



Lyhyen ajan ennusteet liikennetiedotuksen osana



VIKING

Lyhyen ajan ennusteet liikennetiedotuksen osana

Tiehallinnon selvityksiä 73/2001

Tiehallinto

Helsinki 2001

ISSN 1457-9871
ISBN 951-726-829-7
TIEH 3200719

Oy Edita Ab
Helsinki 2001

Julkaisua myy/saatavana:
Tiehallinto, julkaisumyynti
Telefaksi 0204 22 2652
S-posti julkaisumyynti@tiehallinto.fi
www.Tiehallinto.fi/julk2.htm

Tiehallinto
Liikenteen palvelut
PL 33
00521 HELSINKI

Puhelinvaihte 0204 22 150

Lyhyen ajan ennusteet liikennetiedotuksen osana. Helsinki 2001. Tiehallinto, Liikenteen palvelut. Tiehallinnon selvityksiä 73/2001. 30 s. + liitt. 16 s. ISSN 1457-9871, ISBN 951-726-829-7, TIEH 3200719.

Asiasanat: liikennetiedotus, ennusteet

Aiheluokka: 11, 20

TIIVISTELMÄ

Lyhyen ajan liikenne-ennusteita voidaan hyödyntää monissa liikenteen hallinnan toiminnoissa kuten automaattisissa liikenteen ohjausjärjestelmissä, alueellisessa liikenteen ohjauksessa ja liikennetiedotuksessa. Selvityksessä kartoitettiin kirjallisuustutkimuksen avulla, mihin vaiheeseen lyhyen ajan eli alle kahden tunnin päähän ulottuvien ennustemenetelmien tutkimuksissa ja käytännön soveltamisessa on edetty ja mitä kokemuksia on saatu ja mitä kehityssuuntia valittu. Lisäksi arvioitiin, millaiset mallit vaikuttavat lupaavimmilta liikenteen hallinnan palvelusovellusten kannalta. Selvityksellä luodaan pohjaa liikennetiedotuksen seuraavalle kehittämisvaiheelle Suomessa. Tästä syystä eri ennustemenetelmiä, niiden tarvitsemia lähtötietoja ja ennusteiden tarkkuutta tarkasteltiin ensisijaisesti liikennetiedotuksen näkökulmasta.

Kirjallista materiaalia aiheesta löytyi kohtuullisen helposti. Tutkimusta tehdään laajalti ja erilaisia ennustemalleja ja -menetelmiä on paljon kehitteillä, mutta päivittäisessä liikennetiedotuskäytössä olevia järjestelmiä tai toteutettuja palveluja ei löytynyt. Suurin osa läpikäydyistä lähteistä käsitteli malleja, joita on korkeintaan testattu oikealla liikennetiedolla. Mallien hyvyyden vertailu oli vaikeaa, koska raporteissa ennusteiden hyvyttä on kuvattu hyvin erilaisilla virheen tunnusluvulla. Lisäksi mallin hyvyys voi yhden tunnusluvun avulla tarkasteltuna vaikuttaa kovin erilaiselta kuin toisen tunnusluvun avulla tarkasteltuna. Eri menetelmien käyttökelpoisuutta liikennetiedotukseen arvioitiin lähinnä sillä perusteella, kuinka suuren osan ajasta malli ennusti oikein. Liikennetiedotuksessa lyhyen ajan ennusteista on eniten hyötyä liikenteen ollessa ruuhkautunutta. Tärkeää on, miten hyvin malli toimii nimenomaan ruuhkatilanteissa. Tiedotuksen näkökulmasta ei ole syytä hyväksyä ennusteissa suurempaa virhemarginaalia ruuhka-aikana kuin muulloin. Ennusteiden tarkkuus on tiedotuspalvelussa kenties vielä tärkeämpää kuin liikenteenohjausjärjestelmissä, koska ennuste kerrotaan tienkäyttäjälle suoraan eikä tämä koe sitä vain välillisesti ohjausjärjestelmän toiminnan kautta.

Liikenne-ennustemenetelmät voidaan ryhmitellä neljään luokkaan: historiadataa ja tilastotietoa käyttävät menetelmät, neuroverkkoja ja/tai sumeaa logiikkaa mallinnuksessa hyödyntävät tekoälymenetelmät, simulointi- ja sijoittelumenetelmät sekä Kalman-suodattimeen perustuvat mallit. Puhtaat historiadataa käyttävät menetelmät ovat helppoja ottaa käyttöön ja tekevät ennusteen nopeasti, mutta ne eivät pysty reagoimaan liikennetilanteen yllättäviin muutoksiin. Simulointi- ja sijoittelumenetelmät soveltuvat erityisesti kaupunkialueille, joissa verkkonäkökulma on tärkeä ja kuljettajan reitinvalinnalla on suuri merkitys. Tekoälymenetelmät osaavat ennustaa liikennetilannetta muuttuvissakin olosuhteissa, jos mallin muuttujien valinta ja opettaminen on onnistunut. Eri ennustemenetelmät tarvitsevat osittain erilaisia lähtötietoja, mutta useimmiten mallit käyttävät lähtötietoinaan ajantasaisista liikennemäärä-, nopeus ja varausastetietoja. Löytyi myös malleja, joissa on yhdistetty useita eri menetelmiä. Tämän perusteella ei voida sulkea pois mitään menetelmää vaan pikemminkin mallien kehittelyssä tulisi pyrkiä hyödyntämään eri menetelmien hyviä puolia. Menetelmien kehittämisessä ja kokeiluissa tulisikin jatkossa painottaa enemmän liikennetiedotuksessa ja alueellisessa ohjauksessa vaadittavaa verkkonäkökulmaa.

Lyhyen ajan ennusteet liikennetiedotuksen osana. [Short-term traffic predictions. State of the Art study] Helsinki 2001. Finnish Road Administration. Finnra Reports 73/2001. 30 p. + app. 16 p. ISSN 1457-9871, ISBN 951-726-829-7, TIEH 3200719.

Keywords: road user information, predictions

ABSTRACT

Short-term traffic predictions can be used for many traffic management measures including automatic traffic control, area traffic management and road user information. This survey maps, with the help of a literature study, how far research work, prediction methods and their practical applications have proceeded. Also it explains what lessons have been learned and what directions of development have been chosen. The models were assessed in order to find out which seem to be the most promising for traffic management services. The purpose of this report is to provide a basis for future development of road user information in Finland. The input data requirements and prediction accuracy of various methods were therefore considered mainly from the traffic information point of view.

Literature concerning the subject could be fairly easily found. Research is going on, various prediction models and methods are developed but real information systems in operation and realised services were not found. The main part of the studied sources discussed models that had at most been tested with real traffic data. It was difficult to assess the performance of the models as it was described in the reports due to the different error parameters used. In addition, one parameter can give quite a different impression than another. The usability of various applications for traffic information was mainly assessed based on how long a model could predict correctly. Short-term predictions are most practical for information services during congestion. It is therefore important that the model performs well in congestion. From the information point of view there is no reason to tolerate larger margins of error during congestion. The accuracy of the predictions may be even more important for information than for control systems because the prediction is disseminated directly to road users.

Traffic prediction methods can be classified in four classes: methods making use of historic and statistic data, various artificial intelligence methods that make use of neural networks or fuzzy logic, simulation and traffic assignment methods and models based on Kalman filters. Methods making use of pure historic data are easy to implement and quickly calculate the prediction but they cannot react to surprising changes in the traffic situation. Simulation and traffic assignment methods suite especially well in urban environments where the network level point of view is important and the drivers' choice of route has great significance. Artificial intelligence methods are able to predict the traffic situation also in variable situations if the choice of variables and their learning has been successful. Various prediction methods partly require different input data but most models make use of real time traffic volume, speed and occupancy measurement. Also such models were found that make use of several methods. Based on this no method can be excluded, on the contrary the advantages of the various methods should be utilised for model development. In the future more emphasis should be on developing and testing the methods focusing on the network point of view required for traffic information and area traffic management.

The project has been granted European Community financial support in the field of Trans-European Networks – Transport.

ESIPUHE

Tiehallinto on tilannut Lyhyen ajan ennusteet liikennetiedotuksen osana – State of the Art –selvityksen Traficon Oy:ltä. Työn tavoitteena on kartoittaa tilannekuvaus maailmalla tehdyistä ja hyödynnetyistä kokemuksista lyhyen ajan liikenne-ennusteisiin liittyen.

Selvitys on tehty Traficon Oy:ssä kesällä 2001. Kirjallisuusselvityksen tekijänä toimi tekn. yo. Heli Mattila. Traficon Oy:ssä työhön osallistuivat myös DI Jari Oinas ja DI, DE Kristian Appel. Tiehallinnossa tutkimuksen etenemiseen ja valvontaan osallistuivat DI Sami Luoma, FK Jorma Helin sekä DI Martin Johansson. Tutkija, DI Satu Innamaa Teknillisestä korkeakoulusta osallistui selvityksen tekemiseen neuvonantajana ja mm. avustamalla kirjallisuuslähteiden etsinnässä.

Hanke on saanut Euroopan unionin liikenteen perusrakenteen kehittämiseen tarkoitettua TEN-T (Trans-European Networks – Transport) –rahoitusta.

Helsingissä 30. marraskuuta 2001

Tiehallinto

Liikenteen palvelut

Sisältö

1. JOHDANTO	9
2. TYÖN LÄHTÖKOHDAT JA TAVOITTEET	10
3. TUTKIMUSMENETELMÄ	11
4. LYHYEN AJAN ENNUSTEIDEN TARVE JA KÄYTTÖTARKOITUS	12
4.1 Ennusteiden tarve liikenteen hallinnan eri palveluissa	12
4.2 Vaatimukset liikenteen seurannalle	15
4.3 Tienkäyttäjän tarpeet	16
5. ENNUSTEMALLIEN LUOKITTELU	19
5.1 Menetelmien jaottelu	19
5.2 Tilastolliset menetelmät	19
5.3 Tekoälymenetelmät	20
5.3.1 Neuroverkot	20
5.3.2 Sumea logiikka	21
5.4 Simulointi- ja sijoittelumallit	21
5.4.1 Mikrosimulointi	21
5.4.2 Makrosimulointi	22
5.5 Kalman-suodattimeen perustuvat mallit	22
6. TUTKIMUSTULOSTEN ANALYSOINTI	23
6.1 Yleistilanne	23
6.2 Mallien tarvitsemat lähtötiedot	23
6.3 Ennusteiden arviointi	25
7. JOHTOPÄÄTÖKSET JA JATKOTOIMENPITEET	27

1. JOHDANTO

Yksi liikennetiedotuksen tärkeimmistä toiminnoista on ajantasainen sujuvuustiedotus eli jatkuva, linkkikohtainen tieto liikenteen sujuvuudesta. Tiedon avulla autoilija voi valita reittinsä välttyäkseen turhilta jonotuksilta ja viivytyksiltä sekä riskeiltä. Sujuvuustieto on erittäin hyödyllinen myös liikennekeskuksen päivystäjille heidän työssään sekä tiedottajille esimerkiksi paikallisradioasemilla.

Tienkäyttäjille palvelu on vieläkin hyödyllisempi, jos sitä täydentää ns. lyhyen ajan ennuste liikenteen sujuvuuden arvioidusta kehittymisestä lähiaikoina. Tällainen palvelu voi toimia kysyntää ohjaavana. Autoilija voi suunnitella reittinsä ja harkita tarvittaessa uudelleen lähtöaikaansa. Palvelun aikaperspektiivi saattaa vaihdella tiedotuksen tarkoituksesta ja alueellisesta laajuudesta johtuen. Palvelu voi noudattaa esimerkiksi samaa tarkkuustasoa kuin nykytilanteen sujuvuustiedotus aikatahtäimen ollessa 15 min – 2 tuntia. Valtateiden ruuhkissa lähinnä viikonloppuisin ja juhlapyhinä aikatahtäin voi olla myös selvästi pidempi esimerkiksi 6 – 12 tuntia tai 24 tuntia ja tarkkuus vastaavasti karkeampi. Tässä selvityksessä on keskitytty ensiksi mainittuihin eli ennusteisiin, jotka ulottuvat korkeintaan noin kahden tunnin päähän nykyhetkestä.

