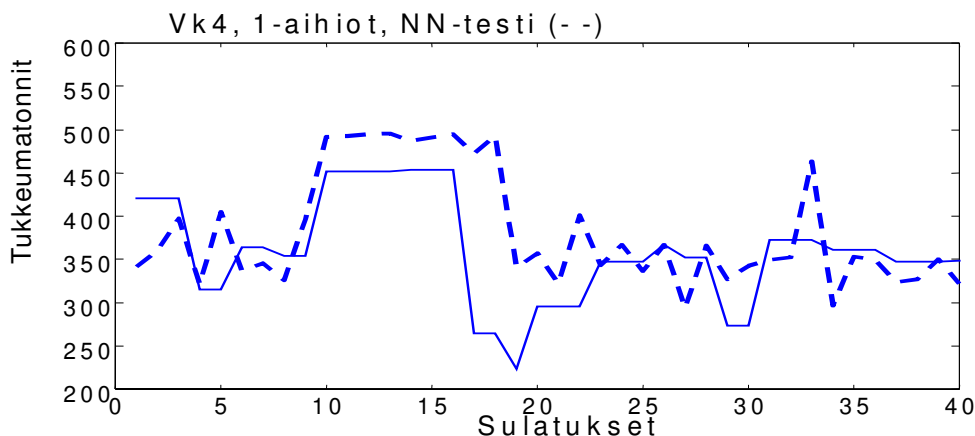
3 NEUROVERKOT

Neuroverkot opetettiin Matlab NN-toolbox-työkaluohjelmalla. Neuroverkkomalleissa käytettiin 2-kerrosverkkoja, joiden 1. kerros sisälsi epälineaariset aktivointifunktiot ($y=\tanh(x)$) ja lähtökerroksessa oli yksi lineaarinen funktio ($y=x$). Verkon parametrien lukumäärä valittiin siten, ettei se ollut opetusjoukkoa suurempi. Työkaluohjelmalla laskettiin verkon painokertoimet ja bias-arvot backpropagation-proseduurilla. Kukin tapaus vaati useita opetuskertoja, koska neuroverkon parametrit voivat vaihdella, vaikka lähtötiedostot eivät muutukaan. Lisäksi kunkin opetuskerran sisällä verkkoparametrien päivitysten lukumäärä vaikuttaa lopputulokseen. Mallinnusperiaatteet esitettiin tarkemmin aiemmassa raportissa¹.

3.1 Valukone 4

Tukkeentumien mallitus onnistui nyt ensimmäistä kertaa valukoneella 4. Aiemmin mittausten vähäinen määrä teki mallinnuksen mahdottomaksi. Valukoneella 4 tukkeumiin vaikuttavat suureet on esitetty aihiolaatukohtaisesti korrelaatiotaulukkoina Liitteessä 1. Korrelaatioista todettakoon, että aihiolaaduilla 2 ja 4 datapisteitä oli käytössä alle 30; 2-laadulla 28 pistettä ja 4-laadulla 24 pistettä. Osaltaan tämä seikka selittää joidenkin muuttujien voimakkaat korrelaatiot tukkeumatonneihin. Esim. 4-laadulla etuC ja huAO korreloivat voimakkaasti tukkeumatonneihin kertoimilla 0.59 ja 0.62. 1-laadulla datapisteitä oli käytössä 90 kpl ja 3-laaduilla 50 kpl, eikä näissä datajoukoissa havaittu erityisen suuria korrelaatioita tukkeumatonneihin (Liite1).

Vk4:n 1-aihiolla kokeiltiin tukkeuman ennustamista seuraavilla muuttujilla: hujalt, huAltot, vjno, anaB_k1, anaMn_k1. Nämä muuttujat syötettiin samanaikaisesti 2-kerrosneuroverkkoon, joka opetettiin ja testattiin. Kuvassa 2 on esitetty ko. neuroverkon toiminta testiaineistossa 1-aihiolla.



Kuva 2. Vk4 1-aihiot. Neuroverkon testaus jatketiilen tukkeuman ennustuksessa. Katoviiva kuvaa mallin toimintaa. OK \pm 60 \pm = 73%. Käytetyt muuttujat: hujalt, huAltot, vjno, anaB_k1, anaMn_k1. Aktivointifunktiot: 6 kpl $y=\tanh(x)$, 1 kpl $y=x$.

