

# **Kaukolämpöverkon dynamiikan mallintaminen neuraalilaskennalla**

Magnus Wistbacka & Kari Sipilä



ISBN 951-38-5323-3 (nid.)  
ISSN 1235-0605 (nid.)

ISBN 951-38-5324-1 (URL: <http://www.inf.vtt.fi/pdf/>)  
ISSN 1455-0865 (URL: <http://www.inf.vtt.fi/pdf/>)

Copyright © Valtion teknillinen tutkimuskeskus (VTT) 1998

#### JULKAISIJA – UTGIVARE – PUBLISHER

Valtion teknillinen tutkimuskeskus (VTT), Vuorimiehentie 5, PL 2000, 02044 VTT  
puh. vaihde (09) 4561, faksi (09) 456 4374

Statens tekniska forskningscentral (VTT), Bergsmansvägen 5, PB 2000, 02044 VTT  
tel. växel (09) 4561, fax (09) 456 4374

Technical Research Centre of Finland (VTT), Vuorimiehentie 5, P.O.Box 2000, FIN-02044 VTT, Finland  
phone internat. + 358 9 4561, fax + 358 9 456 4374

VTT Energia, Energiajärjestelmät, Tekniikantie 4 C, PL 1606, 02044 VTT  
puh. vaihde (09) 4561, faksi (09) 456 6538

VTT Energi, Energisystem, Teknikvägen 4 C, PB 1606, 02044 VTT  
tel. växel (09) 4561, fax (09) 456 6538

VTT Energy, Energy Systems, Tekniikantie 4 C, P.O.Box 1606, FIN-02044 VTT, Finland  
phone internat. + 358 9 4561, fax + 358 9 456 6538

Tekninen toimitus Leena Ukoski

LIBELLA PAINOPALVELU OY, ESPOO 1998

Wistbacka, Magnus & Sipilä, Kari. Kaukolämpöverkon dynamiikan mallintaminen neuraalilaskennalla [Estimating the state of district heating network by neural network method]. Espoo 1998, Valtion teknillinen tutkimuskeskus, VTT Tiedotteita – Meddelanden – Research Notes 1919. 36 s.

**Avainsanat** district heating, thermal networks, statistical models, neural nets, neural network models

## TIIVISTELMÄ

Tutkimuksessa käytettiin neuroverkkolaskentaa kaukolämpöverkon tilan estimoinnissa. Tilastopohjaisen mallin edut verrattuna kaukolämpöverkon fysikaaliseen malliin olisivat sen yksinkertaisempi ylläpito ja helpompi käyttö verkon ajotilanteiden estimoinnissa. Raportissa tutkittiin Vantaan Energia Oy:n kaukolämpöverkon tilan estimointia Helsinki-Vantaan lentokentällä, Länsimäessä ja Mesikukantiellä Tikkurilassa. Estimoitavia suureita em. paikoissa ovat meno-paluulämpötila, absoluuttinen paine, paine-ero ja virtaus. Mallit kehitettiin 10 minuutin ja tunnin keskiarvomittauksiin perustuen.

Lentokentän tapauksessa haettiin tarkkailupisteen selittäjille paras kombinaatio eri viiveillä. Meno- ja paluulämpötilan sekä virtauksen mallien viritys toimi hyvin. Paine-eron ennustaminen pelkästään verkossa esiintyvien tunnettujen paine-erojen avulla ei toiminut hyvin, vaan tarvittiin lisäselittäjiksi tunnettuja absoluuttisia painemittauksia. Lämpötilan ennustamisen viivetarkastelussa todettiin, että vakioviiveen käyttö on perusteltua. Lentokentän kaukolämmön paluulämpötilaa estimoitiin myös lineaarisella aikasarja-analyysillä samoilla selittäjillä kuin neuromallillakin. Neuromallin todettiin ennustavan paluulämpötilan paremmin kuin aikasarjamalli.

Länsimäessä paine-eron ennustamista tutkittiin käyttäen selittäjinä pumppuasemien paine- ja paine-eromittauksia sekä Länsimäen paine-eroa ja ulkolämpötilaa. Ennustemallina käytettiin tuntikeskiarvomallia. Neuromalli, jossa on kaikki 21 selittäjää mukana, antoi parhaan tuloksen. Jos selittäjien määrä rajoitetaan siten, että otetaan mukaan vain seitsemän merkittävintä selittäjää, niin keskihajonta kasvaa 20 %.

Kolmantena kohteena oli Mesikukantien paluulämpötilan ja paine-eron ennustaminen. Paluulämpötilan ennustaminen tehtiin periaatteessa samalla tavalla kuin lentokentän tapauksessa. Selittäjiksi otettiin lisäksi Koivukylän lämpökeskuksen kattiloiden menolämpötilat ja virtaukset. Paine-eron ennustamisessa käytettiin pumppuasemien ja Koivukylän lämpökeskuksen painetietoja sekä ulkolämpötilaa. Näin saatiin paras ennuste, jonka keskihajonnaksi saatiin 1,2 % maksimi- ja minimiarvojen keskiarvosta.

Neurolaskennalla saatiin hyvä tilastolliseen mittaustietoon perustuva kaukolämpöverkon tilan estimointimalli. Neuromallin, kuten kaikkien muidenkin tilastopohjaisten mallien, käytössä yksi suurimpia työvaiheita on datan kerääminen ja muokkaaminen tilastollisessa laskennassa tarvittavaan muotoon. Mallin muodostaminen, selittäjien hakeminen ja mallin opettaminen vaativat asiantuntemusta. Nämä tehtävät pitäisi pystyä automatisoimaan siten, että verkkomallin käyttäjän ei tarvitse opettaa neuromallia, vaan tietokone hoitaa ko. toiminnot automaattisesti. Mallin uudelleen opettamista ajatellen automaattinen datojen muodostaminen ei saa olla kuitenkaan liian rajoittava tekijä. Mallin rakenteen muuttaminen ja uudelleen opettaminen tulee olla riittävän yksinkertaista, jotta sitä tarvittaessa myös tehtäisiin.

Wistbacka, Magnus & Sipilä, Kari. Kaukolämpöverkon dynamiikan mallintaminen neuraalilaskennalla [Estimating the state of district heating network by neural network method]. Espoo 1998, Technical Research Centre of Finland, VTT Tiedotteita – Meddelanden – Research Notes 1919. 36 p.

**Keywords** district heating, thermal networks, statistical models, neural nets, neural network models

## ABSTRACT

Neural network method is used for estimation of the state of a district heating (DH) network. The advantages of a statistical model compared to a physical model are a more simplified updating and easier operation for the state estimation of the district heating network. In this report the estimation in the district heating network of Vantaa Energy Oy is studied at the Helsinki-Vantaa Airport, at Länsimäki and at Tikkurila. The estimated variables were outgoing and return DH-temperature, pressure, absolute pressure difference and DH-water flow. The models are based on 10 minute and one hour average measurements.

In the case of the airport application the best combination of the parameters were defined with different delays. The models for out and return temperatures as well as for water flow run well. The estimated pressure difference at the observation point did not run well based on other pressure difference alone but did run after including known pressure parameters. Fixed delay for estimated temperature interval run well and marginal advantage is utilised using dynamical delay and processing the delay parameter becomes complicated. The return temperature at the airport was estimated with a linear time-series analysing model using the same parameters as in the neural model. The results of the neural model were better than the results of the time series model.

The estimated pressure difference at Länsimäki was studied by using as parameters pressure and pressure difference measurements at booster pump stations, pressure difference at Länsimäki and outdoor temperature. The estimation model with average hourly values was used. The neural model with all 21 parameters gave the best result. If the amount of the most remarkable parameters were limited to 7, the standard deviation error was increased by 20 %.

The third object was the estimation of the DH-return temperature and pressure difference at Mesikukka road in Tikkurila. The return temperature was estimated in the same way as at the airport. The outgoing temperatures and water flows of two boilers at Koivukylä were used as extra parameters. The pressure difference was estimated using pressure measurements at booster pump stations and Koivukylä heat centre as well as outdoor temperature in Vantaa. The best estimation result with the standard deviation error of 1.2 % from the average of maximum and minimum value was obtained.

The acceptable neural network model of DH-network system was developed based on statistical measurements. One of the biggest tasks in developing neural models as well as other statistical models is data collection and reprocessing for the models. Thorough experiences is required for modelling, parameter definition and training the neural model. Those tasks should be automated into a computer in such a manner that the user only utilises the results of the computer model. Retraining the model and changing the structure of the model must be so easy for the user that those steps will also be done when needed.

## ALKUSANAT

Tämä tutkimus on jatkoa vuonna 1996 tehdyllä tutkimuksella ”Tilastollisten mallien soveltaminen kaukolämpöjärjestelmän dynamiikan kuvaamiseen”. Tutkimus liittyi TEKESin rahoittamaan ja Suomen kaukolämpö ry:n koordinoimaan kaukolämpötekniikan TERMO-tutkimusohjelmaan.

Edellisessä tutkimuksessa etsittiin tilastollisia menetelmiä kaukolämpöverkon toimintatilan määrittämiseksi. Neurolaskenta todettiin käyttökelpoiseksi menetelmäksi kuvata kaukolämpöverkon tilaa tekemättä verkosta fysikaalista laskentamallia, kuten perinteisissä verkon tilaa simuloivissa ja suunniteluun käytetyissä malleissa tehdään.

Tässä tutkimuksessa jatkettiin em. neurolaskentamenetelmän soveltamisen kehitystä kaukolämpöverkon toimintatilan ennustamiseksi verkosta mitatun informaation perusteella.

Hanketta ovat rahoittaneet TEKES ja VTT Energia. Tutkimusta varten perustettiin johtoryhmä, johon kuuluivat Heikki Kotila (TEKES), Pertti Sahti (Vantaan Energia Oy), Jorma Laukkanen (Komartek Oy) ja Tero Mäkelä (Suomen kaukolämpö ry).

Tekijät esittävät parhaimmat kiitokset rahoittajille ja johtoryhmälle saamastaan tuesta ja hyvästä yhteistyöstä.

Espoossa kesäkuussa 1998

# SISÄLLYSLUETTELO

TIIVISTELMÄ	3
ABSTRACT	4
ALKUSANAT	5
SISÄLLYSLUETTELO	6
1. JOHDANTO	7
1.1 Tausta	7
1.2 Tavoite	7
1.3 Vantaan kaukolämpöjärjestelmä	8
2. NEUROMALLINTAMINEN YLEENSÄ JA TYÖSSÄ KÄYTETYT PIIRTEET	9
3. LENTOKENTÄN PALUU- JA MENOLÄMPÖTILA SEKÄ VIRTAUS JA PAIN-ERO	12
3.1 10 minuutin keskiarvot	12
3.2 Tuntikeskiarvot	15
3.2.1 Vakioviiveen riittävyyden tarkastelu	20
3.2.2 Aikasarjamalli tuntikeskiarvoilla	21
3.3 Tuntikeskiarvomalli sovellettuna 10 min:n arvoille	22
3.4 Tuntikeskiarvomallin uudelleenopettaminen 10 min:n aikasarjoille	23
3.5 Taulukkomuotoinen esitys lentokentän malleista	23
4. LÄNSIMÄEN VIRTAUKSEN SELITTÄMINEN PAIN-EROILLA JA ULKOLÄMPÖTILALLA	25
4.1 Taulukkomuotoinen esitys Länsimäen virtausmalleista	27
5. MESIKUKANTIEN PALUULÄMPÖTILA JA PAIN-ERO	28
5.1 Paluulämpötila	28
5.2 Taulukkomuotoinen esitys Mesikukantien paluulämpötilamallista	30
5.3 Paine-ero	30
5.4 Taulukkomuotoinen esitys Mesikukantien paine-eromalleista	31
6. JOHTOPÄÄTÖKSIÄ JA JATKOTOIMENPITEITÄ	33
VIITTEET	36

# 1. JOHDANTO

## 1.1 Tausta

Tutkimus on jatkoa Kari Sipilän vuonna 1996 tekemään ”Tilastollisten mallien soveltaminen kaukolämpöjärjestelmän dynamiikan kuvaamiseen” [1]. Tämä työ noudattaa samaa peruslähtökohtaa, eli kaukolämpöverkon tilamallien pohjana ovat tilastolliset analyysit eivätkä verkon fysiikkaa simuloivat tarkastelut. Mittauspohja on laajennettu ja malleissa on otettu mukaan enemmän selittäjiä sekä selitetty pitempiä ajanjaksoja, joissa selittäjien ja selitettävien vaihtelut ovat suurempia.