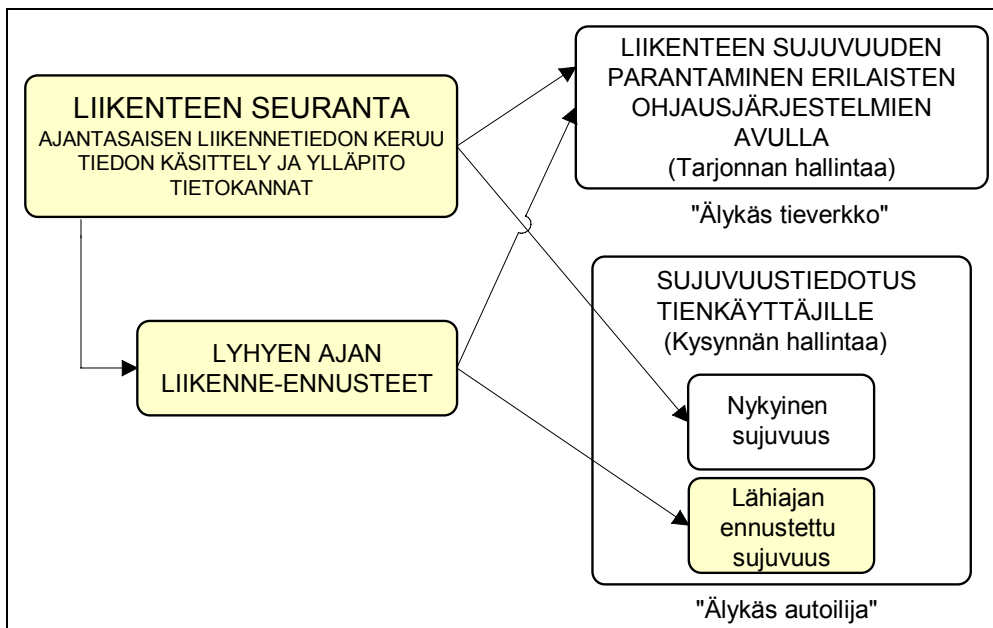
Lyhyen ajan ennusteen tuottaminen liikenteen sujuvuudesta vaatii mallintamista. Se voi tapahtua joko vertaamalla nykytilaa aikaisempiin tilanteisiin pelkästään silmämääräisesti tai perustua monimutkaisiin uusimpia mallinnusmenetelmiä (neuroverkot, sumea logiikka jne.) käyttäviin menetelmiin. Näiden välille mahtuu monenlaisia perinteisempiä mallinnusmenetelmiä.

Palvelua kehittämisessä tärkeä näkökulma on, miten ennustetietoa voidaan hyödyntää. Palvelusta on tehtävä tienkäyttäjälle helposti hyödynnettävä. Lisäksi on mietittävä, miten tiedotus vaikuttaa autoilijoiden käyttäytymiseen ja sitä kautta verkon toimintaan ja miten tämä voidaan huomioida mallinnuksessa ja tiedotuksessa.

2. TYÖN LÄHTÖKOHDAT JA TAVOITTEET

Maailmalla on tutkittu ja kokeiltu lyhyen ajan ennustemenetelmiä jo useita vuosia. Menetelmiä on kehitetty sekä sujuvuustiedotuksen että ohjauksen näkökulmasta. Tässä työssä keskitytään autoilijoille suunnattuun sujuvuustiedotukseen eli näkökulma on informaation tuottamisessa ja sitä kautta kysynnän ohjaamisessa (kuva 1). Työn tavoitteena on selvittää, kuinka pitkälle asiassa on muualla maailmassa edetty ja mitä kehityssuuntia on valittu. Tarkoituksena on selvittää, millaiset mallit vaikuttavat lupaavimmilta käytännön soveltamisen kannalta. Ennusteiden luotettavuuden lisäksi huomioitavia seikkoja ovat mm. mallin asettamat vaatimukset liikenteen seurannalle, mallin käyttämisen ja ylläpidon vaatimukset, mallin soveltaminen uusiin kohteisiin ja soveltuvuus erilaisten liikennetilanteiden ennustamiseen. Myös mallien asettamat laitevaatimukset lähinnä laskentatehon suhteen on huomioitava. Selvityksessä keskitytään erityisesti lyhyen ajan sujuvuustiedotuksen käytännön toteuttamiseen ja tuotteistukseen, joten vertailuun on otettu mukaan malleja, joiden toiminnasta käytännön tilanteissa on mahdollisimman paljon tietoa ja kokemuksia. Kiinnostuksen kohteena ovat myös tiedotuksella saavutettavat hyödyt sekä palvelun kustannukset.

Selvityksen tarkoitus on luoda pohja liikennetiedotuksen seuraavalle kehittämisvaiheelle Suomessa. Kun liikenteen ajantasainen sujuvuustiedotus saadaan liikenteen ajantasaisen seurannan myötä toimimaan kattavasti lähivuosina, on paljolti vain mallinnuksesta kiinni, milloin voidaan ryhtyä kokeilemaan lyhyen ajan sujuvuusennustetta palveluna. Tiehallinnon tavoitteena on, että liikennetilanneluokan lyhyen aikavälin ennusteet saataisiin kattavaan palvelukäyttöön viimeistään vuonna 2010 (Tiehallinto 2001a). Tavoitteeseen edetään tutkimustyön ja rajoitettujen kokeilujen kautta.



Kuva 1. Lyhyen ajan liikenne-ennusteiden hyödyntäminen osana liikenteen hallintaa. Tässä selvityksessä keskitytään tienkäyttäjille suunnattuun liikenteen sujuvuustiedotukseen.

3. TUTKIMUSMENETELMÄ

Selvitys on suoritettu kirjallisuustutkimuksena. Ensisijaisina tietolähteinä on käytetty IRRD-tietokantaa (International Transport Research Documentation) sekä ITS World Congress esitelmiä vuosilta 1997 – 2000. Hakusanoina on käytetty lähinnä ilmaisuja ”short term”/”short time”, ”prediction”/”forecast” sekä ”travel time information”. Haku IRRD-tietokannasta tehtiin Tiehallinnon kirjastossa. Tiehallinnon kirjaston henkilökunta avusti tiedonhaussa opastamalla IRRD-tietokannan käytössä ja hankkimalla tietokannan avulla löydetyt lähteet selvitystyön tekijöiden käyttöön. Tutkimusta varten on myös haastateltu tutkija, diplomi-insinööri, Satu Innamaata, joka on perehtynyt erityisesti neuroverkkojen käyttöön lyhyen ajan liikenne-ennusteissa.

Oleellisimmiksi katsotut lähteet on listattu taulukkoon (liite 3), jossa kustakin lähteestä kerrotaan selvityksen kannalta tärkeimmät asiat tiivistetyssä muodossa. Mielenkiintoisimmista tapauksista on tehty kuvauskortit (liite 1), joissa kerrotaan tutkimuksesta ja sen tuloksista laajemmin.

4. LYHYEN AJAN ENNUSTEIDEN TARVE JA KÄYTTÖTARKOITUS

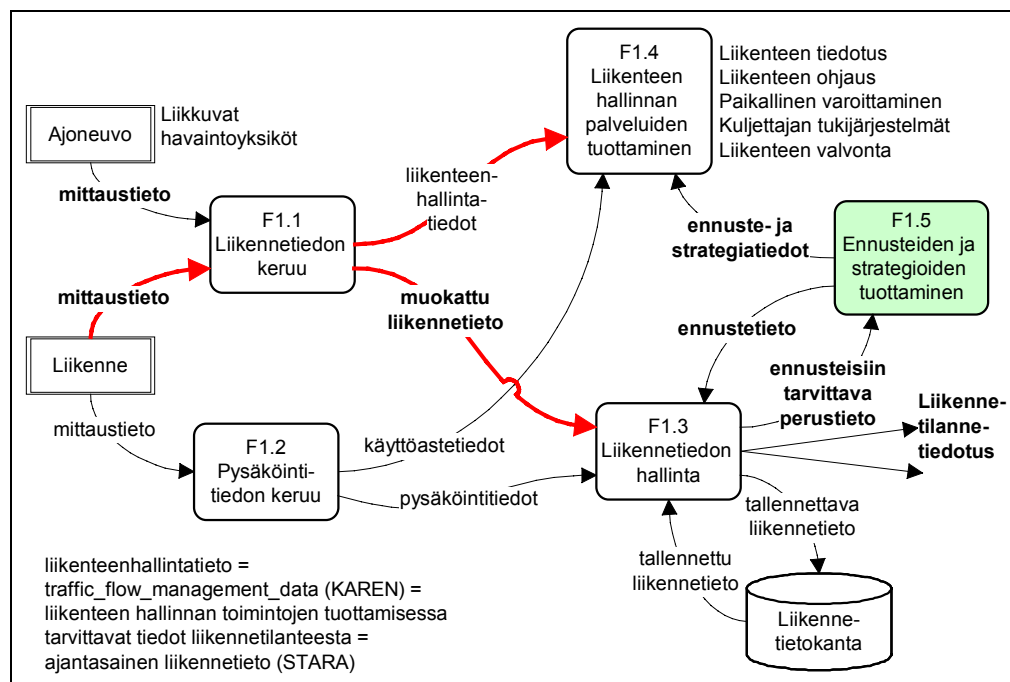
4.1 Ennusteiden tarve liikenteen hallinnan eri palveluissa

Tiehallinnon tärkeimmät liikenteen hallinnan toiminnot ovat tiedotus, ohjaus ja häiriön hallinta (Tiehallinto 2001b). Tärkeimpiin Tiehallinnolle asetettuihin liikenteen hallinnan päämääriin kuuluvat mm:

- Liikenneturvallisuuden parantaminen
- Matkustamisen ja kuljetusten varmuuden ja sujuvuuden turvaaminen
- Matkustus- ja kuljetuskysynnän mahdollisimman tehokas hoitaminen
- Infrastruktuurin mahdollisimman tehokas käyttö
- Liikennemuotojen yhteistoiminnan parantaminen
- Kansalaisten liikkumismahdollisuuksien turvaaminen
- Liikenteen ympäristöhaittojen vähentäminen
- Tietoyhteiskunnan edistäminen

Useimpien yllä mainittujen päämäärien voidaan katsoa hyötyvän lyhyen ajan liikenne-ennusteista. Saadessaan informaatiota liikenteen sujuvuuden ennakkoidusta kehitymisestä lähitunteina, tienkäyttäjä voi mahdollisuuksiensa mukaan suunnitella reittinsä ja matkustusajankohtansa siten, että välttyisi ruuhkassa liikkumiselta. Matkustaminen tulee sujuvammaksi ja miellyttävämmäksi ja ajan käyttö tehostuu. Liikenne jakautuu tasaisemmin tieverkolle ja ruuhkahuiput tasoittuvat. Tämä tehostaa infrastruktuurin käyttöä ja vähentää liikenteen ympäristöhaittoja. Lyhyen ajan liikenne-ennusteet hyödyttävät sekä yksilöä että yhteiskuntaa.

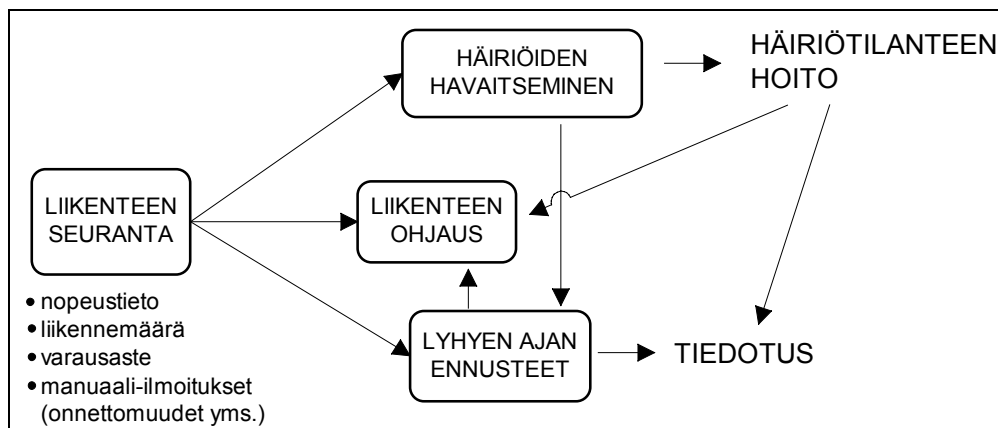
Kuvassa 2 on eurooppalaisen ITS -puitearkkitehtuurin (KAREN, European ITS Framework Architecture) pohjalta esitetty, miten liikenne-ennusteet ovat osa liikenteen hallinnan toimintoja.



Kuva 2. Liikenne-ennusteet osana liikenteen hallinnan toimintoja KAREN-arkkitehtuurin mukaan. Ennustamiseen liittyvät tietovirrat on merkitty lihavoituna.

Liikennetiedotus ei ole ainoa liikenteen hallinnan toiminto, joka tarvitsee lyhyen ajan ennusteita. Lyhyen ajan ennusteita voidaan hyödyntää automaattisissa liikenteen hallintajärjestelmissä kuten muuttuvassa liikenteen ohjauksessa ja opastuksessa sekä ruuhkavarointusjärjestelmissä. Liikenteen alueellinen hallinta, jossa liikennettä ohjataan koko verkon kannalta optimaalisesti, voi vaatia myös liikennekeskuksen päivystäjän manuaalisia ohjaustoimia, joiden valinnassa päivystäjä voi hyödyntää lyhyen ajan ennusteita.