Aihiolaatujen 2, 3 ja 4 osalta mallin toiminta selviää Taulukosta 1, johon on koottu valukoneen 4 neuroverkkomallit ahiolaaduilla 1, 2, 3 ja 4. Ahiolaaduilla 1 ja 3 on käytetty kahden sulatuksen mallia. Ahiolaadulla 1 korrelaatiot olivat liian heikkoja, jos muuttujia otettiin vain yhdestä sulatuksesta, eikä kahdenkaan sulatuksen avulla korreloivia muuttujia löytynyt kuin 7-9 kpl (Liite1). Myös 3-laadulla korreloivien muuttujien määrää lisättiin laskemalla korrelaatiot kahdesta peräkkäisestä sulatuksesta ja valusta.

Taulukko 1. Neuroverkkojen onnistumisprosentit +/-60t tarkkuudella. Valukone 4.

Vk, aihiot, sulatuksia mallissa, mallino.	Sisäänmenosuureet (k1= edellinen sulatus)	NN Ok+-60t (%)	Testipisteitä	Opetuspisteitä	NN-rakenne	NN-parametrit (kpl)
4, 1, 2, 1	hujalt, huAltot, vjno, anaB_k1, anaMn_k1	73	40	51	6,1	43
4, 2, 1, 2	etuC, huN, vnopm, vjno	60	15	24	3,1	19
4, 3, 2, 3	s1huAO, vs1lt, valunop, vjno, huROtot_k1, s1(etuV-anaV)	73	15	35	4,1	33
4, 4, 1, 4	etuC, huAO, s1vslt, vjno	79	14	20	3,1	19

Taulukon 1 neuroverkkojen parametrien lukumäärät määräytyvät kunkin opetusjoukon koon mukaan. Parametrien määrä ei saisi ylittää opetuksessa käytettyjen esimerkkipisteiden määrää.

3.2 Valukone 5

Valukoneella 5 tukkeuminen mallitusta varten on olemassa jo paljon mittauksia. Aiemmassa raportissa esitettiin valukoneen 5 korrelaatiot ahiolaatukohtaisesti sen liiteosassa. Seuraavaan Taulukkoon 2 on koottu tämänhetkiset neuroverkkomallit sekä niiden toiminta testiaineistossa valukoneella 5. Neuroverkkojen tulosuureet ovat samoja kuin aiemmassa raportissa¹. Opetusdatan määrä on 1-aihioita lukuunottamatta karkeasti ottaen tuplaantunut verrattuna vuoden 2001 helmikuussa käytetyissä olleeseen datamäärään. 1-aihioilla opetusaineiston koko säilytettiin lähes samana ja se on kooltaan 100 pistettä. Muilla aihioilla 2, 3, ja 4 opetusdatamäärää kasvatettiin vuoden 2001 helmikuun noin 40 pisteestä 60-70 pisteeseen. Taulukossa 2 osa malleista käsittää kaksi peräkkäistä sulatusta. Ahiolaaduilla 2 ja 3 esitetyt mallit ovat suurimmalta osaltaan kahden sulatuksen malleja. Taulukon 2 NN-rakenne (6,1) tarkoittaa kaksikerrosverkkoa, jossa ensimmäinen kerros koostuu 6 kpl tanh-funktiosta ja toinen kerros pitää sisällään yhden lineaarisen funktion ($y=x$). Kaikissa malleissa on käytetty tätä neroverkkorakennetta.

3.3 Valukone 6

Valukoneella 6 tukkeuminen mallitusta varten on myös olemassa mittauksia riittävästi mallien opetukseen ja testaukseen. Ahiolaadulla 4 mittauksia ei ollut vielä riittävästi

vuonna 2001. Silloin mittauksia oli käytössä vain 24 sulatuksesta 4-laadulla. Nyt niitä on 65 sulatuksesta. Aiemmassa raportissa esitettiin valukoneen 6 korrelaatiot aiholaatukohtaisesti sen liiteosassa. Taulukkoon 3 on koottu tämänhetkiset neuroverkkomallit sekä niiden toiminta testiaineistossa valukoneella 6. Neuroverkkojen sisäänmenosuureet ovat samoja, kuin aiemmassa raportissa. Aiholaatua 4 ei voi verrata aiempaan raporttiin, koska tässä raportissa 4-laadun mallissa on käytetty erilaisia muuttujia.

Taulukko 2. Neuroverkkojen onnistumisprosentit +/-60t tarkkuudella. Valukone 5. Tilanne huhtikuussa 2002 ja helmikuussa 2001, sekä muutos näiden välillä.