Tilastopohjaisen mallin edut verrattuna fysikaaliseen malliin ovat sen yksinkertaisempi ylläpito ja helpompi käyttö. Mallien käyttöalueet ovat muun muassa ohjaus, optimointi ja verkon kunnon tarkkailu. Fysikaaliseen malliin verrattuna tilastopohjainen malli ei pysty yhtä hyvin selittämään harvoin esiintyviä poikkeustilanteita, jotka eivät ole edustettuina tilastollisessa analyysissä. Myös ekstrapolointia on syytä välttää; mallin tilastollisessa pohjassa tulisi olla mukana riittävän laajat vaihtelut ääritilanteineen, jotta mallin käyttö onnistuisi.

Luvussa 2 on yksinkertainen esitys neurolaskennan piirteistä.

## 1.2 Tavoite

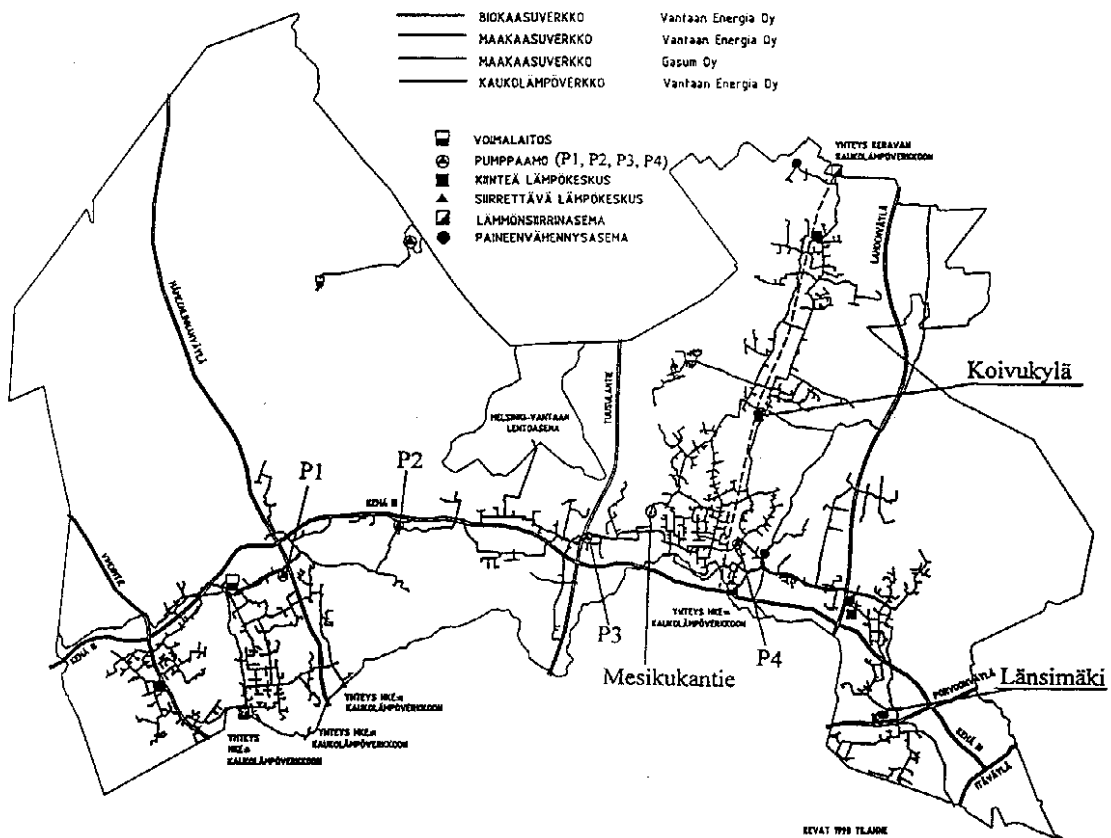
Tutkimuksessa kehitettiin kaukolämpöverkon reaaliaikaiseen ohjaukseen soveltuvia tilastopohjaisia menetelmiä. Kaukolämpöverkon mittauksiin perustuen eri parametrien väliset kuvaukset tehtiin neuraalilaskentamenetelmällä. Aiemman tutkimuksen perusteella malliin lisättiin ulkolämpötilasta riippuva parametri. Tilastolliseen kaukolämpöverkoston aineistoon perustuva käsittely edellyttää riittävän laajaa mittausaineistoa, jolloin voidaan tutkia neuromallin kyky selittää verkossa tapahtuvat ilmiöt. Tarkkailupisteen selittäjät valittiin selitettävyyden mukaan eikä fysikaalisiin perusteisiin, jotta mallin luonti olisi perusteiltaan mahdollisimman yleispätevää myöhempää kokonaismallin kehitystyötä ajatellen. Tarkoituksena on selvittää, voidaanko neuraalilaskennalla luoda riittävän hyvä tilastolliseen käsittelyyn pohjautuva kaukolämpöverkon malli ilman, että kehitetään kaukolämpöverkoston fysikaalisiin yhtälöihin perustuva malli. Selittäjien vaikutusta tarkkailupisteen suureiden kuvaukseen voidaan toki rajata niiden fysikaalisen kytkennän perusteella, mutta se ei ole tavoitteena vielä tässä vaiheessa. Tilastolliseen menetelmään perustuvan mallin tavoitteena on kuvata kaukolämpöverkon toimintaa, kuten dynaamisia fysikaalisiin perusteisiin pohjautuvia kaukolämpöverkon simulointimalleja, tarvitsematta kuitenkaan luoda kaukolämpöverkon fysikaalista verkkomallia.

### 1.3 Vantaan kaukolämpöjärjestelmä

Vuonna 1997 Vantaan Energian kaukolämpöjärjestelmässä oli kaukolämpöjohtoja yhteensä 349 km. Lämmitysvoimalaitosten sähköteho oli 203 MW ja kaukolämpöteho 330 MW. Kiinteistä lämpökeskuksista saatiin 278 MW:n teho. Polttoaineiden yhteensä 2 890 GWh:n käytöstä 45 % oli hiiltä, 53 % maakaasua ja loput 2 % öljyä. Yhteistuotantolaitokset, josta kaksi on höyryvoimalaitoksia ja yksi kombilaitos, sijaitsivat Martinlaaksossa.

Sähkön 1 761 GWh:n kokonaishankinnasta 963 GWh oli peräisin omasta voimalaitostuotannosta ja 1 101 GWh toimitettiin Vantaalle. Lämmön vastaavasta 1 546 GWh:n kokonaishankinnasta 1 471 GWh oli omaa voimalaitostuotantoa ja 1 440 GWh toimitettiin Vantaalle. Vantaan kaukolämpöverkko on yhteydessä sekä Helsingin että Keravan verkkoihin. Sähkö- ja kaukolämpösopimusten lisäksi Vantaan Energia toimittaa myös maakaasua.

Kuvassa 1 esitetään Vantaan kaukolämpöverkko tuotantolaitoksineen ja pumppu-  
asemineen.



Kuva 1. Vantaan kaukolämpöverkko.



## 2. NEUROMALLINTAMINEN YLEENSÄ JA TYÖSSÄ KÄYTETYT PIIRTEET

Neurolaskennassa laskenta tapahtuu toisiinsa kytketyillä laskentaelementeillä eli neuroneilla (Matlab-manuaali Neural Network Toolbox) [2]. Jokaisella neuronilla on painokerroin, joka määrää kahden elementin välisen kytkennän. Yhdistämällä kaikkien neuronien tulokset saadaan neuronikerroksen tulos. Kerroksia voi olla useampia; yhden kerroksen tulos voi olla syöte seuraavalle kerrokselle tai lopputuloksen tuottava viimeinen kerros.

Jokainen kerros sisältää painokerroinmatriisin ja biasvektorin sekä suodattimen, jolla matriisin ja biasvektorin tuottama tulos muokataan. Erilaisista suodattimista mainittakoon tangentiaalinen (tansig), logaritminen (logsig) ja lineaarinen (purelin) suodatin. Kaksikerroksisessa neuromallissa ensimmäinen kerros laskee syötteestä uudet arvot, jotka puolestaan muodostavat jälkimmäisen kerroksen syöttöarvot. Jälkimmäinen kerros tuottaa siten tulosteen.

Ensimmäisen neurokerroksen kerroinmatriisin toinen dimensio riippuu syötteestä eli selittäjien lukumäärästä ( $R$  kuvassa 2), toinen dimensio ( $S1$  kuvassa 2) on mallintajan valittavissa. Kun vielä mallin selitettävien lukumäärä ( $S2$  kuvassa 2) on määritetty, kaikkien neurokerroinmatriisien ja biasvektoreiden dimensiot on lyöty kiinni.

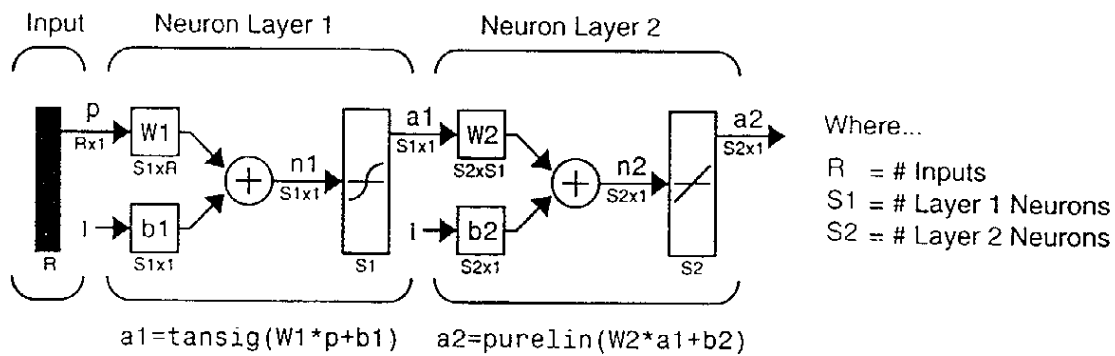
Mallin kokonaistuloksena voi yhdestä syötteestä syntyä joko yksi ( $S2=1$  kuvassa 2) tai useampi ( $S2>1$  kuvassa 2) arvo riippuen mallin rakenteesta. Verrattuna toisenlaisiin ennustemalleihin, esimerkiksi aikasarjamalleihin, neuromalli sisältää huomattavasti enemmän parametrejä, yhteensä  $S1 \times (R+1) + S2 \times (S1+1)$ . Aikasarjamalli sisältää yleensä korkeintaan pari parametriä selittäjää kohti sekä muutaman selitettävään liittyvän parametrin.

Parametrien arvot saadaan mallin opetusvaiheessa, jossa opetusalgoritmi iteroi kertoimet, jotka minimoivat havaintoaineiston ja mallin tuottamien arvojen varianssin.

Tässä käytetyissä neuromalleissa kerroksia on ollut kaksi, joista ensimmäisen suodatusfunktio on epälineaarinen "tansig" ja jälkimmäisen puhtaasti lineaarinen "purelin". Ensimmäisen kerroksen valittava dimensio ( $S1$  kuvassa 2) on yleensä ollut viisi, mikä on monessa tapauksessa ollut opetusvaiheessa suurin mahdollinen määrä muistirajoitusten takia, varsinkin jos selittäjiä on paljon tai mallinnettava aikasarja pitkä.