Myös häiriöiden hallinnassa voidaan hyödyntää lyhyen ajan liikenne-ennusteita. Häiriöiden hallinta muodostuu liikenteen tiedotuksesta ja ohjauksesta sekä eri tekijöiden välisestä yhteistyöstä häiriön havaitsemiseksi ja hoitamiseksi. Osana häiriöiden hallintaa on tiedotus häiriön luonteesta ja sen kestosta. Tässä voidaan hyödyntää lyhyen ajan ennusteita ennustamalla häiriöstä aiheutuneen ruuhkan vaikutus (esim. jonot) ja kesto. Lyhyen ajan ennusteiden käyttöä häiriöiden hoidossa havainnollistaa kuva 3.



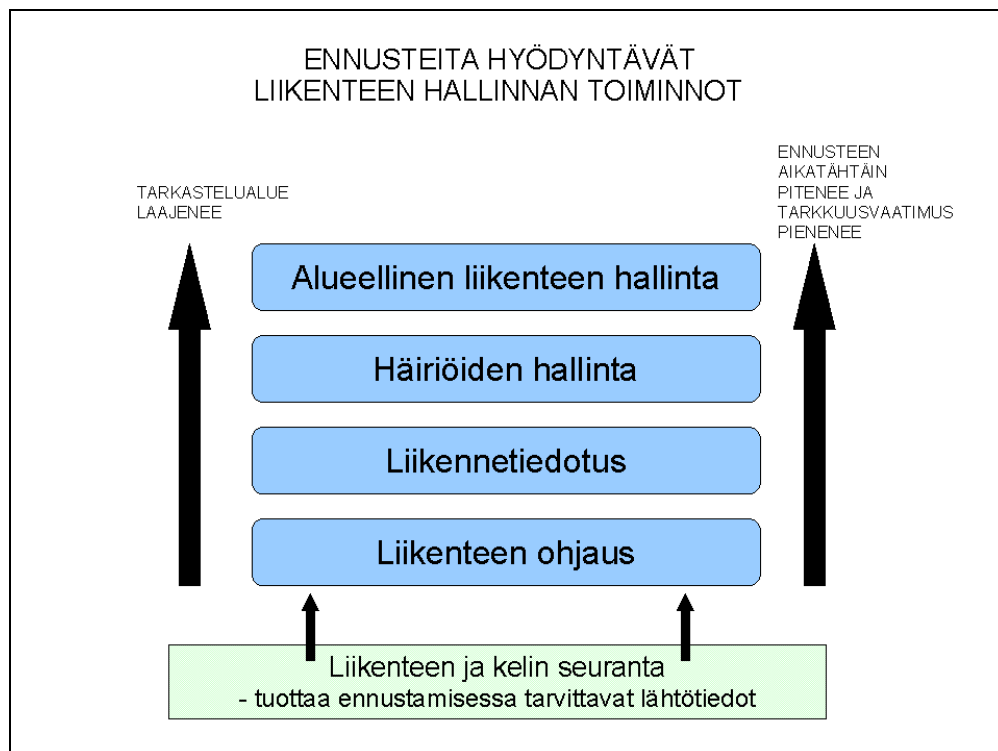
Kuva 3. Lyhyen ajan ennusteiden hyödyntäminen häiriötilanteiden hoitamisessa

Suuresta kuormitusasteesta johtuvan ruuhkan ennakoiminen edellyttää liikennevirran sujuvuutta kuvaavien liikennetietojen (nopeus, liikennemäärä jne.) keruuta. Liikennevirta käyttäytyy ruuhkatilanteissa eri tavalla kuin normaaleissa olosuhteissa. Sujuvuuden heikkeneminen taas ennakoi ruuhkan syntymistä. Automaattisten ruuhkavaroitus- ja muiden automaattisten liikenteen ohjauksjärjestelmien keräämää tietoa liikennevirran käyttäytymisestä voidaan hyödyntää lyhyen ajan liikenne-ennusteiden tekemisessä.

Liikennetiedotuspalvelussa tarvitaan ensisijaisesti tietoa nopeuden ennustetusta kehityksestä. Keskinopeuden perusteella määritetään liikennetilanneluokka (liikenne sujuvaa, jonoutunutta, hidasta, pysähtelee tai seisoo) (Tiehallinto 2001a), joka esitetään tienkäyttäjille esimerkiksi värikoodattuna karttana. Liikennetilanneluokituksista saatetaan kehittää siten, että siinä otetaan nopeuden lisäksi huomioon myös liikennemäärä, jolloin liikennemääräennusteiden merkitys kasvaa. Linkki- tai väyläkohtainen ennustettu matka-aikatieta on myös hyödyllistä autoilijalle, joka voi valita kahden tai useamman reitin välillä. Liikennetiedotuksen kannalta on tärkeää, että malli osaisi tunnistaa erityisesti tilanteet, joissa ruuhka on syntymässä ja vastaavasti purkautumassa. Liikenteestä mitattavissa suureissa saattaa olla satunnaista vaihtelua, joka mallin tulisi osata erottaa todellisesta liikennetilanteen muuttumisesta.

Häiriöiden hallinnan ja liikenteen ohjauksen kannalta tärkeimpiä ennustesuu-reita ovat liikennemäärä ja liikennevirran keskinopeus. Automaattisissa liikenteen ohjauksjärjestelmissä (esim. liikennevalot) ohjelmanvalinta perustuu yleensä liikennemäärään. Nykyisin ohjelman valinta tapahtuu pääsääntöisesti kellonajan perusteella tai tietyn mittausjakson (yleensä 5...15 min) toteutuneeseen liikennemäärään eli historiatietoon perustuen. Liikennemääräennusteen avulla voitaisiin ohjelman vaihto ajoittaa mahdollisimman oikea-aikaisesti. Häiriöiden hallintaan kuuluu usein liikenteen ohjaaminen vaihtoehtoiselle reitille esim. onnettomuuden tai tietyön takia. Lyhyen ajan liikennemääräennustetta voidaan käyttää vaihtoehtoisten reittien suunnitteluun tarkastelemalla reittien kuormitusta häiriön takia lisääntyneellä liikennemäärällä.

Kuvassa 4 on esitetty ennusteita hyödyntävät liikenteen hallinnan toiminnot. Eri toiminnoilla on erilaiset aikajänteet. Liikenteen ohjaus, joka keskittyy usein vain yhteen väylään tai liittymään, tarvitsee nopeasti tuotettuja ja tarkkoja sekä paikallisia ennusteita. Liikennetiedotuksessa aikatähtäin on hieman pidempi ja tarkastelualue laajempi. Häiriöiden hallinnassa ja alueellisessa liikenteen hallinnassa tarkastellaan vielä suurempia kokonaisuuksia kuin liikenteen ohjauksessa ja liikennetiedotuksessa.



Kuva 4. Lyhyen ajan ennusteita hyödyntävät liikenteen hallinnan toiminnot.

4.2 Vaatimukset liikenteen seurannalle

Liikenteen hallinnan toiminnot vaativat liikenteen ajantasaista seuranta. Liikenteen hallinnan palvelut tarvitsevat tietoa sekä pysyvistä että muuttuvista seikoista tieliikennejärjestelmässä. Erytisen tärkeitä ovat ajantasaiset tiedot liikenteestä ja häiriötilanteista kuten onnettomuuksista ja tietöistä. Myös säästä, kelistä ja kunnossapidon tilanteesta tarvitaan ajantasaista tietoa. Eri liikenteen hallinnan toiminnot tarvitsevat osittain erilaisia lähtötietoja. (Tiehallinto 2001b)

Liikenteen seuranta voidaan jakaa automaattiseen ja manuaaliseen seurantaan. Automaattinen seuranta tapahtuu erilaisilla kiinteillä mittauslaitteilla tai liikkuvilla antureilla. Manuaaliseuranta taas tarkoittaa erilaisia ihmisten liikenteestä tekemiä havaintoja. (Tiehallinto 2001a)

Liikenteen historia- ja tilastotietoja tarvitaan mm. liikenteen yleisen kehityksen seuraamiseen ja pitkän aikavälin ennusteiden laatimiseen. Tiedot kerätään Tiehallinnon LAM-järjestelmällä (liikenteen automaattinen mittausjär-

jestelmä) ja muilla Tiehallinnon vuosittain tekemillä liikennelaskennoilla. Lisäksi erilaiset liikenteen ohjaus- ja valvontajärjestelmät keräävät omiin tietokantoihinsa tilastotietoja. (Tiehallinto 2001a)

Historia- ja tilastotietoja käytetään useissa menetelmissä lyhyen ajan ennusteiden laatimiseen. Tilastolliset menetelmät tarvitsevat tilastotietoa lähtötiedokseen. Tilastotieto voidaan luokitella päivätyypin (arki, lauantai, pyhä) ja vuodenajan mukaan, mutta yhdeksi luokittelevaksi tekijäksi voidaan ottaa myös sää ja keli. Erilaiset vuosittain toistuvat paljon yleisöä keräävät tapahtumat tulee myös huomioida. Myös mm. neuroverkkomenetelmissä tarvitaan tilannekirjaston tietoja verkon opetukseen.

Ajantasaista liikennetietoa tarvitaan päivittäisessä liikenteen hallinnassa kuten valo-ohjauksen toiminnan säätelyssä ja liikennetilannetiedottamisessa. Ajantasainen liikenteen seuranta edellyttää, että kerätyt liikennetiedot ovat hyödynnettävissä muutaman minuutin viipeellä. LAM-järjestelmän ja liikenteen ohjaus- ja valvontajärjestelmien keräämää tietoa voidaan hyödyntää myös ajantasaisen liikennetiedon keruussa. (Tiehallinto 2001a)

Lyhyen ajan ennustemenetelmät tarvitsevat paljon ajantasaista liikennetietoa. Ennusteissa tarvitaan useimmiten tietoja liikennemäärästä, ajoneuvojen nopeudesta sekä ilmaisimen varausasteesta.

Liikenteen sujuvuustietoa voidaan saada sekä piste- että linkkimittauksesta. Pistemittauksessa liikenteen sujuvuus määritetään yhdessä tai useammassa seurantalinkin pisteessä kerättyjen tunnuslukujen avulla. Pistemittauksen tuottamien tietojen oletetaan kuvaavan koko linkin tilaa, jolloin virhepäätelmien riski on olemassa. (Tiehallinto 2001a) Luotettavuutta voidaan parantaa lyhentämällä mittauspisteiden välimatkaa. Pistemittauksissa tiedot kerätään nykyisin pääasiassa induktiosilmukoilla. Lyhyen ajan ennusteet saattavat edellyttää enemmän mittauspisteitä kuin pelkkä nykytilanteen seuranta.

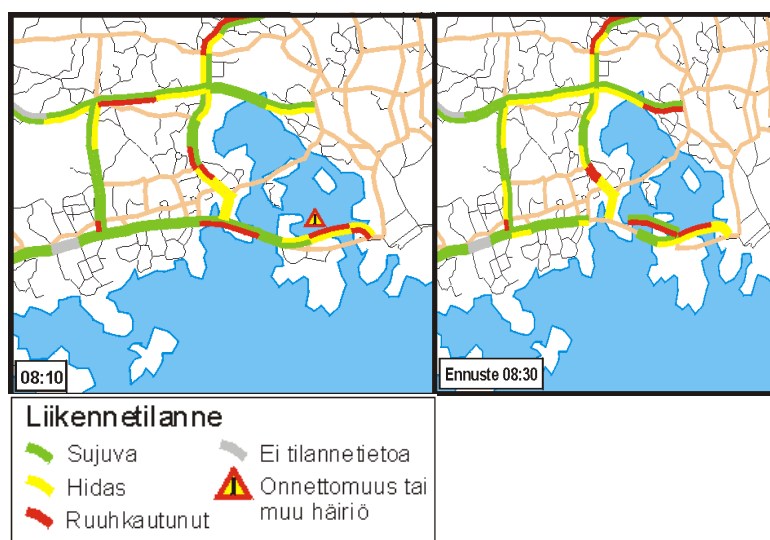
Linkkimittauksissa tunnistetaan yksittäisiä ajoneuvoja tai niiden ominaisuuksia seurantalinkin päissä ja linkin keskinopeus lasketaan näistä tiedoista. Liikenteen seuranta tapahtuu automaattisen ajoneuvon tunnistamisen kuten rekisterikilpien tunnistamisen avulla. Seurantalinkin keskinopeustieto reagoi muutoksiin tasaisemmin kuin pistetieto. Tämän voidaan olettaa helpottavan sujuvuuden lyhyen aikavälin ennustettavuutta. Ongelmia tuottaa kuitenkin se, että mitä enemmän matkanopeus laskee tai mitä pidempi seurantalinkki on, sitä enemmän matka-aikatie viivästyy. (Tiehallinto 2001a)

Muita liikenteen seurantaan käytettäviä menetelmiä, joiden keräämiä tietoja voitaisiin käyttää lyhyen ajan ennusteiden tekoon, ovat mm. videokamerat, infrapunailmaisimet, tutkailmaisimet, GSM-paikannus ja anturiajoneuvot. (Tiehallinto 2001a)

4.3 Tienkäyttäjän tarpeet

Sujuvuustiedottamisessa tulee erityisesti huomioida tienkäyttäjän tarpeet ja sopiva tiedon esitysmuoto. Suurimmat vaikutukset liikenteen sujuvuuteen saadaan aikaan, kun autoilija saa informaation mahdollisimman aikaisessa vaiheessa, jolloin matkan ajankohtaa voi vielä muuttaa. Häiriötilanteessa on

lisäksi tärkeää, että tienkäyttäjä saa tiedon häiriöstä sekä sen havaituista ja odotettavissa olevista vaikutuksista mahdollisimman pian häiriön havaitsemisen jälkeen. Liikenteen sujuvuuden ennakoitu kehittyminen on mahdollista esittää nykytilanteen rinnalla esim. internetissä värikoodattuna karttana. Tästä on esimerkki kuvassa 5. Värikoodatulla kartalla liikennetilanneluokka esitetään linkeittäin ja ajosuunnittain eri väreillä. Liikennetilanneluokitus perustuu liikennevirran keskinopeuden ja vapaan virran keskinopeuden suhteeseen (Liikenteen seurannan valtakunnallinen esiselvitys Tiehallinto 2001a). Autoilijoille voitaisiin myös kertoa liikennetilanteesta tarkemmin ilmoittamalla kunkin linkin keskinopeus ja/tai matka-aika. Liikennetilanneluokka hyödyttää etenkin autoilijoita, jotka eivät tunne seutua eivätkä osaa arvioida tieosien normaalia matka-aikaa. Seudulla päivittäin liikkuvat autoilijat saattaisivat myös kokea keskinopeus- ja matka-aikatiedotuksen hyödyllisenä.