Vk, aihiot, sulatuksia mallissa, mallino	Sisäänmenosuureet (k1= edellinen sulatus)	NN Ok+-60t (%)	Testipisteitä	Opetuspisteitä	NN-rakenne	Helmikuu-01 NN Ok+-60t (%)	EroNNok+-60t-NN(helmikuu-01)
5, 1, 1, 5	huN, vskalt, vserohs1, vnopt, vjno	52	182	100	6,1	64	-12%
5, 1, 1, 6	s1huN, vserolika, vserohs1, vjno	54	182	100	6,1	68	-14%
5, 2, 2, 7	huAO, vskalt, vnopt, vjno, huAltot_k1, vs1lt_k1, vnoptero_k1	60	30	60	6,1	64	- 4%
5, 2, 1, 8	huAO, vskalt, s1vslt, vnopt, vjno	<50	64	60	6,1	49	?
5, 2, 2, 9	huAO, vskalt, vjno, (anaAO-huAO)_k1, vs1lt_k1, vnopt_k1	50	30	60	6,1	65	-15%
5, 3, 2, 10	huAM, vskalt, hu3mlt_k1, anaN_k1, anaAM_k1, vnopt_k1	59	64	60	6,1	63	- 4%
5, 3, 2, 11	hukasaik, vserohs1, vjno, s1(etuP-anaP), anaAl_k1, vnopt_k1	56	64	60	6,1	80	-24%
5, 4, 2, 12	suhvshu, vnopt, hu3mlt_k1, anaB_k1, anaS_k1, vnopt_k1	54	37	60	6,1	75	-21%
5, 4, 1, 13	hujlt, etuV, suhvshu, vnopt, koklev	54	68	72	6,1	68	-14%
5, 4, 1, 14	hujlt, etuV, suhvshu, koklev	56	68	72	6,1	68	-12%

Opetusdatan määrä on 1-aihoita lukuunottamatta karkeasti ottaen tuplaantunut verrattuna vuoden 2001 helmikuussa käytävissä olleeseen datamäärään. 1-aihoilla opetusaineiston koko on kooltaan 100 pistettä. Muilla aihioilla 2 ja 3 opetusdatamäärää kasvatettiin vuoden 2001 helmikuun noin 30 pisteestä 50-60 pisteeseen.

Taulukko 3. Neuroverkkojen onnistumisprosentit +/-60t tarkkuudella. Valukone 6.
Tilanne huhtikuussa 2002 ja helmikuussa 2001, sekä muutos näiden välillä.

Vk, aihiot, sulatuksia mallissa, mallino	Sisäänmenosuureet (k1= edellinen sulatus)	NN Ok+-60t (%)	Testipisteitä	Opetuspisteitä	NN-rakenne	Helmikuu-01 NN Ok+-60t (%)	EroNNok+-60t- NN(helmikuu-01)
6, 1, 1, 15	s1huN, vs1lt, vserohs1, vnopm, vjno	63	100	100	6,1	61	+2 %
6, 1, 1, 16	etuP, s1huN, s1huAO, vs1lt, vserohs1	59	100	100	6,1	77	-18%
6, 1, 1, 17	etuP, s1huN, vserohs1, koklev, vjno	58	100	100	6,1	84	-26%
6, 1, 1, 18	etuP, etuV, vserohs1, koklev, vjno	62	100	100	6,1	78	-16%
6, 2, 1, 19	hujlt, huN, s1vslt, vnopm	65	26	60	6,1	81	-16%
6, 2, 1, 20	huN, suhvshu, vnopm	58	26	60	6,1	73	-15%
6, 2, 1, 21	hujlt, s1huN, koklev, vjno	58	26	60	6,1	84	-26%
6, 3, 1, 22	huALtot, huN, vserohka	56	27	50	6,1	89	-33%
6, 3, 1, 23	huALtot, huN, vserohka, koklev, vjno	63	27	50	6,1	64	-1%
6, 3, 1, 24	huALtot, huN, vserohka, koklev	56	27	50	6,1	56	+0%
6, 4, 2, 25	HuAltot,s1huAO, suhvs ,vjno, anaN_k1 vskalt_k1	63	16	28	3,1	?	?