Mainitun kaltaisilla suodattimilla kaksikerroksinen neuroverkko voi approksimoida mitä tahansa funktiota, jolla on äärellinen määrä epäjatkovuuksia, kunhan neuronien lukumäärä on riittävä (Matlabin neuroverkkomanuaali, sivu 5-5).

Kuvassa 2 esitetään mallintamisessa käytetty neuromalli.



Kuva 2. Mallintamisessa käytetty neuroverkkorakenne. Selittäjävektori  $p$  (selittäjiä  $R$  kappaletta) ja matriisi  $W1$  (dimensio  $S1 \times R$ , jossa  $S1$  on mallintajan valittavissa) kerrotaan ja tulokseen lisätään biasvektori  $b1$ . Tulosvektoria  $n1$  (dimensio  $S1 \times 1$ ) käsitellään tansig-suodattimella, joka kuvaa välin  $(-\infty, +\infty)$  väliin  $(-1, +1)$ . Tulos  $a1 = \text{tansig}(W1 \cdot p + b1)$  siirtyy seuraavaan neurokerrokseen, jossa kertolasku tehdään matriisin  $W2$  (dimensio  $S2 \times S1$ , jossa  $S2$  on selitettävien lukumäärä eli tässä tapauksessa 1) kanssa ja biasvektori  $b2$  lisätään. Lopputulos on siten  $a2 = \text{purelin}(W2 \cdot a1 + b2)$ . Opetusvaiheessa  $W1$ ,  $W2$ ,  $b1$  ja  $b2$  saavat arvoja, jotka minimoivat laskentatulosten ja todellisten arvojen erotuksista riippuvaa kriteeriä. Opetuksessa esiintyy siten useampi selittäjävektori  $p$  ja selitettävä arvo  $a2$  (eriaikaisia havaintoja), joille lasketaan parhaat mahdolliset  $W1$ ,  $W2$ ,  $b1$  ja  $b2$ . (lähde: Matlab manuaali)

Mallintamisessa on mallinnettu ainoastaan yhtä selitettävää kerralla ( $S2=1$  kuvassa 2). Monien selittäjien mallintaminen olisi opetusvaiheessa useimmiten ylivoimainen tehtävä. Lisäksi eri selitettävät riippuvat eri selittäjistä ja mahdollisesti eri viiveillä, joten selittäjien joukossa olisi siten joillekin selitettäville ylimääräisiä selittäjiä.

Opetusvaiheen iteroinnin alkuvaiheessa neuroverkkoparametrien alkuarvot voivat vaikuttaa ratkaisevasti iteroinnin etenemiseen. Huonot alkuarvot voivat jopa katkaista iteroinnin numeeris-matemaattisista syistä. Iteroinnin herkkyys alkuarvoille on selvästi pienempi, mikäli mallissa esiintyvät aikasarjat on ennen opetusta skaalattu kaikki suurin piirtein samaan vaihteluväliin. Siten kaikki aikasarjat on lineaarisella muunnoksella skaalattu väliin  $[0,1]$  tai mahdollisesti vähän tämän ulkopuolelle, mikäli havaintoaikasarja jossakin vaiheessa on laajennettu ja skaalausparametrit on säilytetty ennallaan. Ennusteissa saadaan ennustettavan oikea arvo käänteisellä muunnoksella.

Neuromalli sopii suhteellisen huonosti itse mallintamiseen; mm. viiveiden ja merkittävien selittäjien löytyminen onnistuu usein helpommin vaikka aikasarja-analyysin avulla, jossa nämä ominaisuudet ovat osa mallintamistyökalustoa. Aikasarja-analyysissä viiveet muodostavat luontevan osan mallin rakennetta, joten niiden määrittäminen onnistuu helposti. Mallintamisen tuloksena saadaan myös tunnuslukuja, joista voi päätellä, mitkä selittäjät ja viiveet kannattaa merkityksettöminä poistaa mallista.

Neurolaskennassa viiveiden määrittäminen opetusmateriaaliin vaatii kömpelölköä käsityötä. Selittäjien korrelaatiot selitettävän kanssa saadaan suhteellisen hyvin esille, mutta selittäjien väliset ristikorrelaatiot hankaloittavat parhaan mahdollisen mallin löytämistä. Täten mallista on vaikea poistaa turhat selittäjät.

Aikasarja-analyysiin verrattuna neuromallista puuttuvat eräät merkittävät ominaisuudet: autoregressiivisyys ja liukuvan keskiarvon korjausvaikutus. Näiden hyöty ennustetarkoituksessa ei kuitenkaan ole täysin selvä. Autoregressiivisyydellä saadaan ennustettavalle oikea lähtötaso ennusteen alkuun, ja liukuva keskiarvo suorittaa korjauksia, kun oikea arvo poikkeaa mallin mukaisesta arvosta. Näiden vaikutus kuitenkin katoaa, kun ennustejakso on edennyt muutaman askeleen verran viimeisestä oikeasta arvosta. Ennustetarkoituksessa hyödyllisempi ominaisuus aikasarja-analyysissä lienee vuorokausi- tai viikkoviiveen tuoma hyöty. Vuorokausiviiveen ennustetta parantava vaikutus säilyy vuorokauden, mikä on yleensä riittävän pitkä aika ennustelle.

Neuromallissa voidaan karkeasti mallintaa mainittuja piirteitä ottamalla sopivilla viiveillä selitettävä itse selittäjänä mukaan malliin. Täysin tämä ei vastaa aikasarja-analyysiä, sillä ainoastaan autoregressiivisyys on mallinnettu eikä liukuvaa keskiarvoa saada yksinkertaisin keinoin määritettyä.

Viiveitä on käsitelty vakioviiveinä, eli läpi koko ajanjakson kunkin selittäjän viive pysyy muuttumattomana. Todellisuudessa kaukolämpöverkossa ainakin menolämpötila vaikuttaa viiveellä, joka pienenee virtauksen kasvaessa. Muuttuvien viiveiden käyttö on kuitenkin hankalaa, eikä neurolaskenta oikein tarjoa yksinkertaista keinoa saada edes vakioviiveitäkään selville. On kuitenkin syytä pohtia vakioviiveiden riittävyyttä ennustemalleissa. Mikäli vakioviiveen riittämättömyyttä ei voida osoittaa, ei liene syytä kehittää monimutkaista muuttuvan viiveen menetelmää.

Tilanteissa, jossa mallin koko yhdessä sen vaatimien aikasarjojen kanssa muodostuu liian suureksi, on aikasarjat päätetty niin, että opetukseen mukaan otetut ajanhetket edustavat mahdollisimman hyvin koko ajanjaksoa. Eräs tapa on poimia tasavälein arvoja alkuperäisestä aikasarjasta, ja kun tuntikeskiarvoista poimitaan esimerkiksi joka viides arvo, saadaan myös kaikki kellonajat mukaan, koska 24 ei ole jaollinen viidellä.

Mikäli enemmän kuin viidesosa mahtuu ongelmitta mallin opetusvaiheeseen, voidaan opetuspohja laajentaa. Otetaan joka viides arvo mukaan alkaen sekä ensimmäisestä että kolmannelta aika-askeleesta. Näin opetusmateriaali on kavennettu vain 2/5:aan, mikä on parempi kuin esimerkiksi joka toinen tai kolmas arvo näiden vuorokausijaollisuuden takia.

Kavennuksessa on tietenkin sijoitettava viiveelliset suureet alkuperäisessä aikasarjassa oikeisiin paikkoihin, ennen kuin aikasarjasta poimitaan kavennuksen mukaiset kohdat.

### 3. LENTOKENTÄN PALUU- JA MENOLÄMPÖTILA SEKÄ VIRTAUS JA PAINE-ERO

Mitattuja havaintoarvoja on käytetty selittämään Helsinki-Vantaan lentokentän suureita käyttäen ulkolämpötilaa sekä ennen lentokenttää sijaitsevan pumppuaseman P1:n ja lentokentän jälkeen sijaitsevan pumppuaseman P3:n arvoja seuraavasti:

Selittävät lentokentällä:

paluulämpötila (PALA45)  
menolämpötila (MELA45)  
virtaus (VIRT45)  
paine-ero (PAIE45)

Selittäjät:

ulkolämpötila (ULKOLT)  
P1:n menolämpötila (MELAM4)  
P1:n virtaus (KLVES4)  
P3:n virtaus (KLVES6)

Jokaiselle selitettävälle on muodostettu oma selittäjäkokoontapano erilaisine viiveineen.

#### 3.1 10 minuutin keskiarvot

Kymmenen minuutin keskiarvoja on käytettävissä talvelta ja keväältä seuraavasti:

talvi	07.02.96 - 16.02.96	(noin 1 350 havaintoa, 225 h)
kevät	17.03.96 - 13.04.96	(noin 3 900 havaintoa, 650 h)

Mallissa on käytetty useita lyhytaikaisia, myös alle tunnin mittaisia, vakioviiveitä mutta ei vuorokausi- tai viikkoviivettä. Selittäjät viiveineen on valittu yksinkertaisella korrelaatiotarkastelulla, eikä fysikaalista järkevyyttä ole pohdittu. Aikaansaadut selittäjäkokoontapanot ovat seuraavat:

PALA45	selittäjä	viive (min)
		ULKOLT 0, 10, 40, 50
		KLVES4 0, 10
		MELAM4 0, 10, 110, 120
		KLVES6 0, 10
MELA45	selittäjä	viive (min)
		ULKOLT 0, 10
		MELAM4 0, 10, 80, 90
VIRT45	selittäjä	viive (min)
		ULKOLT 0, 10

KLVES4	0, 10
MELAM4	0, 10, 70, 80
KLVES6	0, 10

PAIE45	selittäjä	viive (min)
KLVES4		0, 10
KLVES4 <sup>2</sup>		0, 10
KLVES6		0, 10
KLVES6 <sup>2</sup>		0, 10
ULKOLT		30, 40
MELAM4		30, 40, 90, 100


Tuloksia:

Neuromallin opetuksessa on oltava edustettuina ennusteessa esiintyvät tilanteet, toisin sanoen talvikauteen opetettu malli ei ennusta kevättä yhtä hyvin eikä päinvastoin.

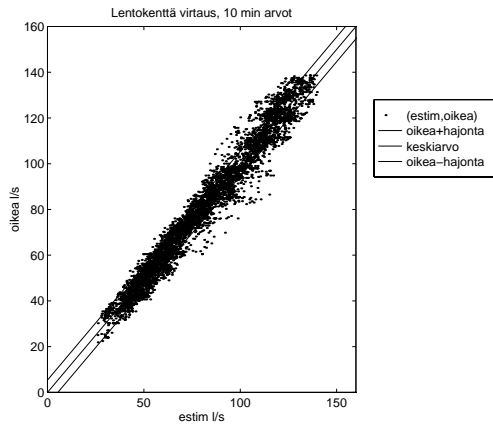
Paine-ero on huonosti selitettävissä mainituilla selittäjillä. Riippuvuus verkon muualla esiintyvistä paineista on ratkaiseva.

Kohdassa 3.5 on taulukkomuotoinen yhteenveto lentokentän kaikista malleista.


Kuvissa 3, 4, 5 ja 6 esitetään ennusteet ja oikeat arvot lukuparimuodossa (ennuste,oikea).



Kuva 3. Paluulämpötilan 10 min ennuste. Kuva 4. Menolämpötilan 10 min ennuste.




Kuva 5. Virtauksen 10 min ennuste.




Kuva 6. Paine-eron 10 min ennuste.