Kuva 5. Värikoodattu kartta nykyhetken liikennetilanteesta (vas.) ja ennustetusta liikennetilanteesta (oik.).

Internetissä esitetty informaatio on käytettävissä matkaa suunniteltaessa ja sen ajoituksesta päätettäessä. Liikennetilanne saattaa muuttua nopeasti, joten myös matkalla oleva autoilija tarvitsee ajantasaista tietoa liikenteen sujuvuudesta, voidakseen vaihtaa reittiään ja välttää näin ruuhkan. Matkalla olevalle autoilijalle informaatiota voidaan jakaa radion välityksellä, muuttuvilla tiedotustauluilla tai henkilökohtaisesti esim. kännykän avulla. Matkan aikana annetun informaation on oltava yksinkertaista ja selkeää, jotta autoilijan on helppo tehdä päätös mahdollisesta reitin vaihtamisesta. Autoilijalle voidaan myös antaa suosituksia reitinvalinnasta. Informaatiosta on eniten hyötyä, kun se annetaan riittävän ajoissa, jolloin autoilija voi vielä vaihtaa reittiään ja välttää ruuhkan (Lind 2000).

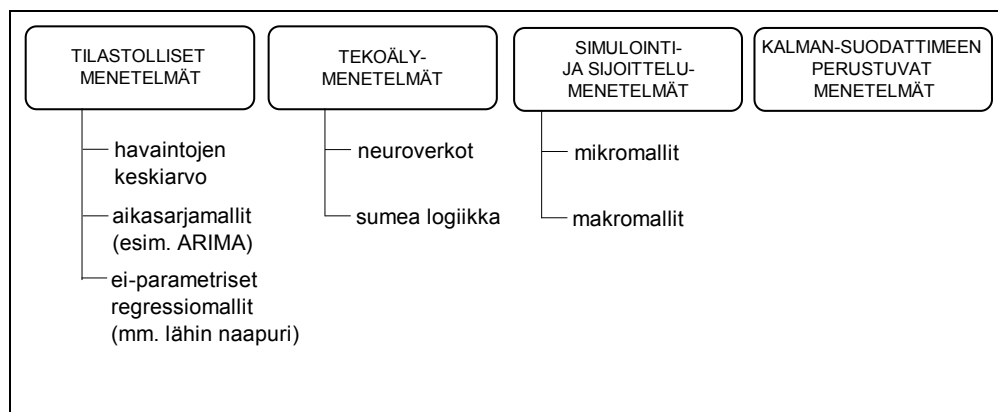
Erittäin tärkeää on, että annettu informaatio on luotettavaa. Tämä on tärkeää heti kun palvelu otetaan käyttöön. Jos autoilija kokee saavansa virheellistä informaatiota, hänen luottamuksensa järjestelmään heikkenee oleellisesti. Voidaan kuitenkin olettaa, että aliarvoitu matka-aika on tienkäyttäjän kannalta haitallisempaa kuin hieman yliarvoitu matka-aika. Autoilija ärsyyntyy ruuhkasta vielä enemmän, jos hän on saanut virheellistä informaatiota, jonka

mukaan liikennetilanne olisi todellisuutta sujuvampi. Tielaitoksen Ruuhkaisuuden kokeminen ja liikennetilannetiedottaminen –tutkimuksessa (1996) puolet kuljettajista koki ajomukavuuden vähentyneen, kun liikenteen keskinopeus oli pienentynyt noin 8 %. Yksilön kokeman haitan lisäksi virheellinen informaatio aiheuttaa myös yhteiskuntataloudellisia kustannuksia, jos autoilija valitsee hitaamman ja ruuhkaantuneemman reitin. Tiehallinnon korkeimman laatutason mukaan ennustetuissa matka-ajoissa hyväksytään 10% virhemarginaali. Matalimmalla laatutasolla virhemarginaali on 20% (Tiehallinto 2001 b).

5. ENNUSTEMALLIEN LUOKITTELU

5.1 Menetelmien jaottelu

Ennustemallit voidaan jakaa historiadataa ja tilastoja käyttäviin malleihin, tekoälymalleihin, simulointi- ja sijoittelumalleihin ja Kalman-suodattimeen perustuviin malleihin (Innamaa 2001). Ennustemenetelmät on esitetty kuvassa 6. Jako ei kuitenkaan ole yksiselitteinen ja useat mallinnusmenetelmät yhdistelevät eri menetelmiä. Tästä esimerkkinä voidaan mainita mallit, jotka etsivät historiadatasta eli tilannekirjastosta samankaltaisia liikennetilanteita SOM-neuroverkon (self-organizing map, itseorganisoiva kartta) avulla. Joitakin menetelmiä ei voida luokitella kuuluvaksi mihinkään näistä menetelmätyypeistä.



Kuva 6. Ennustemenetelmien luokittelu.

5.2 Tilastolliset menetelmät

Historiatietoa käyttävät mallit perustuvat tilastoituihin liikenteen kausi-, viikko- ja tuntivaihteluihin.

Tietokannan havaintojen keskiarvoon perustuva malli käyttää yksinkertaisesti aikaisempien liikennemäärien keskiarvoa lähitulevaisuuden liikenteen ennustamiseen. Haluttaessa ennustaa liikennemäärää ajan D kuluttua, ennusteen $Q(t+D)$ hetkellä t estimoidaan siis olevan yksinkertaisesti $Q_{\text{hist}}(t+D)$. Tilastoidut liikennetilanteet voidaan ryhmitellä esim. viikonpäivän tai sään ja kelin mukaan, jolloin esim. sateisen maanantain ennusteeseen huomioidaan edellisten sateisten maanantaiden toteutunut liikenne. Menetelmä on helppo ottaa käyttöön ja ennuste voidaan laskea nopeasti. Koska malli perustuu tilastoituihin liikenteen vaihteluihin, se ei kykene vastaamaan keskimääräisestä poikkeaviin tilanteisiin. (Innamaa 1999)

Tilastolliset aikasarjamallit, kuten autoregressiiviset integroidut liukuvan keskiarvon mallit (ARIMA-mallit), perustuvat matemaattiseen malliin, jonka

avulla pyritään selittämään aikasarjadataan aikaisempaa käyttäytymistä ja ennustamaan liikennettä sen perusteella. ARIMA perustuu keskeytymättömään datasarjaan, jonka saaminen on kuitenkin usein hankalaa. Tästä syystä aikasarjamalli ei sovellu kovin hyvin laajamittaisiin sovelluksiin. (Innanaa 1999) Aikasarjamalleja käytettäessä on tärkeää tunnistaa eri tyyppiset vaihtelut aikasarjassa. Näitä vaihteluja ovat satunnaisvaihtelu, jaksollinen vaihtelu ja trendit (Sundberg ym. 2000). On tärkeää, että malli erottaa satunnaisvaihtelun todellisesta liikennetilanteen muuttumisesta. Jos eri liikennevirroilla on erilaiset selittävät tekijät, voidaan kullekin kehittää oma aikasarjamallinsa ja yhdistää näiden tulos (Sundberg ym. 2000).

Ei-parametrisessa regressiomallissa yritetään etsiä tilannekirjastosta aikaisempien havaintojen joukkoja, jotka ovat vastaavanlaisessa tilassa kuin järjestelmä ennustehetkellä. Ei-parametrisistä regressiomenetelmistä ennustamisessa on usein käytetty **lähin naapuri** –menetelmää. Menetelmässä naapurit on määritelty niinä k:nä havaintona, jotka muistuttavat eniten järjestelmää ennustehetkellä. Halutun tilanteen estimaatti määritellään laskeamalla naapureista keskiarvo. Menetelmän hyvänä puolena on se, että se ei tarvitse ennako-oletuksia olemassa olevista riippuvuussuhteista. Naapureiden löytäminen voi kuitenkin olla hankalaa. Lähin naapuri -menetelmä sopii kohteisiin, joissa liikennetilanne voidaan kuvata yhdellä muuttujalla, jonka perusteella naapurit valitaan. Jos muuttujia tarvitaan enemmän, tilannekirjastossa olevien havaintojen luokitteluun ja naapureiden löytämiseen soveltuu paremmin itseorganisoituva kartta (self-organizing map) eli SOM-neuroverkko. (Innanaa 1999)

5.3 Tekoälymenetelmät

Tekoälymenetelmiä ovat erilaiset neuroverkkomallit ja sumeaa logiikkaa käyttävät menetelmät.

5.3.1 Neuroverkot

Neuroverkkojen ideana on jäljitellä ihmisen oppimis- ja päättelyprosessia matemaattisesti (Hintikka, Göös). Neuroverkoilla yritetään mallintaa biologisia neuroneja ja näiden välisiä yhteyksiä (Sundberg ym. 2000). Neuroverkko koostuu joukosta ”keinotekoisia hermosoluja” eli solmuja, jotka on liitetty toisiinsa. Tietojen käsittely tapahtuu solmuja toisiinsa yhdistävien liitosten välityksellä. Neuroverkolle opetetaan asioita syöttämällä sille esimerkkejä analysoitavista tilanteista. Neuroverkko oppii siis esimerkeistä yleistämällä, siihen ei suoraan ohjelmoida tiettyjä syötteitä vastaavuuksineen. Oppiminen tapahtuu solmujen välillä sijaisevien liitosten voimakkuuksissa tapahtuvina muutoksina. Tapa, jolla nämä muutokset tapahtuvat on ohjelmoitu. (Honkela) Opettaminen tulee lopettaa ajoissa, ettei ylioppimista tapahdu, sillä verkon tulee osata yleistää muuttujien väliset riippuvuudet (Innanaa 1999).

Neuroverkko on osoittautunut tehokkaaksi menetelmäksi monimutkaisten epälineaaristen riippuvaisuuksien esittämiseen (Innanaa 1999). Neuroverkot sopivat sellaisten ilmiöiden mallintamiseen, jotka ovat moniulotteisia, kokonaisvaltaisia ja jatkuvia (Honkela). Niillä on hyvä virheensietokyky eivätkä ne ole herkkiä lähdetietojen epämääräisyydelle (Juutilainen). Neuroverkkojen

opetusprosessi on monimutkainen, mutta opetuksen jälkeen ne ovat käytössä yksinkertaisia. Monimutkainen neuroverkko vaatii myös kohtuullisen paljon laskentatehoa opetusvaiheessa. Neuroverkkoa on opetettava riittävästi ja sen testaamiseen sekä validointiin tulee kiinnittää huomiota. Siirrettäessä verkkoa alkuperäisestä paikasta toiseen, on se opetettava uudelleen, jotta se oppisi uuden ongelman erityispiirteet. (Innamaa, Pursula 2000)

Lyhyen ajan ennustamisessa käytetään ennusteen syötetietoina esim. matka-aikaa ajoneuvon lähtöhetkellä ja tiejaksolla olevien ajoneuvojen lukumäärää. Opetusjoukon tulee olla riittävän laaja ja ruuhkatilanteiden ennakoimiseksi verkkoa täytyy opettaa riittävän laajalla ruuhka-ajan aineistolla. Yleisimmin liikennetekniikassa käytettyä neuroverkkoa opetetaan vastavirta-algoritmeilla. (Innamaa 1999)

5.3.2 Sumea logiikka

Sumea logiikka mallintaa ihmisen ajattelun ja toiminnan epävarmuutta ja epätasällisyyttä (Tekes). Sumean logiikan mukaan kaikki tilanteet eivät ole mustavalkoisia joko tai –tilanteita (Pesonen). Sumeassa joukko-opissa erilaisten tilanteiden on mahdollista kuulua tiettyyn joukkoon vain osittain ja useampaan joukkoon yhtä aikaa. Perinteisesti ajatellenhan tilanne joko kuuluu johonkin luokkaan tai sitten ei. Jäsenyysaste kuvaa sitä, kuinka paljon jokin tilanne kuuluu johonkin tiettyyn luokkaan. Jäsenyysaste voi saada esimerkiksi arvoja 0...1. Jäsenyysaste 0 vastaa täyttä joukkoon kuulumattomuutta ja 1 täydellistä kuulumista. Jäsenyysaste tältä väliltä tarkoittaa, että tilanne kuuluu joukkoon osittain. (Hintikka, Göös) Sumeaa logiikka voi verrata todennäköisyyslaskentaan, jossa jonkin tapahtuman todennäköisyys on myös välillä 0...1. Sumean logiikan hyviä puolia ovat vaihtelevan toiminnan mallintaminen ja hyvä häiriön sietokyky. Ongelmana on oikean sääntöjoukon löytäminen ja testaaminen. (Pesonen) Sumeaa logiikkaa käytetään usein neuroverkkojen yhteydessä.