4 LINGVISTISET YHTÄLÖT

Lingvististen yhtälöiden muodostaminen tapahtui FuzzEqu-työkaluohjelmalla, joka toimii Matlab-ympäristössä. Lingvististen yhtälöiden menetelmässä mallien generointi tapahtuu monivaiheisesti. Mallitus käsittää pääpiirteissään seuraavia vaiheita: muuttujien jäsenyysastemäärittelyt, jäsenyysfunktioimäärittelyt sekä lingvististen yhtälöiden ratkaisun yhtäaikaan useamman muuttujan avulla. Mallissa käytettävät muuttujat voidaan valita omatoimisesti. Erona neuroverkkomenetelmään lingvistiset yhtälöt voidaan muodostaa yhdellä opetuskerralla, eikä opetuskertojen lukumäärällä ole vaikutusta mallin parametreihin samoja lähtötiedostoja käytettäessä.

Lingvistisissä yhtälöissä käytettiin samoja tulosuureita kuin edellä neuroverkkomalleissa. Myös data jaettiin samalla tavalla. Opetus- ja testiaineistot ovat täysin samoja kuin neuroverkkomalleissa. Näin toimittiin, jotta malleja voidaan verrata keskenään jatketuille tukkeuman ennustuksessa. Taulukkoon 4 on koottu lingvististen yhtälöiden mallit ja niiden suorituskyky valukoneilla 4, 5 ja 6. Taulukossa 4 on esitetty myös vastaavien neuroverkkojen onnistumisprosentit +/-60t tarkkuuksilla. Suorituskyky on ilmoitettu onnistumisprosentteina (ok+-60t) testiaineistossa.

Taulukko 4. Neuroverkkojen ja lingvististen yhtälöiden välinen vertailu. Valukoneet 4, 5 ja 6. LE = lingvistinen yhtälö, NN = neuroverkko.

Vk, aihiot, sulatuksia mallissa, mallino	Tulomuuttujat (k1= edellinen sulatus)	LE Ok+-60t (%)	Testipisteitä	Opetuspisteitä	NN Ok+-60t (%)
4, 1, 2, 1	hujalt, huAltot, vjno, anaB_k1, anaMn_k1	65	40	51	73
4, 2, 1, 2	etuC, huN, vno pm, vjno	47	15	24	60
4, 3, 2, 3	s1huAO, vs1lt, valunop, vjno, huROtot_k1, s1(etuV-anaV)	47	15	35	73
4, 4, 1, 4	etuC, huAO, s1vslt, vjno	50	14	20	79
5, 1, 1, 5	huN, vskalt, vserohs1, vno pm, vjno	55	182	100	52
5, 1, 1, 6	s1huN, vserolika, vserohs1, vjno	56	182	100	54
5, 2, 2, 7	huAO, vskalt, vno pm, vjno, huAltot_k1, vs1lt_k1, vno pero_k1	60	30	60	60
5, 2, 1, 8	huAO, vskalt, s1vslt, vno pm, vjno	<50	64	60	<50
5, 2, 2, 9	huAO, vskalt, vjno, (anaAO-huAO)_k1, vs1lt_k1, vno p_k1	40	30	60	50
5, 3, 2, 10	huAM, vskalt, hu3mlt_k1, anaN_k1, anaAM_k1, vno pm_k1	65	64	60	59
5, 3, 2, 11	hukasaik, vserohs1, vjno, s1(etuP-anaP), anaAl_k1, vno pm_k1	59	64	60	56
5, 4, 2, 12	suhvshu, vno pm, hu3mlt_k1, anaB_k1, anaS_k1, vno p_k1	54	37	60	54
5, 4, 1, 13	hujlt, etuV, suhvshu, vno pm, koklev	<50	68	72	54
5, 4, 1, 14	hujlt, etuV, suhvshu, koklev	<50	68	72	56

Vk, aihiot, sulatuksia mallissa, mallino	Tulomuuttujat (k1= edellinen sulatus)	LE Ok+-60t (%)	Testipisteitä	Opetuspisteitä	NN Ok+-60t (%)
6, 1, 1, 15	s1huN, vs1lt, vserohs1, vnopt, vjno	62	100	100	63
6, 1, 1, 16	etuP, s1huN, s1huAO, vs1lt, vserohs1	58	100	100	59
6, 1, 1, 17	etuP, s1huN, vserohs1, koklev, vjno	57	100	100	58
6, 1, 1, 18	etuP, etuV, vserohs1, koklev, vjno	59	100	100	62
6, 2, 1, 19	hujlt, huN, s1vslt, vnopt	58	26	60	65
6, 2, 1, 20	huN, suhvshu, vnopt	54	26	60	58
6, 2, 1, 21	hujlt, s1huN, koklev, vjno	62	26	60	58
6, 3, 1, 22	huALtot, huN, vserohka	59	27	50	56
6, 3, 1, 23	huALtot, huN, vserohka, koklev, vjno	56	27	50	63
6, 3, 1, 24	huALtot, huN, vserohka, koklev	56	27	50	56
6, 4, 2, 25	HuAltot,s1huAO, suhvs ,vjno, anaN_k1 vskalt_k1	69	16	28	63