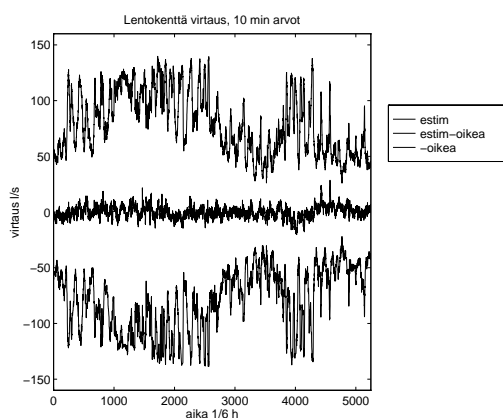
Kuvissa 7, 8, 9 ja 10 esitetään 10 min:n ennusteet, oikeat arvot ja näiden erotus aikasarjamuodossa.




Kuva 7. Paluulämpötilan 10 min ennuste.



Kuva 8. Menolämpötilan 10 min ennuste.

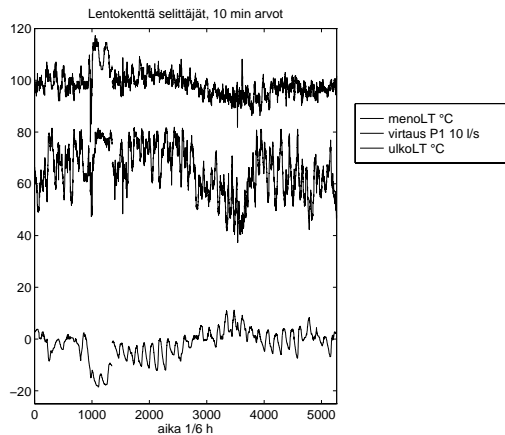


Kuva 9. Virtauksen 10 min ennuste.



Kuva 10. Paine-eron 10 min ennuste.

Kuvassa 11 esitetään 10 min:n tapauksessa käytetyt selittäjät.



Kuva 11. 10 min:n ennusteissa käytetyt selittäjät.

### 3.2 Tuntikeskiarvot

Tuntikeskiarvoja on saatavissa huomattavasti pidemmältä ajalta kuin 10 min keskiarvot:

talvi + kevät	01.11.96 - 02.05.97	(noin 4 370 havaintoa)
kesä + syksy	12.05.97 - 01.11.97	(noin 4 150 havaintoa)
poistettu kesästä	11.06.97 - 01.09.97	(noin 1 970 havaintoa)

Kesäjaksosta on jouduttu poistamaan arvoja, koska lentokentän selitettävien suureiden kohdalla esiintyy puuttuvia tai ilmeisesti vääränlaisia (negatiivisia) arvoja mainittuna aikana liikaa.

Tuntikeskiarvoille ei voi määrittää alle tunnin mittaisia viiveitä, joten lyhyiden viiveiden määrä on olennaisesti pienempi kuin 10 min:n keskiarvotapauksessa. Toisin kuin 10 min:n tapauksessa, vuorokausiviiveitä on käytetty, kun siihen on ollut syytä. Tuntikeskiarvoissa näkyy korrelaatiossa selvä äärikohta 24 h:n viiveellä, kun taas 10 min:n arvoilla äärikohta ei erotu yhtä tarkasti. Selitettävä itse 24 h:n viiveellä antaa usein huomattavan lisäyksen mallin selitettävyyteen.

Viiveiden määrittelyssä on osittain käytetty aikasarja-analyysiä, kuten luvussa 2 on selitetty.

Tuntikeskiarvoilla on mallinnettu samat selitettävät kuin 10 min:n keskiarvoilla eli lentokentän meno- ja paluulämpötilat, virtaus ja paine-ero käyttäen samoja selittäjiä eli ulkolämpötilaa, P1:n menolämpötilaa ja virtausta sekä P3:n virtausta. Näin voidaan selvittää 10 min:n ja tuntikeskiarvojen aiheuttamat erot mallin ennustekyvyyssä.

Tuntikeskiarvomalleja on myös sovellettu 10 min:n havaintoarvoihin sekä jättämällä malliparametrit ennalleen että opettamalla malliparametreille uusia 10 min:n havaintoihin sopivampia arvoja. Näin saadaan jonkinlainen kuva siitä, kuinka olennaisia mallin rakenne ja siinä esiintyvät parametriarvot ovat.

Kaikissa tuntirakenteisissa malleissa (mallin rakenne alun perin kehitetty tuntiarvoja varten) on käytetty seuraavat selittäjät ja viiveet:

PALA45	selittäjä	viive (h)	
		ULKOLT	0, 1, 24
		KLVES4	0
		KLVES6	0
		MELAM4	2
PALA45	24		
MELA45	selittäjä	viive (h)	
		ULKOLT	3
		MELAM4	2
		MELA45	24
VIRT45	selittäjä	viive (h)	
		ULKOLT	0
		KLVES4	0
		KLVES6	0
		VIRT45	24
MELAM4	2		
PAIE45	selittäjä	viive (h)	
		ULKOLT	0
		KLVES4	0
		KLVES6	0
		KLVES4 <sup>2</sup>	0
		KLVES6 <sup>2</sup>	0

Tuloksia:

Tuntikeskiarvojen ennustevirheiden hajonta on suurin piirtein sama kuin 10 min:n mallin ennusteissa, vaikka mallien rakenteet poikkeavat aika lailla toisistaan. Yllättäen mallien välinen ero on pieni myös lentokentän menolämpötilalle, jossa nimenomaan syötetyn menolämpötilan tarkempien viiveiden tulisi parantaa mallin tarkkuutta 10 min:n tapauksessa.

Tuntikeskiarvoissa terävimmät ääriarvot ja tunnin sisällä tapahtuneet muutokset ovat kadonneet verrattuna 10 min:n arvoihin, joten tässä suhteessa tuntiarvoja on helpompi mallintaa.

Vertailussa tulee myös muistaa, että 10 min:n mallin opetuksessa ei ollut käytettävissä yhtä kattavaa aikasarjaa. Tuntiaikasarja sisältää sekä kireämpiä pakkasia että lämpimämpiä jaksoja kuin 10 min:n aikasarja. Tässä suhteessa siis 10 min:n mallien tulisi olla helpompia mallintaa.



Malleissa esiintyvät mahdolliset puutteet on yritetty löytää tutkimalla ennustevirheen riippuvuutta selittäjistä. Mitään systemaattista virheriippuvuutta ei löydetty. Toisaalta on helppo todeta, että varsinkin ääritilanteissa esiintyy usein suurempia virheitä, mutta lähes ainoastaan suurempana hajontana eikä systemaattisena virheenä. Yksinkertaisella tavalla näitä virheitä on vaikea korjata.



Kohdassa 3.5 on taulukkomuotoinen yhteenveto lentokentän kaikista malleista.

Kuvissa 12, 13, 14 ja 15 esitetään tuntiennusteet ja oikeat arvot lukuparimuodossa (ennuste, oikea).


Kuvissa 16, 17, 18 ja 19 esitetään tuntiennusteet, oikeat arvot ja näiden erotus aikasarjamuodossa.

Kuvassa 20 esitetään tuntitapauksessa käytetyt selittäjät.

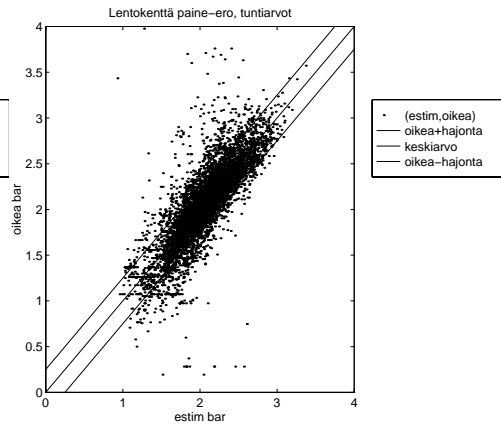
Kuvissa 21, 22, 23 ja 24 esitetään tuntiennustevirheiden riippuvuus ulkolämpötilasta.




*Kuva 12. Paluulämpötilan tuntiennuste. Kuva 13. Menolämpötilan tuntiennuste.*




Kuva 14. Virtauksen tuntiennuste.




Kuva 15. Paine-eron tuntiennuste.



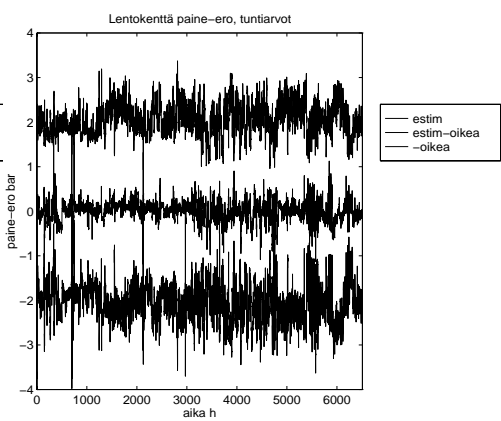
Kuva 16. Paluulämpötilan tuntiennuste.



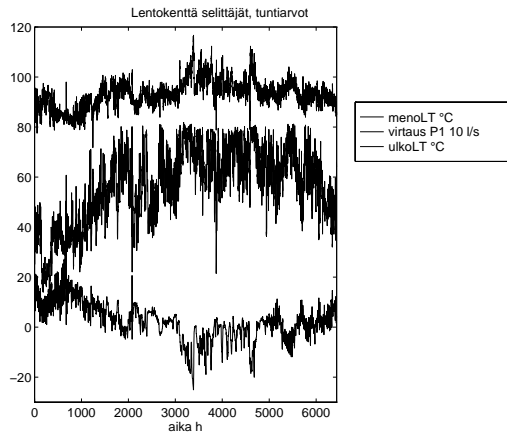
Kuva 17. Menolämpötilan tuntiennuste.



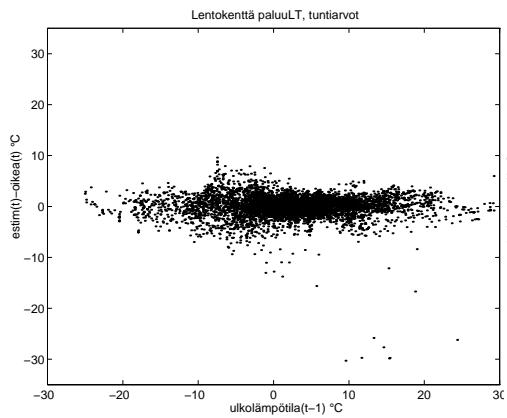
Kuva 18. Virtauksen tuntiennuste.




Kuva 19. Paine-eron tuntiennuste.




Kuva 20. Tuntiennusteissa käytetyt selittäjät.




Kuva 21. Ulkolämpötila ja paluulämpötilavirhe.



Kuva 22. Ulkolämpötila ja paluulämpötilavirhe.



Kuva 23. Ulkolämpötila ja virtausvirhe.




Kuva 24. Ulkolämpötila ja paine-erovirhe.

### 3.2.1 Vakioviiveen riittävyyden tarkastelu

Vakioviiveen riittävyyttä selvitetiin tutkimalla lentokentän menolämpötilan ennustevirheen riippuvuutta pumppuaseman P1 ja lentokentän virtauksista. Lentokentän menolämpötilan ylivoimaisesti tärkein selittäjä on ennen lentokenttää pumppuasemalla mitattu menolämpötila.

Mikäli virtauksen aiheuttama muutos viiveessä olisi ratkaiseva mallin selitettävyyden kannalta, ennustevirheen tulisi jossakin muodossa seurata virtauksen suuruutta ja siinä esiintyviä muutoksia. Näin jossakin määrin tapahtuukin. Suurilla ja etenkin pienillä virtauksilla ennustevirhe on selvästi suurempi kuin virtauksen keskiarvoalueella. Syy tähän voi kuitenkin olla itse virtaus tai tilanteet, joissa virtaus esiintyy äärialueilla, eikä virtauksen aiheuttaman viiveen muutos. Kuvassa 25 esitetään virtauksen vaikutus menolämpötilan ennustevirheeseen.