5.4 Simulointi- ja sijoittelumallit

Simulointimallit jaetaan mikroskooppisiin ja makroskooppisiin simulointimalleihin.

5.4.1 Mikrosimulointi

Mikrosimuloinnissa mallinnetaan yksittäisiä ajoneuvoja ja näiden toimintoja tieverkolla. Jokaisella ajoneuvolla on yksilölliset ominaisuudet ja reitti verkolla. Tämän takia mikrosimulointimalleilla voidaan hyvin arvioida lyhytaikaisten liikenteen hallinnan toimintojen (esim. valo-ohjauksen säädöt) vaikutuksia liikenteen sujuvuuteen. Haittapuolena on, että mikrosimulointimallit vaativat paljon tietoa ja tietokonekapasiteettia. Mikrosimulointiin perustuvia malleja ei olekaan maailmalla laajamittaisessa käytössä. (Milne 2001) Teknillisessä korkeakoulussa on kehitteillä mikrosimulointiin perustuva sovellus (DigiTraffic), jonka periaatteena on luoda ajantasaisia ja ennustavia koko-

naismalleja liikenneolosuhteista perustuen saatavilla olevaan ajantasaiseen mittaustietoon.

5.4.2 Makrosimulointi

Makroskooppisessa simuloinnissa liikennettä mallinnetaan yhtenä kokonaisuutena makroskooppisten ominaisuuksien kuten liikennemäärän ja –tiheyden sekä nopeuden avulla. Nämä mallit ovat luonteeltaan staattisia ja siksi niiden käyttäminen lyhyen ajan ennustuksissa sisältää paljon rajoituksia. (Milne 2001)

Sijoittelua voidaan käyttää osana makroskooppisia simulointimalleja liikennemäärien määrittämiseen. Sijoittelu- ja simulointimallit vaativat dynaamisen lähtöpaikka-määräpaikka- eli OD-matriisin lähtötiedoikseen. Lisäksi mallit tarvitsevat tietoa liikenneverkon rakenteesta, liikennevaloista ym. Ennuste-prosessi on iteratiivinen. Simulointivaiheen tavoitteena on tuottaa tietoa linkkien matka-ajoista kulloisellakin liikenteellä. Sijoitteluvaiheen tavoitteena taas on sijoitella matkat liikenneverkolle. Sijoittelu- ja simulointimalli on isoilla verkoilla hidas ja raskas ja vaatii paljon laskentatehoa. (Innamaa, Pursula 2000). Tämän takia sijoittelu- ja simulointimallit eivät kovin hyvin sovellu dynaamisen liikenteenohjauksen tarpeisiin. Liikennetiedotuspalvelussa aikatahtain on kuitenkin ohjausta pidempi eikä ennusteen tarvitse syntyä yhtä nopeasti. Sijoittelu- ja simulointimalli sopii käytettäväksi silloin, kun verkkonäkökulma on tärkeä ja kuljettajan reitinvalinnalla on suuri merkitys (Innamaa, Pursula 2000). Nämä asiat korostuvat etenkin liikenteen ennustamisessa ja tiedotuksessa kaupunkialuilla, joilla on useita eri reittivaihtoehtoja.

5.5 Kalman-suodattimeen perustuvat mallit

Kalman suodatus on rekursiivinen menetelmä, joka estimoii dynaamisen systeemin hetkellisen tilan satunnaisia virheitä (valkoista kohinaa) sisältävien mittausten perusteella (Schulz, Werwats 2001). Kalman suodattimen perusajatus on se, että haluttujen muuttujien arvot ennustetaan aiempaan informaatioon perustuen siihen hetkeen asti, kunnes uusi mittaustulos on käytössä. Kun uusi mittaustulos saadaan käyttöön, muuttujien estimaattia korjataan mittauksen ja ennusteen väliseen erotukseen verrannollisena. (Karvonen ym. 1982) Kalman suodatinta voidaan pitää klassisen pienimmän neliösumman laajenuksena (Holma 1991). Kalman suodatin suodattaa liikennemittauksen reaaliajassa, on joustava, kalibroii itse itsensä, siinä ei ole stationaarisuusoletuksia ja se pitää sisällään häiriöiden havainnoinnin (Innamaa 1999).

6. TUTKIMUSTULOSTEN ANALYSOINTI

6.1 Yleistilanne

Menetelmiä ja malleja lyhyen ajan liikenne-ennusteiden tekemiseen on tutkittu ja kehitelty maailmalla jo useita vuosia. Aihe kiinnostaa tutkijoita ja erilaisia ennustemenetelmiä on paljon kehitteillä ja tutkimustyötä aiheen ympärillä tehdään. Toteutettuja ja liikennetiedotuskäyttöön vietyjä palveluja ei ole kuitenkaan tässä selvitystyössä löytynyt. Alalla ei tunnu olevan tiettyä selkeää kehityssuuntaa, vaan eri tutkijat ovat keskittyneet erilaisiin ennustemenetelmiin. Ehkä yleisimpiä tutkimuksen kohteena olevia menetelmiä ovat kuitenkin neuroverkkomenetelmät ja erilaiset historiatietoa käyttävät menetelmät. Tutkimusta tehdään erityisesti Keski-Euroopassa (mm. Saksa, Hollanti), USA:ssa, Australiassa ja Japanissa sekä Koreassa. Suomessa on viime vuosina tutkittu lyhyen ajan liikenne-ennusteiden tekemistä neuroverkkojen avulla.

Vaikka todellisessa tiedotuspalvelukäytössä olevia järjestelmiä ei löytynytkään, on lähes kaikkia tässä selvityksessä läpikäytyjä ennustemenetelmiä testattu oikealla liikennetiedolla. Testialueiden koko ja testausaika vaihtelivat suuresti (muutamasta tunnista useisiin kuukausiin). Joissakin tapauksissa testaaminen on tehty jollakin simulointiohjelmalla. Useimmat menetelmät sopivat moottoriteliikenteen ennustamiseen, verkkonäkökulma on mukana harvemmin. Useimmiten menetelmissä ennustetaan linkkien matka-aikaa, keskinopeutta ja/tai liikennemäärää. Suurimmat haasteet malleissa liittyvät ruuhkaliikenteen ennustamiseen ja etenkin ruuhkan alkamisen ja purkautumisen havaitsemiseen. Ruuhkattomassa tilanteessa ennustaminen on helppoa. Tienkäyttäjän ja tiedotuspalvelun kannalta juuri ruuhkatilanteiden ja liikenneolojen muutoskohtien havaitseminen olisi erityisen tärkeää.

6.2 Mallien tarvitsemat lähtötiedot

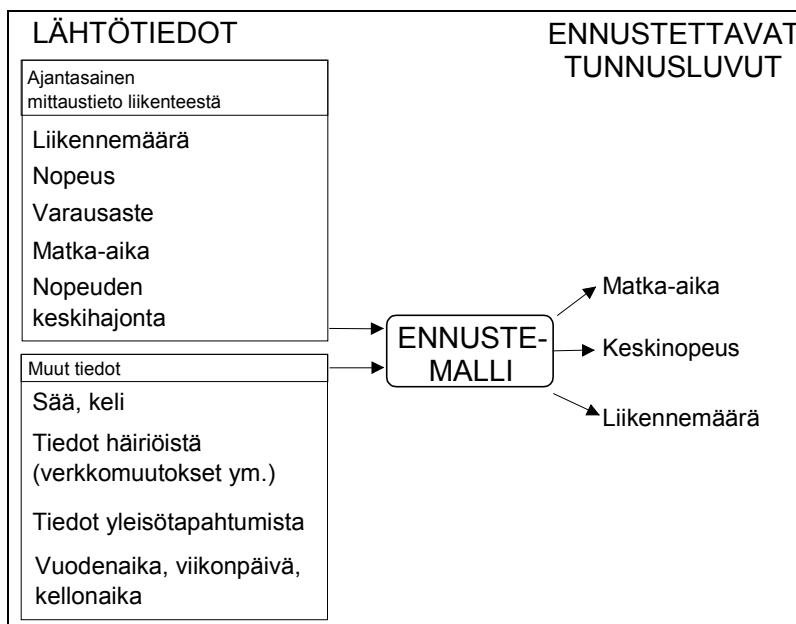
Erilaiset lyhyen ajan ennustemenetelmät tarvitsevat osittain erilaisia lähtötietoja. Useimmiten menetelmät käyttävät lähtötietoinaan kuitenkin liikennemäärää, keskinopeutta ja varausastetta. Useimmissa lähteissä ajantasaisen liikennetiedon keräämiseen on käytetty induktiosilmukoita. Muita menetelmiä olivat mm. automaattinen ajoneuvontunnistus ja anturiajoneuvot.

Taulukkoon 1 on koottu läpikäytyjen kirjallisuuslähteiden perusteella eri ennustemenetelmien yleisesti tarvitsemia lähtötietoja. Taulukossa on ++ -merkinnällä osoitettu useimmiten käytetyt lähtötiedot, ja + -merkinnällä harvemmin käytetyt.

Taulukko 1. Erilaisten ennustemenetelmien tarvitsemia lähtötietoja. ++ tarkoittaa useimpien lähteiden käyttämää lähtötietoa ja + joidenkin lähteiden käyttämää lähtötietoa.

ENNUSTEMENETELMÄ	LÄHTÖTIETO								
	Liikenne-määrä	No-peus	Varau-saste	Mat-ka-aika	Nopeu-den keski-ha-jonta	Histo-ria-tieto liikenteestä	OD-mat-riisi	Sää, keli	Tietoa liikenne-verkosta
Tilastolliset menetelmät	++	++	+	+		++		+	
Tekoälymenetelmät	++	++	+	++	+				
Simulointi- ja sijoittelumallit	++	++					++		++
Kalman-suodatus	++	++	++						

Taulukossa 1 esitettyjen lähtötietojen lisäksi on myös muita tietoja, joista voisi olla hyötyä lyhyen ajan ennusteiden laatimiseen. Sää- ja kelitiedot eivät ole kovin yleisesti käytettyjä lähtötietoja, mutta etenkin Suomessa niillä on suuri merkitys liikenteen sujuvuuteen. Useat kehitetyt ennustemenetelmät hyödyntävät vain ajantasaisista mittaustietoa liikenteestä, vaikka tiedot erilaisista yleisötapahtumista tai häiriöistä liikenneverkolla voisivat parantaa liikenne-ennustetta. Kuvassa 7 on esitetty eräänlainen ”ideaalimalli”, joka ottaisi huomioon ajantasaisen mittaustiedon lisäksi muita liikenteeseen vaikuttavia tekijöitä.



Kuva 7. Periaatekuva ideaalisesta ennustemallista. Ideaalisen ennustemallin tulisi huomioida liikenteestä tehtyjen mittausten lisäksi myös erilaisten häiriöiden ja tapahtumien vaikutukset liikenteen käyttäytymiseen. (Sundberg ym. 2000)

6.3 Ennusteiden arviointi

Eri ennustemenetelmiä on vaikea laittaa paremmuusjärjestykseen. Ennusteen onnistuminen riippuu paljolti kohteesta (kuinka paljon ruuhkaa on, onko se toistuvaa jne.) ja ajankohdasta, jolloin mallia on käytetty. Toiset mallit sopivat paremmin toisiin kohteisiin ja mallien vertailu tulisikin suorittaa miettimällä kohteen erityispiirteitä. Ennustevirheet voivat myös vaikuttaa hyvin erilaisilta eri virheen tunnusluvuilla ilmaistuna. Mallit voivat asettua hyvin erilaiseen paremmuusjärjestykseen, jos tarkasteltua tunnuslukua vaihdetaan. Tätä selvitystä varten läpikäydyissä lähteissä on tuloksista kerrottu hyvin eri tavalla. Useimmiten käytettyjä virheen tunnuslukuja ovat MSE (keskineliövirhe), RMSE (keskineliövirheen neliöjuuri), keskivirhe (mean error), virheellisten osuus (error rate), MAPE (keskimääräisen suhteellisen virheen itseisarvo, mean absolut percent error), selitysaste ja korrelaatiokerroin. Määritelmät ja kaavat virheen tunnusluvuista on esitetty liitteessä 2. Useisakaan lähteissä ei ole kerrottu tuloksista kovinkaan tarkasti matemaattisia virheen tunnuslukuja käyttäen.