5 TULOSTEN TARKASTELU

5.1 Neuroverkot

Valukoneella 4 tukkeumien neuroverkkomallinnus onnistui siten, että 60-73% testipisteissä mallin tarkkuus oli +/-60t sisällä (Taulukko 1). Valukoneella 4 vain 1-aihiolaadulla mittausten määrä oli riittävä (40) mallin testausta ajatellen. Muilla aihioilla 2, 3 ja 4 testipisteitä jäi jäljelle vain noin 15, joka ei välttämättä anna kuvaa mallin lopullisesta suorituskyvystä. Valukoneen 4 malleissa on käytetty sulatuksia numeroalueelta 38082- 69675.

Taulukosta 2 nähdään, että valukoneella 5 mallien onnistumisprosentit ovat laskeneet vuoden 2001 tilanteeseen verrattuna. Nyt (huhtikuussa 2002) mallien onnistumisprosentit ovat hieman yli 50% ja vuonna 2001 ne olivat yleisesti noin 70%. Neuroverkkojen kyky ennustaa jatkeitielen tukkeentuminen on pudonnut noin 20%:lla. Valukoneella 5 mittausten määrä oli riittävä kaikilla aihioilaaduilla myös testausta ajatellen. Valukoneen 5 malleissa on käytetty sulatuksia numeroalueelta 21402- 69695.

Taulukosta 3 nähdään, että valukoneella 6 mallien onnistumisprosentit ovat laskeneet vuoden 2001 tilanteeseen verrattuna. Nyt (huhtikuussa 2002) mallien onnistumisprosentit ovat 56-63% ja vuonna 2001 ne olivat 61-89%. Yleisesti neuroverkkojen kyky ennustaa jatkeitielen tukkeentuminen on pudonnut 15-30%. Poikkeuksen muodostavat mallinumerot 15, 23 ja 24, joissa onnistumisprosentit eivät ole juuri muuttuneet, vaikka käytettyjen mittausten lukumäärä on kasvanut merkittävästi sekä opetuksessa että testauksessa. Toisaalta nämä mallit olivat suorituskyvyltään muita heikompia vuoden 2001 aineistossa. Valukoneella 6 mittausten määrä oli riittävä aihioilaaduilla 1, 2 ja 3 myös testausta ajatellen. Aihioilaadulla 4 mallin testaus vaatii lisää mittauksia. Valukoneen 6 malleissa on käytetty sulatuksia numeroalueelta 21241-69221.

Valukoneella 4 mallinnus käsitti sulatuksia ajallisesti lyhyemmältä jaksolta kuin valukoneiden 5 ja 6 tukkeumamallit. Valukoneella 4 ei käytetty sulatusnumeroaluetta 21000-38000 lainkaan, mikä taas sisältyi valukoneiden 5 ja 6 malleihin. Tämä seikka selittää ainakin osittain sen, että valukoneella 4 tukkeumamallit olivat tarkempia kuin 5 ja 6 koneilla. Myös taulukoiden 2 ja 3 ennustustarkkuuksien muutokset valukoneilla 5 ja 6 vuoden 2001 helmikuun ja vuoden 2002 huhtikuun välillä olivat miinusmerkkisiä 15-30%. Tämä asia vahvistaa käsitystä siitä, että mallit huononevat ajan kuluessa.

5.2 Lingvistiset yhtälöt

Taulukon 4 mukaan mallinnumeroissa 5, 6, 10, 11, 21, 22 ja 25 LE-malli on NN-mallia suorituskkyisempi. Ero on 2-6% LE-mallin hyväksi. Muiden mallien osalta NN-malli toimii tarkemmin kuin LE-malli. Näissä malleissa NN-malli on 1-8% LE-mallia parempi. Lingvististen yhtälöiden mallit toimivat jatkeitielen tukkeuman ennustamisessa käytännössä yhtä hyvin kuin neuroverkot. Erot neuroverkkomallien suorituskkyyn ovat marginaalisia.