*Kuva 25. Virtauksen vaikutus virheeseen. Kuva 26. Virtausmuutoksen vaikutus virheeseen.*

Kun verrataan virtauksen muutoksen vaikutusta ennustevirheeseen, ei saada esille virtauksesta johtuvaa riippuvuutta. Toisin sanoen, kun tunnin aikana virtauksen muutos on ollut suurimmillaan suuntaan tai toiseen, ennustevirhe näyttää jopa pysyvän pienempänä kuin tilanteissa, joissa virtaus on pysynyt suhteellisen vakiona. Toisaalta tilanteita, joissa virtaus muuttuu hitaasti, on suhteellisesti enemmän kuin nopeasti muuttuvia tilanteita, joten on odotettavaa, että silloin esiintyy enemmän suuria virheitä. Kuvassa 26 on esitetty virtauksen muutoksen vaikutus menolämpötilan ennustevirheeseen.

Näiden havaintojen mukaan ei ole syytä tässä vaiheessa kehittää monimutkaista muuttuvan viiveen mallia.

### 3.2.2 Aikasarjamalli tuntikeskiarvoilla

Vertailun vuoksi on lentokentän paluulämpötila (PALA45) mallinnettu aikasarja-analyysillä. Tässä on käytetty hyväksi sen tarjoamat keinot löytää tärkeimmät selittäjät oikeilla viiveillä. Fysikaalista järkevyyttä ei ole pohdittu.

Alkuperäiseen aikasarjaan on sovellettu vuorokausidifferenssointia, mikä tarkoittaa suurin piirtein sitä, että selitettävän muutos omasta arvostaan 24 tuntia ajassa taaksepäin on selitetty selittäjien vastaavanlaisilla muutoksilla vuorokaudentakaisista arvoista. Differenssoinnin lisäksi selitettävälle on mallinnettu liukuvaa keskiarvoa sekä autoregressiivisuutta kuvaavia parametreja lyhyillä viiveillä.

PALA45	selittäjä	viive (h)
	ULKOLT	0, 1, 3
	KLVES4	0, 1
	KLVES6	0, 1
	MELAM4	0
	PALA45	1, 2, 3, 24 (autoregressiivisuus ja liukuva keskiarvo)

Aikasarjamallissa esiintyvät selitettävän autoregressiiviset ja liukuvan keskiarvon ominaisuudet aiheuttavat näennäistä parannusta mallin selityskykyyn. Koska mallissa selitettävän arvo jokaisella hetkellä riippuu omista edellisistä arvoista tietyn korjauksin, mallin ennustuskyky ei vastaa selityskykyä, koska ennustettaessa nämä todelliset arvot ovat saatavissa ainoastaan ennustejakson välittömässä alussa. Ennustejakson edetessä pohjana olevat selitettävän edelliset arvot ovat jo itse ennusteita. Jotta vertailu neuromallin kanssa olisi mahdollista, pitää poistaa nämä piirteet.

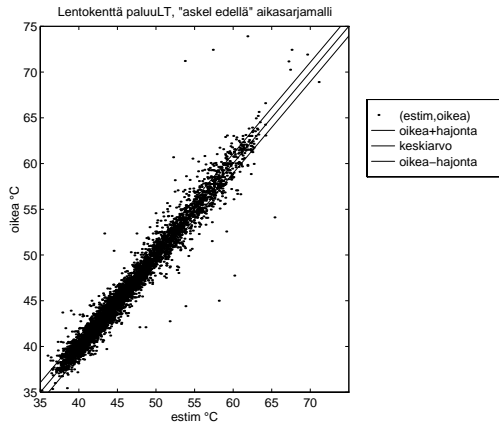
Helpoin tapa tehdä aikasarjamalli vertailukelpoiseksi neuromallin kanssa on yksinkertaisesti jättää pois selitettävän lyhyet viiveet. Tällöin mallissa esiintyvä vuorokausijakso on säilytetty niin, että vuorokauden takaisia todellisia arvoja on koko jakson aikana käytettävissä aivan kuten neuromalleissa tuntikeskiarvotapauksessa.

Tuloksia:


Aikasarjamallin paluulämpötilan ennustevirheen hajonta on 2,54 °C, kun vastaava hajonta neuromallin ennusteessa on 2,17 °C. Aikasarjamallin puhdas lineaarinen luonne sekä huomattavasti pienempi parametrimäärä näkyvät selvästi suurempana hajontana. Toisaalta aikasarjamalli, jossa selitettävän lyhyet viiveet ovat mukana saavuttaisi 1,06 °C:n hajonnan. Kuten mainittu, tämä malli ei ole vertailukelpoinen neuromallien kanssa, vaan kyseessä on eräänlainen ”askel edellä” -ennuste, jossa jokaiselle ennustehetkelle on olemassa tarkat arvot selitettävällekin edelliseltä aika-askeleelta.

”Askel edellä” -mallista voi kuitenkin päätellä, että selitettävän omat vaihtelut noudattavat tietyn tyyppistä säännönmukaisuutta. Ennustemielessä näistä ei välttämättä ole kovin suurta hyötyä. Neuromalli epälineaarilla suodattimella ja suurella neuronimäärällä on parempi verrattuna samantyyppiseen aikasarjamalliin.


Kuvissa 27 ja 28 esitetään ”askel edellä” -aikasarjamallin ennusteet ja oikeat arvot sekä lukuparimuodossa että aikasarjana ja kuvissa 29 ja 30 neuromalliin vertailukelpoisen vuorokausijaksomallin virheet samassa muodossa.



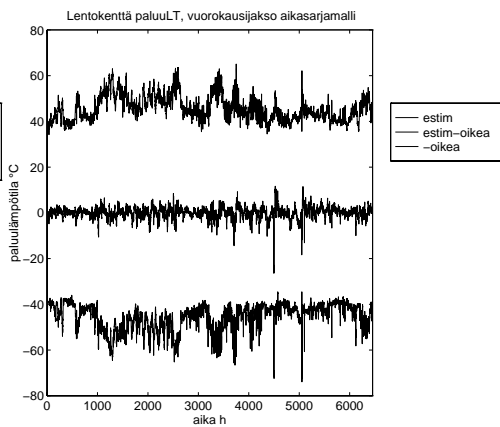
Kuva 27. ”Askel edellä” -ennuste lukupareina.



Kuva 28. ”Askel edellä” -ennuste aikasarjana.



Kuva 29. Vuorokausimalli lukupareina.



Kuva 30. Vuorokausimalli aikasarjana.

### 3.3 Tuntikeskiarvomalli sovellettuna 10 min:n arvoille

Kun muunnetaan 10 min:n aikasarjat siten, että tuntimallin viiveet on niissä määritetty, voidaan soveltaa tuntimalli 10 min:n arvoihin. Kuten on odotettavissa, ennusteen tarkkuus huononee verrattuna alkuperäiseen tuntikeskiarvomalliin. Virheen hajonta suurenee ja varsinkin virtauksen ennusteessa esiintyy systemaattinen virhe, eli virheen keskiarvo ei ole nolla. Tällainen osoittaa, että tuntimallin suora soveltaminen ennustamaan 10 min:n arvoja ei ole perusteltu.

Koska tuntiarvoissa esiintyy suurempia pitkäaikaisia vaihteluita kuin 10 min:n arvoissa eli tuntikeskiarvoissa on edustettuina sekä korkeimpia ulkolämpötiloja että varsinkin kireämpiä pakkasia kuin 10 min:n keskiarvoissa, tuntimallissa ovat edustettuina kaikki tilanteet, jotka esiintyvät 10 min:n aikasarjassa.

Kohdassa 3.5 on taulukkomuotoinen yhteenveto lentokentän kaikista malleista.

### **3.4 Tuntikeskiarvomallin uudelleenopettaminen 10 min:n aikasarjoille**

Kun tuntimalleissa esiintyvät parametrirakenteet säilytetään mutta parametrien arvoille opetetaan uudet arvot, saadaan ennusteet, jotka ovat jonkin verran huonompia kuin tuntiennusteet. Luultavasti tämä johtuu 10 min aikasarjoissa esiintyvistä terävimmistä ääriarvoista ja nopeimmista muutoksista, jotka osittain katoavat tuntikeskiarvoistamisen myötä. Erot eivät kuitenkaan ole kovin suuria.

Tuntirakenteiset mallit uudelleenopetettuina 10 min:n keskiarvoihin eivät aina yllä aivan alkuperäisten 10 min:n mallien tasolle. Ottaen huomioon tuntimallien yksinkertaisempi rakenne lyhyiden viiveiden lukumääriin sekä tarkkuuksiin tuntimallirakenne toimii yllättävän hyvin. On myös muistettava, että 10 min:n alkuperäisissä malleissa ei esiinny vuorokausiviiveitä.

Kohdassa 3.5 on taulukkomuotoinen yhteenveto lentokentän kaikista malleista taulukossa 1.

### **3.5 Taulukkomuotoinen esitys lentokentän malleista**

Taulukossa 1 esiintyvät selitettävien ja selittäjien nimet (PALA45, VIRT45 jne.) sekä muut tunnisteet (Paikkano, Idno ja suure) ovat Vantaan Energian käyttämiä. Selityssarakkeessa on sanallinen selitys.

Selitettävät-kohdassa rakenne tarkoittaa mallissa esiintyvää parametrisointia, viiveitä jne., parametrit kertovat, millaiseen havaintoaineistoon kyseessä oleva malli on opetettu, ja ennuste kertoo, millaiselle havaintoaineistolle ennuste on laadittu.

Sekä opetuksessa (parametrit) että ennusteessa on käytetty havaintoaineistot kokonaisuudessaan kuten kohdissa 3.1 ja 3.2 on selitetty.

Taulukko 1. Ennustemallien vertailu.

SELITETTÄVÄT							
Rakenne	10 min	tunti	tunti	tunti			
Parametrit	10 min	10 min	tunti	tunti			
Ennuste	10 min	10 min	10 min	tunti	Paikkano	Selitys	Idno
<b>PALA45</b>	°C	°C	°C	°C	18	Lentoasema kl-paluulämpötila	158
virheen keskiarvo	0,00	-0,19	-0,65	0,02			
virheen hajonta	2,17	2,28	2,58	2,17			
MAX(mitattu)	67,5			73,9			
MIN(mitattu)	38,4			34,5			
MAX-MIN	29,1			39,4			
<b>VIRT45</b>	l/s	l/s	l/s	l/s	18	Lentoasema kl-virtaus	204
virheen keskiarvo	-0,05	0,01	-2,03	0,02			
virheen hajonta	5,39	5,35	7,07	5,25			
MAX(mitattu)	138,6			180,7			
MIN(mitattu)	21,9			18,8			
MAX-MIN	116,7			161,9			
<b>MELA45</b>	°C	°C	°C	°C	18	Lentoasema kl-menolämpötila	103
virheen keskiarvo	0,03	-0,01	-0,06	-0,04			
virheen hajonta	1,24	1,47	1,53	1,29			
MAX(mitattu)	112,4			115,8			
MIN(mitattu)	74,3			72,2			
MAX-MIN	38,1			43,7			
<b>PAIE45</b>	bar	bar	bar	bar	18	Lentoasema paine-ero	138
virheen keskiarvo	0,01	0,00	-0,05	0,00			
virheen hajonta	0,25	0,28	0,33	0,25			
MAX(mitattu)	3,8			4,0			
MIN(mitattu)	0,6			0,2			
MAX-MIN	3,3			3,8			
virhe(i)=ennuste(i)-oikea(i)							
virheen keskiarvo=(1/N)*SUM(virhe(i))							
virheen hajonta=SQRT(1/(N-1)*SUM((virhe(i)-keskiarvo)^2))							
SELITTÄJÄT							
	10 min			tunti	Paikkano	Selitys	Idno
<b>ULKOLT</b>	°C			°C		Uikolämpötila Vantaalla	199
MAX(mitattu)	11,2			29,2			
MIN(mitattu)	-18,5			-25,1			
MAX-MIN	29,7			54,3			
<b>KLVES4</b>	l/s			l/s	33	P1 kl-virtaus	61
MAX(mitattu)	819,0			818,4			
MIN(mitattu)	373,0			111,5			
MAX-MIN	446,0			706,9			
<b>MELAM4</b>	°C			°C	33	P1 menolämpötila	104
MAX(mitattu)	113,7			116,7			
MIN(mitattu)	72,6			71,8			
MAX-MIN	41,1			44,9			
<b>KLVES6</b>	l/s			l/s	37	P3 kl-virtaus	63
MAX(mitattu)	652,0			661,3			
MIN(mitattu)	242,4			67,4			
MAX-MIN	409,6			593,9			



## 4. LÄNSIMÄEN VIRTAUKSEN SELITTÄMINEN PAINEROILLA JA ULKOLÄMPÖTILALLA

Virtauksen selittäminen paine-eroilla ja ulkolämpötilalla on hyödyllinen siitä syystä, että virtausmittauksia on yleensä kaukolämpöverkossa aika vähän verrattuna painemittauksiin. Täten virtaus on laskettava simuloimalla. Mikäli neuromalli pystyy selittämään virtauksen riittävän hyvin, riittää yksi simulointivaihe kullekin pisteelle, jonka virtaus kiinnostaa.