Tienkäyttäjän ja liikennetiedotuksen kannalta on oleellista, kuinka suuren osan ajasta malli ennustaa oikein (esim. 10 % virhemarginaalilla). Liikennetiedotuksen kannalta erityisen tärkeää on, kuinka suuri osa ruuhka-ajan ennusteista mahtuu virhemarginaalin sisään. Tällaista tietoa ei kuitenkaan ollut saatavilla kuin hyvin pienestä osasta tutkimuksia.

Sallittavan virhemarginaalin asettaminen ei kuitenkaan ole täysin ongelmantonta. Liikennetiedotuksessa lyhyen ajan ennusteista on eniten hyötyä ruuhkatilanteissa, vapaissa oloissa ennustamista ei niinkään tarvita. Mallin tulisi siis olla luotettava erityisesti ruuhkan ennustamisessa. Tulisiko mallille siis asettaa tiukemmat vaatimukset ruuhkaliikenteen kuin normaalin liikenteen ennusteiden tarkkuuden suhteen?

Ruuhkassa ennustaminen on kuitenkin paljon vaikeampaa kuin normaalissa tilanteessa. Mallitekniseltä kannalta katsottuna ruuhka-ajan virhemarginaali voitaisiinkin asettaa vapaata liikennetilannetta suuremmaksi. (Innamaa 2001)

Eri ennustesuureet myös suhtautuvat eri tavalla virhemarginaalin käyttöön. Esimerkiksi matka-aika kasvaa ruuhkan pahentuessa, mikä tarkoittaa sitä, että ruuhkatilanteessa sallittu absoluuttinen poikkeama toteutuneesta matkajasta kasvaa. Nopeus taas alenee ruuhkassa ja nopeusennusteiden sallittu absoluuttinen poikkeama todellisista nopeuksista pienenee. (Innamaa 2001)

On myös pahempi, että malli ennustaa säännöllisesti jotkin tilanteet väärin, kuin että ennusteissa on satunnaisia virheitä, vaikka nämä olisivatkin osittain yli 10 %. Mallin hyvyyden arviointia helpottaa, kun mallin tulokset esitetään kuvaajalla, jossa x-akselilla olisi mitattu (toteutunut) arvo ja y-akselilla ennustettu arvo. Kuvaajan avulla voidaan arvioida minkälaisissa tilanteissa mallilla on erityisiä hankaluuksia. Esimerkki tällaisesta kuvaajasta on kuvassa 8. (Innamaa 2001)



Kuva 8. Mitatun ja ennustetun nopeuden suhtautuminen toisiinsa. Parhaassa tapauksessa mitattu ja ennustettu nopeus asettuvat suoralle $v(\text{ennustettu}) = v(\text{mitattu})$. Esimerkissä nopeusennusteet ovat onnistuneet kohtalaisen hyvin suuremmilla nopeuksilla, mutta pienillä nopeuksilla (ruuhkatilanteessa) malli on aliarvioinut nopeuksia.

Innamaa esitti 1999, että sijoitteluun ja simulointiin perustuvat mallit ovat niin raskaita ja hitaita, etteivät ne sovellu ajantasaisiin sovelluksiin. ARIMA-mallitkaan eivät sovellu tähän tarkoitukseen. Lupaavimmilta Innamaan mukaan vaikuttavat neuroverkot, Kalman-suodatus ja ei-parametrinen lähin naapuri -menetelmä, sekä siihen verrattavissa oleva SOM-neuroverkko. Tässä selvityksessä ei juurikaan tullut esiin seikkoja, jotka olisivat ristiriidassa Innamaan näkemyksen kanssa. Simulointi- ja sijoittelumenetelmillä on vahvuutena verkkoäkökulman ja kuljettajan reitinvalinnan huomioiminen, jotka ovat oleellisia asioita liikennetiedotusta varten tehdyissä lyhyen ajan ennusteissa. Tiedotuspalvelussa ennusteen ei myöskään tarvitse syntyä yhtä nopeasti kuin automaattisissa liikenteenohjausjärjestelmissä. Siksi voidaan olettaa, että simulointi- ja sijoittelumallit ovat käyttökelpoisempia tiedotuspalvelua varten tuotetuissa ennusteissa kuin liikenteenohjausjärjestelmissä.

7. JOHTOPÄÄTÖKSET JA JATKOTOIMENPITEET

Tässä selvityksessä ei löytynyt maailmalla tiedotuspalvelukäytössä olevia järjestelmiä, joihin sisältyisi lyhyen ajan liikenne-ennusteita. Erilaisia menetelmiä ja malleja on kuitenkin kehitetty ja testattu paljon. Tässä selvityksessä läpikäydyistä menetelmistä suurin osa on kehitetty moottoriteliikenteen ennustamiseen ja sopii parhaiten yksittäiselle tieosuudelle. Verkkonäkökulma, joka on tärkeä liikennetilannetiedotuksessa etenkin kaupunkiseuduilla, on mukana harvemmin. Parhaiten verkkonäkökulma tulee esille simulointi- ja sijoittelumalleissa. Nämä mallit ovat kuitenkin hitaita ja työläitä ja vaativat dynaamisen lähtöpaikka-määräpaikka –matriisin lähtötiedoikseen. Liikennetiedotuksessa ja alueellisessa liikenteen hallinnassa tarvittavien ennusteiden aikatahtain on yleensä 5..60 min. Tämä on pidempi kuin liikenteenohjausjärjestelmissä (liikennevalot, väyläohjaus) pääasiassa tarvittava 1...5 min ennustejakso. Mallin nopeus ei siis ole tiedotuksessa ja alueellisessa liikenteen hallinnassa yhtä ratkaisevaa kuin ohjausjärjestelmissä. Rekursiivisuutta eli tiedotuksen vaikutusta liikennetilanteen kehittymiseen ei ollut otettu huomioon kuin harvoissa tutkimuksissa. Suurin osa läpikäydyistä lähteistä keskittyi erilaisiin tilastollisiin malleihin ja neuroverkkojen käyttöön lyhyen ajan liikenne-ennusteissa.

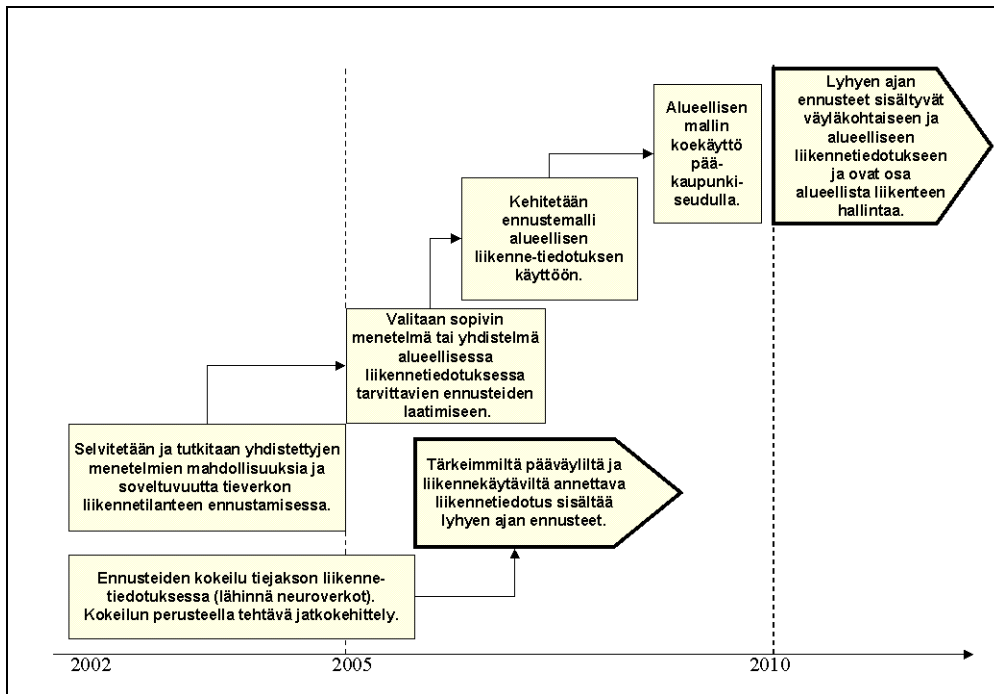
Kaikilla ennustemenetelmillä on hyvät ja huonot puolensa. Selvityksessä löytyi myös malleja, joissa on yhdistetty useita menetelmätyyppejä, jotta eri menetelmien hyvät puolet voitaisiin hyödyntää. Menetelmien yhdistely vaikuttaa lupaavalta, koska mikään yksittäinen menetelmätyyppi ei ole noussut selkeästi toisia paremmaksi. Esimerkiksi neuroverkkoja voitaisiin yhdistellä malliin, joka tekisi dynaamisen lähtöpaikka-määräpaikkamatriisin ja sijoittelisi liikenteen verkolle. Myös rekursiivisuus eli tienkäyttäjien reagoiminen liikennetiedotukseen tulisi ottaa ennustemallissa huomioon.

Lyhyen ajan ennusteista on tiedotuspalvelussa eniten hyötyä liikenteen ollessa ruuhkautunutta. Tiedotuksen näkökulmasta ei ole syytä hyväksyä ennusteissa suurempaa virhemarginaalia ruuhka-aikana kuin muulloin. Ennusteiden tarkkuus on tiedotuspalvelussa kenties vielä tärkeämpää kuin liikenteenohjausjärjestelmissä. Tiedotuspalvelussa liikenteen ennustettu sujuvuus kerrotaan tienkäyttäjälle suoraan, ohjausjärjestelmissä tienkäyttäjä kokee ennusteen onnistumisen välillisesti ohjauksen toimintana. Tavoitteena voisikin olla 5 %:n virhemarginaali.

Lyhyen ajan ennustemenetelmät tarvitsevat useimmiten ajantasaista mittaustietoa liikennemäärästä, liikennevirran keskinopeudesta ja ilmaisimen varausasteesta. Nämä lähtötiedot sisältyvät Liikenteen seurannan valtakunnallisessa esiselvityksessä määriteltyihin määrämuotoisiin liikennetietoihin, joita tarvitaan liikenteen hallinnan peruspalveluiden tuottamiseen (Tiehallinto 2001a).

Tämän selvityksen perusteella ei voida sulkea pois mitään menetelmää vaan pikemminkin mallien kehittämisessä tulisi pyrkiä hyödyntämään eri menetelmien hyviä puolia. Menetelmien kehittämisessä ja kokeiluissa tulisi jatkossa painottaa enemmän liikenteen tiedotuksessa ja alueellisessa ohjauksessa vaadittavaa verkkonäkökulmaa.

Kuvassa 9 esitetään ehdotus jatkotoimenpiteistä ja kehityspolusta sekä niiden aikataulusta, kun tavoitteeksi on asetettu, että viimeistään vuonna 2010 lyhyen ajan ennusteet sisältyisivät liikennetiedotukseen ja alueelliseen liikenteen hallintaan. Välitavoitteena on, että ennusteet sisältyisivät tärkeimmiltä pääväylyiltä ja liikennekäytäviltä annettavaan liikennetiedotukseen jo vuonna 2005...2006. Alueellista liikenteen hallintaa (sisältää häiriöiden hallinnan) varten tarvitaan ennusteita alueen ja tieverkon liikennetilanteen kehittymisestä. Aluksi tulisi selvittää eri ennustemenetelmien yhdistelyn mahdollisuuksia ja soveltuvuutta nimenomaan alueelliseen liikenteen hallintaan ja ennustamiseen. Selvitysten perusteella valitaan käyttökelpoisin menetelmä tai menetelmien yhdistelmä ja tämän pohjalta kehitetään malli tai mallit alueellista liikenteen hallintaa ja tiedotusta varten. Ennen ennusteiden käyttöönottoa mallit on validoitava ja testattava.



Kuva 9. Ehdotus jatkotoimenpiteistä ja niiden alustava aikataulu.