6 YHTEENVETO

Valukoneen 4 aihiolaadun 1 NN-mallit olivat tutkimuksen tarkimmat. NN-mallilla 73% testipisteissä mallitarkkuus oli +/-60 t sisällä. Vastaavan LE-mallin tarkkuus oli 65%. Testiaineisto oli kooltaan 40 pistettä ja testin luotettavuus oli tässä mielessä hyvä. Aihiolaaduilla 2 ja 4 opetusjoukkojen koot jäivät alle 30 pisteeseen. Näissä tapauksissa valukoneen 4 mallit eivät ole välttämättä vielä valmiita. Aihiolaadulla 3 opetuksessa on 35 pistettä, mutta testiaineistosa vain 15.

Valukoneen 4 tukkeumamalleissa käytetyt sulatukset ovat sulatusnumeroalueelta 38082-69675. Valukoneilla 5 ja 6 malleissa käytettiin sulatusnumeroaluetta 21241- 69695. Valukoneella 4 mallit opetettiin ja testattiin ajallisesti lyhyemmällä ajanjaksolla. Tämä saattaa olla osatekijä sille, että valukoneen 4 1-aihioiden mallit olivat kaikkein suorituskykyisimpiä.

Valukoneilla 5 ja 6 mittauksia oli malleja varten riittävästi käytössä. Valukoneilla 5 ja 6 neuroverkot ja lingvistiset yhtälöt näyttävät toimivan käytännössä samalla tavalla jatketiilen tukkeuman ennustamisessa. Kuitenkin ainakin neuroverkkojen suorituskyky heikkenee ajan kuluessa. Kun mallitus tehtiin lyhyemmän ajanjakson datan perusteella, NN-mallit olivat hyvinkin suorituskykyisiä. NN-mallien onnistumisprosentit olivat vuonna 2001 välillä 65-90% valukoneilla 5 ja 6. Vuonna 2002 mittauksia saatiin lisää, joiden avulla mallien opetusjoukkoja saatiin kasvatettua merkittävästi. NN-mallien suorituskyky ja onnistumisprosentit kuitenkin laskivat samalla 50-65% välille. LE-mallien tarkkuudet olivat tässä suuressa aineistossa samaa luokkaa. Nämä mallitarkkuudet 50-65% eivät ole riittäviä, jotta malleilla olisi käytännön merkitystä.

Miten tukkeumamallit saadaan pysymään tarkkoina monta vuotta ilman, että niitä tarvitsee päivittää, on kysymys, johon tarvitaan vastaus ennen mallien käyttöönottoa. Jos prosessimuutoksia tehdään paljon, tukkeumamallien käytettävyys on kyseenalaista.

VK 4 KORRELAATIOT
AIHIOLAATU 1

LIITE 1

VALUSSAOLEVA SULATUS	
hujalt	-0.18
HuALtot	-0.25
vjno	0.41

EDELLINEN SULATUS	
hujalt_k1	-0.22
huROtot_k1	0.19
anaB_k1	-0.29
anaMn_k1	0.28
etuC_k1	0.18
huAO_k1	-0.20
tukton	1.00

AIHIOLAATU 2
VALUSSAOLEVA SULATUS

hujalt	0.25
hukasaika	-0.29
huALtot	-0.30
etuC	0.29
huN	-0.37
s1huN	0.27
huAO	0.21
vnop	0.20
vjno	0.28

EDELLINEN SULATUS	
HuROtot_k1	0.28
AnaB_k1	0.44
AnaN_k1	-0.29
AnaS_k1	0.26
AnaV_k1	0.36
EtuC_k1	0.30
EtuP_k1	0.20
s1(etuP-anaP)	0.34
huN_k1	-0.32
s1(anaN-huN)	0.31
ero(anaAO-huAO)_k1	-0.20
vnopero_k1	-0.23
vnopm_k1	0.32
tukton	1.00

VK 4 KORRELAATIOT
AIHIOLAATU 3

LIITE 1

VALUSSAOLEVA SULATUS	
hujalt	0.26
huROtot	0.23
huALtot	0.26
etuV	0.20
huAM	-0.20
s1huAO	0.40
vskalt	0.28
vs1lt	0.34
vserohka	-0.27
vserolika	-0.27
valunop	-0.36
vnopero	0.23
vnopm	-0.21
vjno	0.39