Länsimäen virtausta (AT0552) selittämään on valittu kaikki pumppuasemien P1, P2, P3 ja P4 paine- ja paine-eromittaukset sekä Länsimäen paine-ero ja ulkolämpötila, yhteensä 21 selittäjää. Näistä on eri menetelmin valittu mukaan tai karsittu pois selittäjiä siten, että turhaa päällekkäisyyttä olisi mahdollisimman vähän. Liian monta turhaa selittäjää tekevät opetusvaiheesta raskaan, ja oikeiden selittäjien valinta ei ole ristikorrelaatioiden takia suoraviivainen tehtävä. Tähän tarpeeseen on sovellettu aikasarja-analyysiä, ja sitä on verrattu puhtaasti korrelaatiomenetelmiin perustuviin selittäjävalintoihin.

Mallin pohjana on käytetty kohdassa 3.2 mainittuja tuntikeskiarvoja, yhteensä 8 442 havaintoa. Koska opetusvaihe ei pystynyt käsittelemään kaikkia tunteja muistirajoitusten takia, poimittiin tuntiaikasarjasta 2/5 (joka viides arvo alkaen ensimmäisestä ja kolmannelta arvosta, kuten luvussa 2 on esitetty), jotta edustettuina olisi mahdollisimman monipuolisia tilanteita. Ennusteet voitiin toki tehdä jokaiselle tunnille.

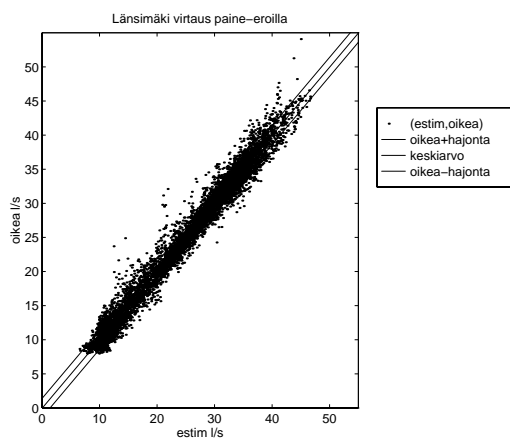
Fysikaalisia syy-seuraussuhteita ei ole pohdittu eikä siten otettu kantaa siihen, onko jäljelle jäänyt selittäjäjoukko siinä suhteessa mielekäs. Kohdassa 4.1 on eri menetelmillä valitut selittäjäkokoontimet tarkemmin esitettynä taulukkomuodossa. Viiveitä ei esiinny malleissa.

Tuloksia:


Lisäämällä selittäjiä mallin jäännösaikasarjan (selittämättä jääneet poikkeamat oikeista arvoista) ja alkuperäisten selittäjäaika-eräiden välisten ristikorrelaatioiden mukaan, kunnes ei enää löydy merkittävää jäännöksen selittäjää, saavutetaan huonompi tulos kuin päinvastaisella lähestymistavalla, jossa aikasarjamallista poistetaan kaikki huonot selittäjät. Tämä on yksi neuromallintamisen puutteita.

Aikasarja-analyysin avulla valitut selittäjät muodostavat hyvän lähtökohdan neuromallille. Jättämällä pois huonot selittäjät saadaan esille ne, joita ei voi jättää pois huonontamatta mallin selitysvoimaa. Tällä tavalla saavutetaan tarkka tahtokohta, jossa mallin selityskyky huononee huomattavasti, mikäli poistetaan vielä lisää selittäjiä. Onko jäljelle jäänyt joukko fysikaalisesti mielekäs, on toinen asia, jota tulisi pohtia.

Kuvissa 31 ja 32 esitetään tuloksia neuromallista, jonka selittäjät on valittu aikasarja-analyysillä. Ennustevirheet ovat lukuparimuodossa (ennuste,oikea) ja aikasarjamuodossa.

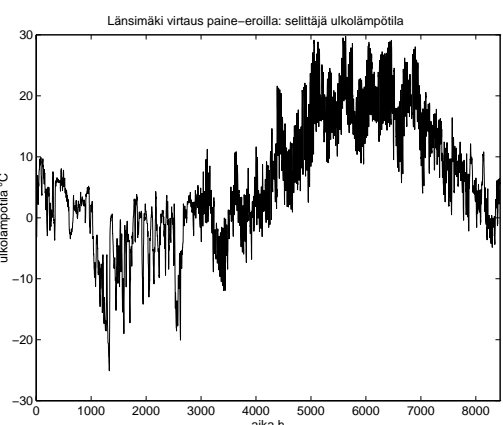
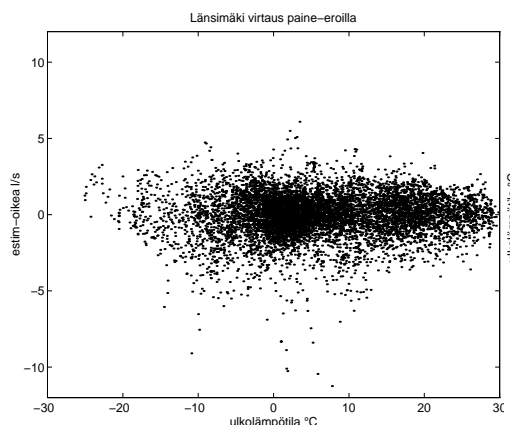


Kuva 31. Länsimäen virtausennuste paineilla.



Kuva 32. Länsimäen virtausennuste paineilla.

Kuvissa 33 ja 34 esitetään ennustevirheen riippuvuus ulkolämpötilasta sekä ulkolämpötila aikasarjana.



Kuva 33. Ulkolämpötila ja ennustevirhe. Kuva 34. Ulkolämpötila.

Huonoin malli saadaan, kun otetaan suoraan mukaan ne selittäjät, joiden korrelaatio selitettävän kanssa ylittää tietyn kynnyksarvon (tässä on käytetty arvoa 0,8). Syynä tähän on selittäjien väliset voimakkaat ristikorrelaatiot, eli useampi selittäjä selittää itse asiassa saman asian. Esimerkiksi ulkolämpötila vaikuttaa sekä suoraan selitettävään että useampaan selittäjään, joiden selitysvoima siten heikkenee, koska ulkolämpötila on jo mukana.

Selitettävä virtaus voidaan hyvin mallissa käsitellä sellaisenaan, eli virtauksen neliön selittäminen ei paranna mallia oleellisesti. Päinvastoin tulee tilanteita, jossa neliöllinen ennuste on negatiivinen. Ilmeisesti epälineaarinen tansig-suodatin ottaa huomioon mahdolliset neliölliset riippuvuudet riittävän hyvin.

Mallin opetuksessa on käytetty 2/5 alkuperäisistä hetkistä, hyvällä tuloksella. Virheen hajonta on lähes sama opetusjakson ennusteelle kuin samoilla parametreillä ennustetulle koko ajanjaksolle.

#### 4.1 Taulukkomuotoinen esitys Länsimäen virtausmalleista

Taulukossa 2 esitetään, kuinka hyviä ennusteita eri tavalla valitut selittäjäjoukot pystyvät tuottamaan. Kaikki mallit on opetettu 2/5:aan supistettuun aineistoon, ennusteet on pääosin tehty koko aineistolle. Selittäjistä on maininta, mitkä niistä ovat missäkin mallissa mukana.

Taulukko 2. Ennustemallien vertailu.

SELITETTÄVÄ										
Rakenne	tunti	tunti	tunti	tunti	tunti					
Selittäjät	aikasarja	aikasarja	kaikki	korr>0.8	korr					
Parametri(tunteja)	2/5*8442	2/5*8442	2/5*8442	2/5*8442	2/5*8442					
Ennuste	2/5*8442	8442	8442	8442	8442			Paikkano	Selitys	Idno
<b>AT0552</b>	l/s	l/s	l/s	l/s	l/s			17	Länsimäki virtaus	18
virheen keskiarvo	-0,04	-0,05								
virheen hajonta	1,38	1,40	1,33	2,60	1,62					
MAX(mitattu)		54,1								
MIN(mitattu)		8,0								
MAX-MIN		46,1								
aikasarja = aikasarja-analysillä poistettu turhat selittäjät kunnes malli huononee										
kaikki = kaikki paineet + ulkolämpötila, yht. 21 kpl										
korr>0.8 = selittäjät joiden korrelaatio selitettävän kanssa > 0.8										
korr = jäännöskorrelaatiolla otettu järjestyksessä mukaan lisää selittäjiä kunnes kaikki korrelaatiot ovat pieniä										
SELITTAJAT		MAX	MIN	MAX-MIN	aikasarja	korr>0.8	korr	Paikkano	Selitys	Idno
AT0846	bar	13,6	7,6	6,1			on	39	P4 menopaine	20
AT0852	bar	2,6	0,2	2,5	on		on	17	Länsimäki paine-ero	23
AT0946	bar	8,9	2,4	6,5	on		on	39	P4 pumpun imupaine, paluup.	25
AT1046	bar	11,8	6,1	5,7	on			38	P4 pumpun lähtöpaine, paluup.	27
MELAP4	bar	13,5	0,0	13,5		on		33	P1 menopuoli lähtöpaine	108
MELAP5	bar	13,3	0,0	13,3	on	on		35	P2 menopuoli lähtöpaine	109
MELAP6	bar	14,7	6,9	7,8		on		37	P3 menopuoli lähtöpaine	110
METUP4	bar	10,3	0,0	10,3				32	P1 menopuoli tulopaine	120
METUP5	bar	10,1	0,0	10,1	on			34	P2 menopuoli tulopaine	121
METUP6	bar	11,5	6,7	4,8				36	P3 menopuoli tulopaine	122
PAIE46	bar	6,7	0,3	6,4	on		on	39	P4 paine-ero lähtöpuoli	139
PAIER4	bar	5,2	0,0	5,2	on			32	P1 paine-ero länsi	144
PAIER5	bar	5,6	0,0	5,6				34	P2 paine-ero länsi	146
PAIER6	bar	3,6	0,3	3,2				36	P3 paine-ero länsi	148
PALAP4	bar	7,0	0,0	7,0	on	on		32	P1 paluupuoli lähtöpaine	163
PALAP5	bar	7,9	0,0	7,9				34	P2 paluupuoli lähtöpaine	164
PALAP6	bar	10,1	5,1	5,0		on	on	36	P3 paluupuoli lähtöpaine	165
PATUP4	bar	5,6	0,0	5,6	on			33	P1 paluupuoli tulopaine	176
PATUP5	bar	6,5	0,0	6,5	on			35	P2 paluupuoli tulopaine	177
PATUP6	bar	9,1	2,5	6,6	on		on	37	P3 paluupuoli tulopaine	178
ULKOLT	°C	29,9	-25,1	54,9	on	on	on		Ulkolämpötila Vantaalla	199
selittäjiä yhteensä					12	6	7			

## 5. MESIKUKANTIEN PALUULÄMPÖTILA JA PAINE-ERO

### 5.1 Paluulämpötila

Kohdassa 3.2 mainituilla tuntikeskiarvoilla on selitetty Mesikukantien paluulämpötila (PALA43) samaan tapaan kuin lentokentän paluulämpötila eli ulkolämpötilalla, menolämpötiloilla ja virtauksilla. Koivukylän kahden lämpökeskusyksikön takia selittäjiä on huomattavasti enemmän kuin lentokentällä - eri viiveet mukaan laskettuna yhteensä 11 kappaletta. Koivukylän lisäksi selittäjapisteinä toimivat pumppuasemat P3 ja P4.