LÄHDELUETTELO

Hintikka J, Göös J, Neuroverkot, VTT Elektroniikka, Älykkäät järjestelmät (viitattu 10.8.2001) <http://www.vtt.fi/ele/tutkimus/soh/aly/neuroverkot.htm>

Hintikka J, Göös J, Sumea mallinnus, VTT Elektroniikka, Älykkäät järjestelmät (viitattu 10.8.2001) http://www.vtt.fi/ele/tutkimus/soh/aly/sumea_mallinnus.htm

Holma M (1991). Kalman-suodatuksen periaatteet ja käyttö liikenneteknisissä mittauksissa ja liikenteen ohjauksessa. Matematiikan erikoistyö, Teknillinen korkeakoulu, Espoo. 15+3 s.

Honkela T, Neuroverkot: johdatus moderniin tekoälyyn, TKK Neuroverkkojen tutkimusyksikkö (viitattu 10.8.2001) <http://www.cis.hut.fi/~tho/stes/step96/honkela2/>

Innamaa S (1999). Automaattiset liikenteenohjaus- ja liikenneinformaatiojärjestelmät. Tielaitoksen selvityksiä 28/1999, Tielaitos, Helsinki. 136 s.

Innamaa S, Pursula M (2000). Liikennemäärän ja nopeuden lyhyen aikavälin ennustaminen. Tielaitoksen selvityksiä 54/2000, Tielaitos, Helsinki. 102+3 s.

Innamaa S (2001). Tutkija, DI Satu Innamaan kanssa käyty sähköpostikeskustelu 23.7. – 13.8.2001

Juutilainen T, Käytännön kokemuksia neuraalilaskennasta prosessinohjauksessa, Control Express Finland Oy (viitattu 10.8.2001) <http://www.tacnet.sci.fi/Opetus/autom95/sm/71/cdluento.htm>

KAREN 2000. European ITS Framework Architecture. Issue 1.0 (CD). European Communities 2000.

Karvonen T, Kettunen J, Vakkilainen P (1982). Kalman suodattimen käyttö hydrologisten ja ekologisten mallien tilan identifioinnissa ja parametristimoinnissa. Monistesarja 1982:1, Teknillinen korkeakoulu, Vesitalouden laboratorio, Espoo. 45 s.

Kiljunen M, Summala H (1996). Ruuhkaisuuden kokeminen ja liikennetilantiedottaminen. Tienkäyttäjätutkimus kaksikaistaisilla teillä. Tielaitoksen selvityksiä 25/1996, Tielaitos, Helsinki. 77+5 s.

Lind G (2000). Strategies for Route Choice Information – Factors Influencing the Magnitude of User Benefits. Konferenssi-cd 7th World Congress on Intelligent Transport Systems, 6-9 November 2000, Turin, Italy. 8 s.

Milne D (2001). Tutkija Dave Milnen sähköpostihaastattelu 31.8.2001.

Mäkelä K, Niittymäki J, Kosonen I, Nevala R (2001). Fits Liikennetelematiikan rakenteiden ja palvelujen tutkimus- ja kehittämissuunnitelma 2001 – 2004, Älykäs liikenteenohjaus, Sumeaan logiikkaan ja simulointiin perustuvan liikennevalo-ohjauksen tuotteistaminen, Tuotteistamissuunnitelma 16.8.2001

(viitattu 19.10.2001) <http://www.hel.fi/liikenteenohjaus/fits/sumeantuottaistaminen.htm>

Pesonen E, Sumea logiikka, Kuopion yliopisto, Tietojenkäsittelytieteen ja sovelletun matematiikan laitos (viitattu 10.8.2001) <http://www.cs.uku.fi/~epesonen/opetus/aly/sumea.html>

Schultz R, Werwatz A, General Kalman Filtering (viitattu 10.8.2001) <http://www.xplore-stat.de/tutorials/gkalframe1.html>

Sundberg J, Ekdahl T, Hanson S (2000). Korttidsprognoiser för parkeringsefterfrågan. KFB projekt Dnr 1997-0646. 45 s.

TeKes, Sumean logiikan mahdollisuudet (viitattu 10.8.2001) <http://www.tekes.fi/julkaisut/sumea/index.html>

Tiehallinto (2001a). Liikenteen seurannan valtakunnallinen esiselvitys. Tiehallinnon selvityksiä 19/2001, Tiehallinto, Helsinki. 55 s.

Tiehallinto (2001b). Tiehallinnon liikenteen hallinnan toimintalinjat -taustaraportti. Tiehallinto, Helsinki. 69 s.

Nimi	MLP -neuroverkkojen soveltaminen liikennetilanteen ennustamiseen
Tyyppi	Mallin kehittäminen
Toteutusajankohta	Touko-kesäkuu 1999
Kohde	Länsiväylä, Helsinki-Espoo, Suomi
Alueen koko	3 km moottoritiejakso
Tilaja	Tielaitos, Liikenne- ja viestintäministeriö
Yhteyshenkilö	satu.innamaa@hut.fi
Tavoite	Selvittää, millainen neuroverkko soveltuisi parhaiten lyhyen aikavälin liikennetilanteiden ennustamiseen.
Ennustemalli	Eteenpäin syötävä monikerrosperseptronineuroverkko (multi-layer perceptron network, MLP).
Perustoiminta	Parhaita tuloksia antaneessa mallissa on kaksi neuroverkkoa, joista toinen ennustaa liikennemääriä ja toinen nopeuksia.
Input	
<i>Lähtötiedot</i>	Nopeus- ja liikennemäärähavainnot 15 viimeiseltä minuutilta 5 minuutin jaksoissa normeerattuina ja pääkomponenttianalyysin avulla käsiteltyinä tai skaalattuna. Joissain malleissa myös ajankohtatiedot tai nopeuden keskihajonta.
<i>Tietolähteet</i>	Induktioilmaisimet. Ilmaisimien sijainnille on olemassa optimaaliset sijoituskohdat, jotka riippuvat paikallisista olosuhteista ja ennustejakson pituudesta.
<i>Muuta</i>	Syötetietona ei kannata antaa liikaa dataa, jos vähemmällä päästään hyvin tuloksiin. Sää- ja kelityyppi kannattaa lisätä malliin yhdeksi syöteparametriksi. Kellonajan ja päivän tai nopeuskeskihajontatietojen antaminen ei parantanut tuloksia.
Output	Liikennemäärä- ja nopeusennuste seuraaville 15 minuutille 5 minuutin jaksoissa
Rajoitukset ja käyttöympäristö	Sopii yksittäiselle tielle, verkkonäkökulmaan huonommin.
Tulokset	Liikennemääräennusteet onnistuivat paremmin kuin nopeusennusteet. Nopeusennusteissa oli systemaattista virhettä, malli yliarvioi alhaisia nopeuksia. Liikennemääräennusteista 64 % ja nopeusennusteista 99 % mahtui 10 %:n virhemarginaaliin. Tulokset eivät huonontuneet ennustejakson pituuden kasvaessa.
Ongelmat	Induktioilmaisimista saadun datan kanssa oli ongelmia. Ilmaisista virheellisiä oli 38-48% mm. sen takia, että ajoneuvon liike oli epätasainen tai poikkeava. Käytetyn datajoukon pienuudesta johtuen mallin oli vaikea ennustaa ruuhkanopeuksia. Tarkasteltu tieosuus olisi myös saanut olla pidempi.
Muuta	Vertailututkimus kaksikaistaisella tiellä vt 3:lla Valkeakoskella touko-lokakuussa 1999. Mallin syötetiedot ennustehetkeä edeltävän puolen tunnin ajalta (viiden minuutin jaksojen liikennemäärä, keskinopeus ja keskimääräiset jonoprosentit). Havaittiin, että vastakkaisen suunnan liikennetietojen vaikutus tuloksiin oli pieni. Jonoprosenttien ennustaminen onnistui suhteellisen hyvin. Havaittiin, että Länsiväylälle kehitettyä mallia voidaan suurelta osin soveltaa myös kaksikaistaiselle tielle.
Lähteet	Innamaa S (2000). Short-Term Prediction of Traffic Situation Using MLP-Neural Networks. 7th World Congress on Intelligent Transport Systems. Turin, Italy, 6 - 9 Nov. 2000. 8 p. Innamaa S, Pursula M (2000). Liikennemäärän ja nopeuden lyhyen aikavälin ennustaminen. Tielaitoksen selvityksiä 54/2000, Tielaitos, Helsinki. 102+3 s.

Nimi	Matka-ajan ennustaminen epälineaarisen aikasarjamallin avulla
Tyyppi	Mallin kehittäminen
Kohde	
Alueen koko	Orlando, Florida, USA
Toteutusajankohta	18 km moottoritiejakso
Tilaaaja	
Yhteyshenkilö	Matthew P. D'Angelo, Haitham M. Al-Deek, Morgan C. Wang
Tavoite	Tiejakson matka-ajan ennustaminen liikenneinformaatiota varten.
Ennustemalli	Epälineaarinen aikasarjamalli. Vertailussa mukana yhden muuttujan (nopeus) ja usean muuttujan (nopeus, liikennemäärä, varausaste) malli.
Perustoiminta	Ennustetaan seuraava arvo v_{n+1} kun tiedetään aikasarja v_1, \dots, v_n .
Input	
Lähtötiedot	Havainnot nopeudesta, liikennemäärästä ja ilmaisimen varausasteesta 30 s välein, jotka yhdistetään 5 minuutin keskiarvoiksi. Aikasarja kerättiin 2,5 h ajalta (30 havaintoa). Mallia käytettiin aamun ruuhkatunteina (klo 6:00-10:00)
Tietolähteet	Induktioilmaisimet 800 m välein
Muuta	30 s välein saatavien nopeushavaintojen yhdistäminen 5 min keskiarvoksi tuottaa harhaa. Havaintojen yhdistämiseen käytettiin suodattamista. Havaittiin, että suodattaminen tasajakaumaa käyttäen antoi parhaat tulokset.
Output	Nopeuden ja siitä lasketun tiejakson matka-ajan ennuste 5 min välein.
Rajoitukset ja käyttöympäristö	
Tulokset	Yhden muuttujan malli tuotti parempia tuloksia kuin usean muuttujan malli. Tuloksista 98% oli 10% virhemarginaalin sisällä. Keskimääräinen matka-ajan ennusteen virhe oli 1,3%.
Ongelmat	Ongelmia oli liikennetilanteen muuttuessa. Ruuhkan syntyessä ja purkautuessa ennusteissa oli enemmän virhettä, kuin vakaassa tilanteessa (eli ruuhkattomana ja ruuhkan aikana). Kaaosteoriaa tai tekoälyä voitaisiin ehkä soveltaa muuttuvien tilanteiden ennustamisessa.
Muuta	Epälineaarinen aikasarjamalli voi antaa epärealistisen alhaisia nopeusennusteita. Kynnysarvoksi asetettiin testien perusteella 16 km/h, jota pienemmät arvot korvattiin viereisten ilmaisinvälien ennusteiden keskiarvoilla.
Lähteet	D' Angelo M, Al-Deek H, Wang M (1999). Travel-Time Prediction for Freeway Corridors. Transportation Research Record, No. 1073. s. 184-191.

Nimi	Matka-aikojen ennustaminen modulaarisen neuroverkon avulla
Tyyppi	Mallin kehittäminen
Toteutusajankohta	1996 (231 arkipäivää)
Kohde	US-290 (6-kaistainen moottoritie), Houston, Texas, USA
Alueen koko	27,6 km tiejakso
Tilaaaja	
Yhteyshenkilö	Dongjoo Park, Laurence R. Rilett
Tavoite	Linkkien matka-aikojen ennustaminen liikenneinformaatiota varten
Ennustemalli	Modulaarinen neuroverkko
Perustoiminta	Tilastoidut matka-ajat jaettiin luokkiin valvomatonta ryhmittelytekniikkaa käyttäen. Ryhmittelytekniikoina käytettiin itseorganisoivaa karttaa (self-organizing map, SOM) ja sumeaa logiikkaa (fuzzy c-means clustering technique). Jokaiselle luokalle luodaan oma neuroverkko matka-aikojen ennustamista varten.
Input	
<i>Lähtötiedot</i>	Linkkien matka-ajat aggregoituna 5 min matka-aikahavainnoiksi. Mallia käytettiin aamun ruuhkatunteina (klo 6:00-10:00)
<i>Tietolähteet</i>	Automaattinen ajoneuvon tunnistusjärjestelmä, 7 tunnistuspistettä
<i>Muuta</i>	
Output	Linkkien matka-ajat seuraaville 5-25 minuutille
Rajoitukset ja käyttöympäristö	Mallia tehtäessä on huomioitava ryhmien määrä ja niiden ominaisuuksien erotelu sekä ryhmittelyyn käytettävät parametrit ja niiden painokertoimet. Ennustejakson pituuden kasvaessa ennustevirhe kasvaa ja jossain vaiheessa (1-2 h ->) historiadataa käyttävä malli voi antaa parempia tuloksia.
Tulokset	Sumeaa logiikkaa käyttävä ryhmittelytekniikka antoi hieman parempia tuloksia kuin itseorganisoivaa karttaa käyttävä. Ennustevirhe sumeaa logiikkaa käyttäen oli 8,1-15,7 % ja SOMia käyttäen 8,2-16,4 %. Virhe kasvoi ennustejakson pituuden kasvaessa. Parhaisiin tuloksiin päästiin luokkien eli neuroverkkojen määrän ollessa 10.
Ongelmat	Malli vaatii vielä tutkimista ja kehittämistä mm. parhaan havaintojakson pituuden sekä sopivan neuroverkkomallin löytämiseksi.
Muuta	
Lähteet	Park D, Rilett L (1998). Forecasting Multiple-Period Freeway Link Travel Times Using Modular Neural Networks. Transportation Research Record, No. 0743. s. 163-170.