EDELLINEN SULATUS	
hu3m_k1	0.24
huROtot_k1	0.29
huALtot_k1	0.25
anaAL_k1	-0.26
anaAM_k1	-0.22
etuP_k1	0.21
etuV_k1	0.25
ero(etuV-anaV)_k1	0.35
s1(etuV-anaV)	0.41
ero(etuP-anaP)_k1	0.20
HuAL_k1	-0.24
HuAM_k1	-0.31
HuAO_k1	0.24
ero(anaAO-huAO)_k1	-0.20
vskalt_k1	0.22
vs1lt_k1	0.27
vserohka_k1	-0.23
vserolika_k1	-0.23
vnopero_k1	-0.17
vnopm_k1	0.19
tukton	1.00

VK 4 KORRELAATIOT
AIHIOLAATU 4

LIITE 1

VALUSSAOLEVA SULATUS

hujalt	-0.27
etuC	0.59
etuP	0.24
etuV	0.24
huAL	-0.37
huAO	0.62
vskalt	-0.18
vs1lt	-0.29
s1vs1lt	-0.42
vserohs1	0.34
vnopero	-0.32
vjno	0.40

EDELLINEN SULATUS

hujalt_k1	-0.33
huALtot_k1	0.23
anaN_k1	0.23
anaP_k1	0.22
anaAO_k1	-0.36
etuC_k1	0.38
ero(etuP-anaP)_k1	-0.23
ero(anaN-huN)_k1	0.46
huAl_k1	0.26
huAM_k1	0.32
huAO_k1	-0.22
vskalt_k1	-0.20
vs1lt_k1	-0.39
vnopero_k1	-0.34
tukton	1.00

ISSN 1238-9404

Oulun yliopisto

Säätötekniikan laboratorio – Sarja B

Toimittaja: Leena Yliniemi

1. Yliniemi L & Koskinen J, Rumpukuivaimen sumea säätö. Joulukuu 1995. 17 s. 6 liitettä. ISBN 951-42-4301-3.
2. Leiviskä K, Rauma T, Ahola T, Juuso E, Myllyneva J & Alahuhta P, Sumea mallintaminen, viritys ja säätö. Tammikuu 1996. 44 s. ISBN 951-42-4348-X.
3. Altavilla M, Koskinen J & Yliniemi L, Rumpukuivaimen säätö neuroverkolla. Tammikuu 1996. 12 s. ISBN 951-42-4373-0.
4. Myllyneva J, Leiviskä K, Heikkinen M, Kortelainen J & Komulainen K, Sumean säädön käyttömahdollisuudet hiertämön ohjauksessa. Huhtikuu 1997. 52 s. ISBN 951-42-4647-0.
5. Leiviskä K & Heikkinen M, TMP-prosessin mallintaminen ja mallipohjainen säätö. Huhtikuu 1997. 68 s. ISBN 951-42-4646-2.
6. Jaako J, Nopeusyhtälön parametrien sovittaminen. Huhtikuu 1998. 25 s. ISBN 951-42-4961-5.
7. Myllyneva J, Kortelainen J, Latva-Käyrä K, Nystedt H & Leiviskä K, Hiertämön laatusäädöt. Syyskuu 1998. ISBN 951-42-5023-0.
8. Lähteenmäki M & Leiviskä K, Tilastollinen prosessinohjaus: perusteet ja menetelmät. Lokakuu 1998. ISBN 951-42-5064-8.
9. Tervahartiala P & Leiviskä K, Tilastollinen prosessinohjaus: ohjelmistoverailu. Elokuu 1999. ISBN 951-42-5343-4.
10. Jaako J, Eräitä optimointitehtäviä. Syyskuu 1999. 39 s. ISBN 951-42-5352-3.
11. Jaako J, Yksinkertaisia prosessimalleja. Syyskuu 1999. 73 s. ISBN 951-42-5353-1.
12. Jaako J, MATLAB-ohjelman käyttö eräissä prosessiteknisissä laskuissa. Syyskuu 1999. 61 s. ISBN 951-42-5354-X.
13. Jaako J, Säätötekniikan laboratorion opetuskokeiluja I – Portfoliomuotoisen kurssin toteutus ja tulokset. Helmikuu 2000. 28 s. ISBN 951-42-5544-5.
14. Ahola T, Ruuska J, Juuso E & Leiviskä K, Paperikoneen katkoherkkyyssindikaattori. Helmikuu 2000. 33 s. ISBN 951-42-5563-1.
15. Ylikunnari J, InTouch valvomo-ohjelmiston implementointi lämmönsiirron identifiointiprosessiin (PS II:n harjoitustyölaitteisto). Maaliskuu 2000. ISBN 951-42-5568-2.
16. Mäki T & Juuso E, Tapahtumapohjainen sumea lingvistinen yhtälöjärjestelmä lääkevalmisteiden koostumusten ja valmistusprosessien tutkimuksessa. Kesäkuu 2000. ISBN 951-42-5678-6.
17. Jaako J, Säätötekniikan laboratorion opetuskokeiluja II – Apuopettaja opettajan apuna. Elokuu 2000. 22 s. ISBN 951-42-5742-1.
18. Sivonen J, Johdatus säätötekniikkaan, opetuslaitteiston suunnittelu ja toteutus. Syyskuu 2000. 20 s. ISBN 951-42-5795-2.
19. Mutka P, Neuraalilaskenta ja epälineaarinen dynamiikka komponenttien kulutus- ja myyntiennusteiden laatimisessa. Joulukuu 2000. 41 s. ISBN 951-42-5873-8.
20. Komulainen K & Juuso E, Vikatietojen hyödyntäminen funktionaalisessa testauksessa. Joulukuu 2000. 22 s. ISBN 951-42-5874-6.
21. Ikäheimonen J, Juuso E, Leiviskä K & Murtovaara S, Sulfaatisellun menetelmät, keiton ohjaus ja massan pesu. Joulukuu 2000. 48 s. ISBN 951-42-5875-4.
22. Ikäheimonen J, Juuso E, Leiviskä K, Murtovaara S & Sutinen R, Keittoliipeä- ja massa-analyysi sellun keitossa ja pesussa. Joulukuu 2000. 35 s. ISBN 951-42-5876-2.