Selittäjinä toimivat siten:

- ulkolämpötila (ULKOLT)
- P3:n menolämpötila (MELAM6)
- P4:n menolämpötila (MELT46)
- Koivukylä A menolämpötila (MLAM11)
- Koivukylä B menolämpötila (MELA12)
- P3:n virtaus (KLVES6)
- P4:n virtaus (VIRT46)
- Koivukylä A virtaus (KLVE11)
- Koivukylä B virtaus (KLVE12)

Selittäjäjoukosta ei ole poistettu huonoja selittäjiä. Viiveet on valittu ristikorrelaatioiden maksimien perusteella eikä erillisellä aikasarja-analysillä. Ulkolämpötilalle on asetettu myös vuorokausiviive, kuten itse selitettävälle paluulämpötilalle.

Jotta lähtötiedot olisivat mahdollisimman samanlaisia lentokentän kanssa, on kuumimmasta kesäajasta poistettu 2 000 tuntia materiaalista. Jäljelle jää yli 6 000 tuntia.


Selittäjien viiveinä on käytetty:

PALA43	selittäjä	viive (h)
	MELAM6	2
	KLVES6	0
	MLAM11	0
	KLVE11	0
	MELA12	0
	KLVE12	0
	MELT46	1
	VIRT46	0
	ULKOLT	4, 28
	PALA43	24

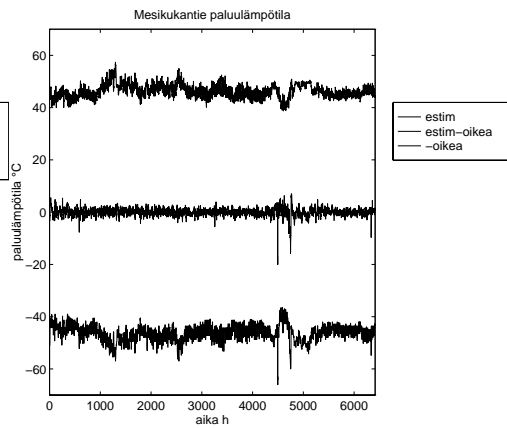
Tuloksia:

Verrattuna lentokentän paluulämpötilaan Mesikukantien paluulämpötila on paremmin selitettävissä. Virheen hajonta on yli puoli astetta pienempi. Molempien paluulämpötilojen maksimi- ja minimiarvot ovat suurin piirtein samoja.

Kuvissa 35 ja 36 esitetään tuntiennusteet ja oikeat arvot lukuparimuodossa (ennuste, oikea) sekä aikasarjamuodossa.




Kuva 35. Mesikukantien paluulämpötilaennuste.

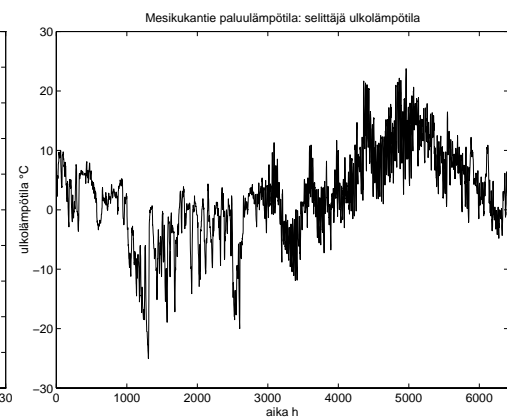


Kuva 36. Mesikukantien paluulämpötilaennuste.

Kuvissa 37 ja 38 esitetään ennustevirheen riippuvuus ulkolämpötilasta sekä ulkolämpötila aikasarjana.



Kuva 37. Ulkolämpötila ja ennustevirhe.



Kuva 38. Ulkolämpötila.

## 5.2 Taulukkomuotoinen esitys Mesikukantien paluulämpötilamallista

Taulukossa 3 esitetään Mesikukantien mallin tulokset. Taulukon esitysmuoto on samanlainen kuin aikaisemmin esitetyissä taulukoissa.

Taulukko 3. Mesikukantien paluulämpötilamalli.

SELITETTÄVÄ								
Rakenne	tunti							
Parametrit(tunteja)	6414							
Ennuste	6414				Paikkano	Selitys	ldno	Suure
<b>PALA43</b>	°C				28	Mesikukantie kl-paluulämpötila	156	Tr
virheen keskiarvo	0.01							
virheen hajonta	1.52							
MAX(mitattu)	66.0							
MIN(mitattu)	36.4							
MAX-MIN	29.6							
SELITTÄJÄT								
		MAX	MIN	MAX-MIN	Paikkano	Selitys	ldno	Suure
KLVE11	l/s	171.5	0.0	171.5	11	Koivukylä A kl-vesivirtaus		57 F
KLVE12	l/s	377.2	56.3	320.9	10	Koivukylä B kl-virtaus		58 F
KLVES6	l/s	661.3	67.4	593.9	37	P3 kl-virtaus		63 F
MELA12	°C	111.0	66.2	44.8	10	Koivukylä B menolämpötila		98 Tf
MELAM6	°C	117.0	77.6	39.4	37	P3 menolämpötila		106 Tf
MELT46	°C	115.5	69.3	46.2	39	P4 kl-menolämpötila		111 Tf
MLAM11	°C	111.0	48.0	63.0	11	Koivukylä A menolämpötila		123 Tf
ULKOLT	°C	23.8	-25.1	48.8		Ulkolämpötila Vantaalla		199 Tu
VIRT46	l/s	213.9	0.6	213.3	39	P4 kl-virtaus		205 F

## 5.3 Paine-ero

Toisin kuin lentokentän paine-ero, Mesikukantien paine-ero (PAIE43) on selitetty pumppuasemien P1, P2, P3 ja P4 sekä Koivukylän paine-eroilla ottamatta kantaa siihen, miten nämä fysikaalisesti muodostavat paine-eron. Ulkolämpötilakin on käytetty selittäjänä. Tässä on käytetty kaikki käytettävissä olevat tuntihavainnot, yhteensä yli 8 000 tuntia. Vuorokausiiviiveitä ei ole käytetty mallissa.

Huonoja selittäjiä ei ole poistettu mallista, mutta erilaisia selittäjäkokoja, kaikki ilman viiveitä, on kokeiltu:


- pelkästään paine-erot
- paine-erot ja ulkolämpötila
- kaikki paineet (myös absoluuttiset) ja ulkolämpötila
- kaikki paineet (myös absoluuttiset), virtaukset ja ulkolämpötila.

Tuloksia:

Kun mallissa käytetään kaikki paineisiin liittyvät selittäjät pumppuasemilla P1, P2, P3 ja P4 sekä Koivukylässä, saadaan ylivoimaisesti paras malli. Virtaukset eivät paranna mallia, ja myös ulkolämpötilan selitysvoima näyttää olevan harvinaisen alhainen.

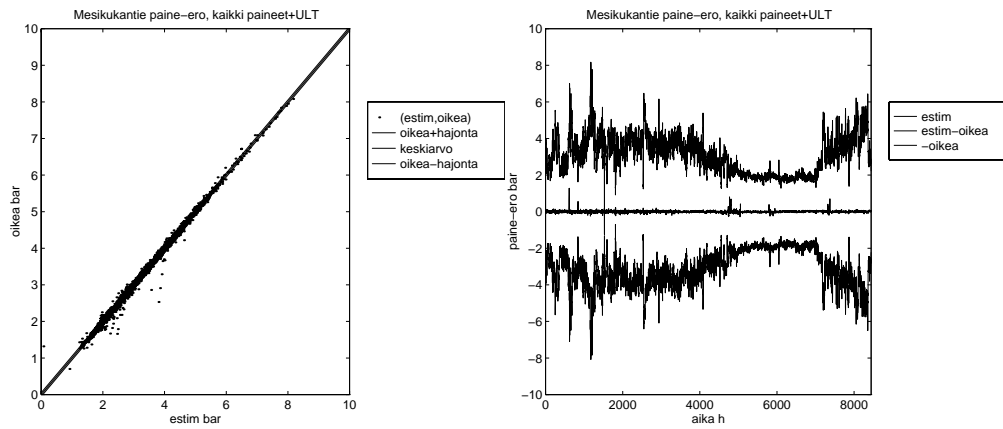
Pelkästään paine-eroilla ei pystytä selittämään Mesikukantien paine-eroa läheskään yhtä hyvin kuin mallilla, jossa absoluuttisetkin paineet esiintyvät.

Kuvissa 39 ja 40 esitetään ennusteet, jossa selittäjinä toimivat paine-erot ja ulkolämpötila, lukuparimuodossa (ennuste,oikea) ja aikasarjumuodossa.



Kuva 39. Paine-ero-ennuste paine-eroista. Kuva 40. Paine-ero-ennuste paine-eroista.

Kuvissa 41 ja 42 esitetään ennusteet, jossa selittäjinä toimivat kaikki paineet ja ulkolämpötila, lukuparimuodossa (ennuste,oikea) ja aikasarjumuodossa.



Kuva 41. Paine-ero-ennuste kaikista paineista.

Kuva 42. Paine-ero-ennuste kaikista paineista.

## 5.4 Taulukkomuotoinen esitys Mesikukantien paine-eromalleista

Taulukossa 4 Mesikukantien paine-eromallissa kaikki ennusteet on laskettu koko aineistolle (8441 h), mutta joissakin tapauksissa opetusvaiheessa (parametrit) on käytetty supistettua havaintoaineistoa.

Taulukko 4. Mesikukantien paine-eromalli.