25. Rahikka L & Juuso E, Sulfaatisellun eräkeittoprosessin jatkuvatoiminen analysointi. Joulukuu 2000. 36 s. ISBN 951-42-5879-7.
26. Pirttimaa M & Leiviskä K, Tilastollinen prosessinohjaus: Pastapainoprosessin tehdaskokeet. Joulukuu 2000. ISBN 951-42-5884-3.
27. Jaako J & Nelo S, Prosessi- ja ympäristötekniikan opetuksen tulevaisuuden haasteita. Tammikuu 2001. ISBN 951-42-5889-4.
28. Näsi J, Isokangas A & Juuso E, Klusterointi kuorimon puuhäviöiden mallintamisessa. Tammikuu 2001. ISBN 951-42-5894-0.
29. Mäki T & Juuso E, Lingvistinen yhtälöjärjestelmä lääkevalmisteiden rakeistusprosessin dynaamisessa simuloinnissa. Tammikuu 2001. ISBN 951-42-5895-9.

31. Joensuu P, Vikadiagnostiikka sulatuksen laadunohjauksessa: Syherön syntyminen ja siihen vaikuttavat tekijät. Tammikuu 2001. ISBN 951-42-5893-2.
32. Ikäheimonen J., Leiviskä K. & Ruuska J., Jatketiilen tukkeentumisen mallintaminen neuroverkoilla. Helmikuu 2001. ISBN 951-42-5906-8.
33. Ikäheimonen J., Leiviskä K. & Ruuska J., Sulkutangon asennon ja valunopeuden käyttö jatketiilen tukkeentumisen ennustamisessa. Maaliskuu 2001. ISBN 951-42-5946-7.
34. Ruuska J. & Leiviskä K., LD-KG-konvertterin lämpötilamalli. Toukokuu 2001. ISBN 951-42-6411-8.
35. Ainali I., Juuso E. & Sorsa A., Vesikemikaalien annostelutyökalun kehittäminen: Flotaation perusteet, koejaksot ja mallinnus. Marraskuu 2001. ISBN 951-42-6589-0
36. Näsi J. & Sorsa A., Jatkuvatoimisen liuospuhdistuksen pilot-prosessin mallinnus ja prosessikehitys. Helmikuu 2002. ISBN 951-42-6626-9.
37. Ikäheimonen J. & Leiviskä K. Syherödatan analysointi histogrammeja käyttäen. Maaliskuu 2002. ISBN 951-42-6678-1.
38. Ikäheimonen J. & Leiviskä K. Neuroverkot ja lingvistiset yhtälöt jatketiilen tukkeuman ennustuksessa. Huhtikuu 2002. ISBN 951-42-6700-1.

ISSN 1238-9404

Säätötekniikan laboratorio – Sarja B