SELITETTÄVÄ							
Rakenne	tunti	tunti	tunti	tunti			
Parametrit(tunteja)	8441	8441	2/5*8441	2/5*8441			
selittäjät	paine-erot	paine-erot+ULT	kaikki paineet+ULT	kaikki paineet+virt+ULT			
Ennuste	8441	8441	8441	8441	Paikkano	Selitys	Idno
<b>PAIE43</b>	bar	bar	bar	bar	28	Mesikukantie paine-ero	136
virheen keskiarvo	0,000	-0,001	0,000	-0,003			
virheen hajonta	0,348	0,338	0,053	0,054			
MAX(mitattu)				8,08			
MIN(mitattu)				0,70			
MAX-MIN				7,38			
SELITTÄJÄT	MAX	MIN	MAX-MIN		Paikkano	Selitys	Idno
PAIE11	5,9	1,2	4,7		11	Koivukylä A paine-ero	131
PAIE12	6,3	0,0	6,3		10	Koivukylä B paine-ero	132
PAIE46	6,7	0,3	6,4		39	P4 paine-ero lähtöpuoli	139
PAIER4	5,2	0,0	5,2		32	P1 paine-ero länsi	144
PAIER5	5,6	0,0	5,6		34	P2 paine-ero länsi	146
PAIER6	3,6	0,3	3,2		36	P3 paine-ero länsi	148
AT0846	13,6	7,6	6,1		39	P4 menopaine	20
AT0946	8,9	2,4	6,5		39	P4 pumpun imupaine, paluup.	25
AT1046	11,8	6,1	5,7		38	P4 pumpun lähtöpaine, paluup.	27
MELAP4	13,5	0,0	13,5		33	P1 menopuoli lähtöpaine	108
MELAP5	13,3	0,0	13,3		35	P2 menopuoli lähtöpaine	109
MELAP6	14,7	6,9	7,8		37	P3 menopuoli lähtöpaine	110
MEPA11	15,0	7,1	7,9		11	Koivukylä A menopaine	117
MEPA12	15,7	8,2	7,5		10	Koivukylä B menopaine	118
METUP4	10,3	0,0	10,3		32	P1 menopuoli tulopaine	120
METUP5	10,1	0,0	10,1		34	P2 menopuoli tulopaine	121
METUP6	11,5	6,7	4,8		36	P3 menopuoli tulopaine	122
PALAP4	7,0	0,0	7,0		32	P1 paluupuoli lähtöpaine	163
PALAP5	7,9	0,0	7,9		34	P2 paluupuoli lähtöpaine	164
PALAP6	10,1	5,1	5,0		36	P3 paluupuoli lähtöpaine	165
PAPA11	9,8	5,0	4,8		11	Koivukylä A paluupaine	172
PAPA12	11,8	5,6	6,2		10	Koivukylä B paluupaine	173
PATUP4	5,6	0,0	5,6		33	P1 paluupuoli tulopaine	176
PATUP5	6,5	0,0	6,5		35	P2 paluupuoli tulopaine	177
PATUP6	9,1	2,5	6,6		37	P3 paluupuoli tulopaine	178
KLVES4	818,4	0,0	818,4		33	P1 ki-virtaus	61
KLVES5	802,5	0,0	802,5		35	P2 ki-virtaus	62
KLVES6	661,3	0,0	661,3		37	P3 ki-virtaus	63
VIRT46	213,9	0,6	213,3		39	P4 ki-virtaus	205
ULKOLT	29,9	-25,1	54,9			Ulkolämpötila Vantaalla	199



## 6. JOHTOPÄÄTÖKSIÄ JA JATKOTOIMENPITEITÄ

Tutkimuksessa jatkettiin aiemmin tehtyä tilastollisten menetelmien käytön tutkimusta kaukolämpöverkon tilan estimoimiseksi. Tässä tutkimuksessa keskityttiin neuroverkkolaskennan hyödyntämiseen verkon tilan estimoinnissa. Mittauspisteitä oli enemmän kuin aiemmin tehdyssä tutkimuksessa. Tilastopohjaisen mallin edut verrattuna kaukolämpöverkon fysikaaliseen malliin olisivat sen yksinkertaisempi ylläpito ja helpompi käyttö verkon ajotilanteiden estimoinnissa. Tilastollisen materiaalin käsittely mahdollistaisi myös verkossa mahdollisesti orastavien vikakohteiden havaitsemisen nopeammin, ennen kuin ne johtaisivat suurvuotoon.

Raportissa tarkastellaan Vantaan Energia Oy:n verkon tilan estimointia tarkkailupisteissä Helsinki-Vantaan lentokentällä, Länsimäessä ja Mesikukantiellä Tikkurilassa. Havainto- ja syöttöpisteitä on kuten aiemmassakin tutkimuksessa, mutta tässä yhteydessä niitä hyödynnettiin laajemman aineiston pohjalta. Estimoitavia suureita tarkkailupisteissä em. paikoissa ovat meno-paluulämpötilat, absoluuttinen paine, paine-ero ja virtaus. Mallit kehitettiin 10 minuutin ja tunnin keskiarvomittauksiin perustuen.

Lentokentän aineistolla haettiin tarkkailupisteen selittäjille paras kombinaatio eri viiveillä. Meno- ja paluulämpötilan sekä virtauksen mallien viritys toimii hyvin, jos saavutettu ennustetarkkuus riittää; menolämpötilan keskihajonta saavuttaa 1,4 %, paluulämpötilan 4 %, virtauksen 6 % ja paine-eron 11,5 % mittauksessa esiintyneiden maksimi- ja minimiarvojen keskiarvosta. Paine-eron ennustaminen pelkästään verkossa esiintyvien tunnettujen paine-erojen avulla ennako-odotuksista huolimatta ei toiminut hyvin, vaan lisäselittäjiksi tarvitaan tunnettuja absoluuttisia painemittauksia. Tuntiarvoihin perustuva malli toimii parhaiten, jos ennustetaan tunneittain tarkkailupisteen tilaa, mutta 10 min:n välein mitattuihin arvoihin perustuva malli tarvitaan, jos halutaan 10 min:n välein tarkkailupisteen estimoitu tila. Myös 10 min:n mittauksilla opetettu tuntirakennemalli toimi varsin hyvin, mutta siinä viiveen pitää olla nolla tai tunnin monikertoja. Lämpötilan ennustamisen viivetarkastelussa (suora korrelaatiomenetelmä tai aikasarja-analyysi) todettiin, että vakioviiveen käyttö on toistaiseksi perusteltua, koska dynaamisen muuttuvan viiveen käytön hyöty on marginaalinen ja johtanee monimutkaiseen ja vaikeasti eri tilanteissa hallittavaan ratkaisuun. Lentokentän paluulämpötilaa estimoititiin myös lineaarisella aikasarja-analyysillä samoilla selittäjillä kuin neuromallillakin. Neuromallin todettiin ennustavan paluulämpötilan paremmin kuin aikasarjamalli. Ennustevirheen hajonta oli aikasarjamallilla 17 % suurempi kuin neuromallilla saavutettu tulos.

Länsimäen paine-eron ennustamista tutkittiin käyttäen selittäjinä pumppuasemien P1, P2, P3 ja P4 paine- ja paine-eromittauksia sekä Länsimäen paine-eroa ja ulkolämpötilaa. Ennustemallina käytettiin tuntikeskiarvomallia. Neuromalli, jossa on kaikki 21 selittäjää mukana, antoi parhaan tuloksen, 4 %:n keskihajonnan maksimi- ja minimiarvojen keskiarvosta. Jos selittäjien määrä rajoitetaan siten, että otetaan mukaan vain 7 merkittävintä selittäjää (ulkolämpötila, Länsimäen paine-ero, pumpun 4 paluupuolen

imupaine, P4:n lähtöpuolen paine-ero ja lähtöpaine, P3:n paluupuolen tulo- ja lähtöpaine), niin keskihajonta kasvaa 5 %:iin maksimi- ja minimiarvojen keskiarvosta laskettuna. Parametrien määrä vähenee kuitenkin 1/3:aan. Virtauksen neliöllisen suureen ennustaminen ei paranna mallia.

Kolmantena kohteena oli Mesikukantien paluulämpötilan ja paine-eron ennustaminen. Paluulämpötilan ennustaminen tehtiin periaatteessa samalla tavalla kuin lentokentän tapauksessa. Selittäjiksi otettiin lisäksi Koivukylän lämpökeskuksen kattiloiden menolämpötilat ja virtaukset. Tuntikeskiarvoneuromallilla paluulämpötilan keskihajonnan virheeksi saatiin 3 % maksimi- ja minimiarvojen keskiarvosta. Paine-eron ennustamisessa käytettiin pumppuasemien ja Koivukylän lämpökeskuksen painetietoja sekä ulkolämpötilaa. Näin saatiin paras ennuste, jonka keskihajonnaksi saatiin 1,2 % maksimi- ja minimiarvojen keskiarvosta.

Tilastollisten mallien käyttö edellyttää riittävän kattavan tilastoaineiston keräämistä. Energialaitosten mittauksissa pitäisikin kiinnittää erityistä huomiota em. seikkaan. Kuluttajien kaukoluenta mahdollistaisi jo monien energialaitosten kaukolämpöjärjestelmissä esim. verkon painetietojen keräämisen kuluttajan kohdalta verkosta. Merkittävimpien kuluttajien lämpötila- ja virtaustietojen sekä verkon painetietojen avulla pystyttäisiin luomaan verkosta tilastolliseen aineistoon perustuen hyvä tilamalli, jota voitaisiin käyttää monella tavalla energialaitoksen ja kuluttajien hyödyksi.

Neurolaskennalla saatiin hyvä kaukolämpöverkon tilan estimointimalli tilastolliseen mittaustietoon perustuen. Mallin muodostaminen, selittäjien hakeminen ja mallin opettaminen on kuitenkin työläs vaihe ja vaatii hyvää asiantuntemusta. Nämä tehtävät pitäisi pystyä automatisoimaan siten, että verkkomallin käyttäjän ei tarvitse opettaa neuromallia vaan tietokone hoitaa ko. toiminnot automaattisesti. Käyttöhenkilökunta ainoastaan käyttää neuromallia kaukolämpöverkon tilan estimointiin erilaisissa käyttötilanteissa ja saa esim. kustannusennusteita kaukolämpöverkon eri ajotilanteista ja voimalaitoksen tai kattilalaitoksen ajosuosituksen odotettavissa olevaan kaukolämpöverkon tilan muutokseen. Verkon kunnan tarkkailu pitäisi tuottaa myös käyttäjistä riippumatta. Käyttäjä ainoastaan pyytää verkon kuntoanalyysin halutessaan tai malli hälyttää havaitessaan jotain poikkeavaa.

Neuromallin, kuten kaikkien muidenkin tilastopohjaisten mallien, käytössä yksi suurimpia työvaiheita on datan kerääminen ja muokkaaminen tilastolliseen laskentaan tarvittavaan muotoon. Historiatiedoista muodostetaan opetusvaiheessa käytettävää tilastollista materiaalia. Ennustetta tehdessä tulee myös olla käytettävissä jonkinlainen historia – ja suunnittelupohjainen aineisto. Mallin uudelleen opettamista ajatellen automaattinen datojen muodostaminen ei saa olla liian rajoittava tekijä. Mallin uudelleen opettamisen ja mallin rakenteen muuttamisen tarpeen vaatiessa tulee olla riittävän yksinkertaista, jotta sitä tarvittaessa myös tehtäisiin.

Kehitettyä mallia pitäisi vielä testata huomattavasti suuremmalla mittausaineistolla kuin tähän mennessä on tehty ja 2 - 3 erilaisessa kaukolämpöverkossa. Mallin laskemia tuloksia voitaisiin verrata todellisiin ajotilanteisiin ja todeta, olisiko voitu saavuttaa säästöjä, jos olisikin ajettu kaukolämpöverkkoa toteutetusta ajotavasta poiketen

neuromallin osoittamalla tavalla. Mallin toimintaa olisikin kehitettävä kustannustietoisempaan suuntaan ja lisättävä myös kaukolämpöverkon käytön optimointia suorittava laskentarutiini. Myös analysointi mittausaineistossa, jossa on tapahtunut verkon vuototilanne, pitäisi tutkia. Näin voitaisiin todeta, voidaanko tuleva vika havaita ja millaisella menetelmällä riittävän ajoissa etukäteen.

## VIITTEET

1. Kari Sipilä, 1996. Tilastollisten mallien soveltaminen kaukolämpöjärjestelmän dynamiikan kuvaamiseen. Espoo: Valtion teknillinen tutkimuskeskus, VTT Julkaisuja - Publikationer 813. 45 s. + liitt. 2 s.
2. Math Works, 1994. Neural Network Toolbox Manual. USA: Math Works Inc. 440 s.