Nimi	Matka-ajan ennustaminen MLP-neuroverkolla
Tyyppi	Mallin kehittäminen
Kohde	vt 4, Lahti-Heinola, Suomi
Alueen koko	28 km tiejakso
Toteutusajankohta	Kesä-elokuu 2000
Tilaja	Tiehallinto, Liikenne- ja viestintäministeriö
Yhteyshenkilö	satu.innamaa@hut.fi
Tavoite	Selvittää, minkälaisilla syötteillä saadaan aikaiseksi paras matka-aikaennuste ja miten järjestelmän rakenne vaikuttaa ennusteeseen.
Ennustemalli	Eteenpäin syöttävä monikerrosperseptroniverkko (multi-layer perceptron network, MLP)
Perustoiminta	Kullekin osalinkille ja osalinkkiyhdistelmälle oma neuroverkko.
Input	
<i>Lähtötiedot</i>	Korrelaation perusteella valittuja eri osalinkkien ja osalinkkiyhdistelmien erilaisia keski- ja mediaanimatka-aikoja sekä matka-ajan keskihajontoja sekä LAM-pisteistä liikennemääriä, keskinopeuksia ja nopeuskeskihajontoja
<i>Tietolähteet</i>	Matka-aikoja mittaava järjestelmä (automaattinen ajoneuvon tunnistus) ja induktioilmaisimet.
<i>Muuta</i>	Lisäkamerapisteet parantavat tulosta enemmän kuin lisä-LAM-pisteet.
Output	Matka-aikaennuste kullekin osalinkille ja osalinkkiyhdistelmälle seuraavan minuutin aikana saapuville ajoneuvoille
Rajoitukset ja käyttöympäristö	Sopii yksittäiselle tielle sekä verkolle. Opetusjoukon tulee olla riittävän laaja ja ruuhkatilanteiden ennakoimiseksi verkkoa täytyy opettaa riittävän laajalla ruuhka-ajan aineistolla.
Tulokset	Paras malli ennusti oikein yli 90 % ajasta ruuhkaliikenteessä. Mallien hyvyys vaihteli suunnan ja sen mukaan, oliko linkki jaettu osalinkkeihin vai ei (oikein ennustetut 60%-90,3% ruuhkaliikenteessä). Malli yliarvioi matka-aikoja hieman.
Ongelmat	Aineistossa oli vähän ruuhkaisia päiviä. Mitattujen matka-aikojen osuus oli pieni, koska kameroita vain yhdellä kaistalla / suunta.
Muuta	Aineistoa kerätään lisää kesän 2001 aikana ja malleja pyritään parantamaan uuden datan avulla.
Lähteet	Innamaa S (2001, accepted to be published). Short-Term Prediction of Highway Travel Time Using MLP-Neural Networks. 8th World Congress on Intelligent Transport Systems. Sydney, Australia, 30 Sept. - 4 Oct. 2001. 12 p.

Nimi	Liikennetilanteen ennustaminen tilasto- tietojen ja nykytilan mittausten avulla
Tyyppi	Mallin kehittäminen
Kohde	Moottoritieverkko lähellä Amsterdamia, Hollanti
Alueen koko	
Toteutusajankohta	
Tilaaja	
Yhteyshenkilö	Rik van Grol, Domenico Inaudi, Eric Kroes
Tavoite	Matka-ajan ennustaminen, vaikeasti ennustettavien tilanteiden tunnistaminen (ennusteen tarkkuus voidaan määrittää ja kertoa tienkäyttäjille).
Ennustemalli	Tilastollinen kehitys talletettuna tietokantaan
Perustoiminta	Liikennetiedot on tallennettu aikasarjoina viikonpäivän mukaan jaotellen. Aika-sarjaa päivitetään antamalla uusille havainnoille suurempi painoarvo. Ennusteita voidaan korjata ilmaisimilta saadun reaaliaikaisen tiedon avulla.
Input	
<i>Lähtötiedot</i>	Liikennemäärät ja nopeudet viikonpäivän mukaan jaoteltuna
<i>Tietolähteet</i>	
<i>Muuta</i>	Säätyyppiä voitaisiin myös käyttää luokitteluun viikonpäivän lisäksi.
Output	Liikennemäärä ja nopeus
Rajoitukset ja käyttöympäristö	
Tulokset	Reaaliaikainen mittaustieto liikenteestä paransi ennustuksia vai hieman. Reaaliaikaisesta tiedosta ei ollut hyötyä puolta tuntia pidemmälle meneville ennusteille.
Ongelmat	Ei kykene ennustamaan yllättäviä ruuhkatilanteita.
Muuta	Liikennetilanteiden ennustaminen on vaikeaa mutta toisissa tilanteissa voidaan ennustaa tarkemmin kuin toisissa. On tärkeää tietää ennusteen tarkkuus ja kertoa tienkäyttäjille myös matka-aikojen hajonnasta kussakin tilanteessa.
Lähteet	Grol R van, Inaudi D, Kroes E (2000). On-Line Traffic Condition Forecasting Using On-Line Measurements and a Historical Database. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 10 s.

Nimi	Reaaliaikaisen ja ennustetun liikennetiedon jakaminen tienkäyttäjille
Tyyppi	
Kohde	Melbourne, Australia
Alueen koko	
Toteutusajankohta	Kokeilu alkoi lokakuussa 1999, autoilijoita mukana yli 70
Tilaaaja	
Yhteyshenkilö	Charles A Karl, Roslyn S Trayford
Tavoite	Tuottaa ja jakaa autoilijoille informaatiota liikenteen sujuvuudesta ja sitä kautta välttää ruuhkien syntymistä. Tavoitteena myös tutkia milloin ja millaista informaatiota autoilijat haluavat ja miten sitä voidaan jakaa nykyistä tekniikkaa käyttäen.
Ennustemalli	Monimuuttujaregressiomalli, monimuuttuja aikasarja-analyysi, neuroverkkomalli (spectral analysis), piece-wise daily templates
Perustoiminta	Autoilijoista on tehty tietokanta, joka sisältää jokaisen autoilijan profiilin (vakituisen matkan lähtö- ja määräpaikka, lähtöaika, moottoritien liittymis- ja poistumisramppi ym.). Autoilijoille lähetetään vähän ennen lähtöä tekstiviesti, joka kertoo ennustetun matka-ajan, tiedot häiriöistä ja säästä. Matkan aikana voidaan lähettää informaatiota esim. onnettomuuksista.
Input	
Lähtötiedot	Nykyinen matka-aika, sää, onnettomuudet, ennustemallia varten tilastotietoa liikenteestä
Tietolähteet	Induktiosilmukat, liikennevalot, videokamerat, GPS/GSM –paikannus, manuaaliseuranta, sää, media
Muuta	
Output	Ennustettu matka-aika
Rajoitukset ja käyttöympäristö	Lähtötietoa tulee kerätä koko kaupungin alueelta, ei vain moottoriteiltä. Autoilijoille tulee jakaa sekä reaali-aikaista että ennustetietoa ja tiedonjakoon tulee olla monia eri kanavia.
Tulokset	Lyhyillä matkoilla ennustevirhe voi olla suuri, mutta sillä ei ole käytännön kannalta merkitystä. Pidemmällä matkoilla (yli 30 min) yllättävien tapahtumien vaikutus tasoittuu.
Ongelmat	
Muuta	
Lähteet	Karl Jr C A, Trayford R S (2000). Delivery of Real-Time and Predictive Travel Time Information: Experiences from Melbourne Trial. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy. 10 s.

Nimi	Moottoritien liikenteen ennustaminen simulointi- ja sijoittelumallilla
Tyyppi	Mallin kehittäminen
Kohde	Moottoritiejakso välillä Vienne – Montpellier/Lancon, Ranska
Alueen koko	310 km tieverkko, 29 eritasoliittymää
Toteutusajankohta	Kesä 1995
Tilaaaja	ASFA (Association des Societes Francaises d'Autoroutes)
Yhteyshenkilö	Jean-Marc Morin, Bernard Baradel, Joel Bomier
Tavoite	Liikennetilanteiden ennustaminen
Ennustemalli	Malliin kuuluu OD-matriisit ennustava MITHRA 2 ja liikennevirran makroskooppinen simulointimalli SIMRES, jotka saavat lähtötietoa automaattisesta liikenteenmittausjärjestelmästä (MISTRAL).
Perustoiminta	MITHRA ennustaa tulevan OD-matriisin vertailemalla nykyhetken liikennemittauksia tilastoituihin ja luokiteltuihin OD-matriiseihin. SIMRES-mallissa tieverkko on mallinnettu jakamalla se 2 km pituisiin osiin, joille on määritetty nopeus-liikennetiheys –suhte liikennemittausten perusteella.
Input	
Lähtötiedot	MITHRA: usean vuoden tilastoidut OD-matriisit, tämän hetkinen liikennemäärä. SIMRES: ajantasainen mittaus tieto liikenteestä (liikennemäärä, nopeus, varausaste). Tiedot 6 min välein.
Tietolähteet	49 mittauspistettä, tiedot 20 km välein
Muuta	
Output	Varausasteeseen ja nopeuteen perustuva liikennetilanneluokka. Rinnakkain esitetään nykytilanne ja ennustettu liikennetilanne (2 tunnin päästä).
Rajoitukset ja käyttöympäristö	
Tulokset	OD-matriisin suhteellinen neliökeskivirhe (MRQE = mean relative quadratic error) tunnin ennusteille 25 % ja kahden tunnin ennusteille 34 %. Liikennemäärän tämän hetken estimaatin MRQE 16-18 % ja kahden tunnin ennusteen MRQE 24-28 %.
Ongelmat	
Muuta	Lisää käyttötestejä kesällä 1996. Malliin tarkoitus lisätä mahdollisuus simuloida liikenteen ohjaustoimien vaikutuksia.
Lähteet	Morin J-M, Baradel B, Bomier J (1996). On-Line Short Term Simulation and Forecast of Motorway Traffic Patterns: Field Results Obtained on ASF Network in France. 3th World Congress on Intelligent Transport Systems, 14-18 October 1996, Orlando, USA. 9 s.

VIRHETERMIT

MSE = mean squared error

MSE eli keskineliövirhe on mittaluku, jolla kuvataan aineiston perusteella es-
timoitavalle parametrille muodostetun estimaatin tarkkuutta. MSE lasketaan
parametrin estimaatin ja todellisen arvon välisen eron neliön odotusarvona.
Mikäli estimoitava parametri on θ ja mikäli sille otoksen perusteella laskettu
estimaatti $\hat{\theta}$, on estimaattiin liittyvä keskineliövirhe

$$MSE = E(\hat{\theta} - \theta)^2$$

$$MSE = \frac{1}{n} \sum_i (y_i - \hat{y}_i)^2$$

RMSE = root mean squared error

RMSE on yksinkertaisesti MSE:n eli keskineliövirheen neliöjuuri.

$$RMSE = \sqrt{\frac{1}{n} \sum_i (y_i - \hat{y}_i)^2}$$

Korrelaatiokerroin

Korrelaatiokerroin mittaa lineaaristen riippuvuuksien voimakkuutta. Korrelaa-
tiokertoimen arvo voi vaihdella välillä $-1 \dots 1$. Korrelaatiokertoimen positiivi-
nen arvo tarkoittaa, että muuttujien välillä on positiivinen riippuvuus. Vastaa-
vasti negatiivinen korrelaatiokerroin viittaa negatiiviseen riippuvuuteen.
<http://noppa5.pc.helsinki.fi/uudet/da1htm/sanasto.html>

Selitysaste R^2

Selitysaste R^2 kertoo, kuinka suuren osan selittävä muuttuja pystyy selittä-
mään selitettävän muuttujan vaihtelusta. Selitysaste vaihtelee välillä $0 \dots 1$.
Selitysaste on sitä lähempänä ykköstä, mitä paremmin selitettävän muuttu-
jan vaihtelu saadaan selitettyä. Yhden muuttujan regressiomallin selitysaste
on korrelaatiokertoimen neliö. (www.valt.helsinki.fi/atk/stat/regressio.htm)

ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
1. Sji + sim	Casimir J. de Rham, Rainer Lange	Short Term Forecast and Evaluation for Intelligent VMS Setting, Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 7 s.	Saksa	2000	Liikenteen tasapainoinen sijoitus verkolla muuttuvien opasteiden avulla	Malli luo dynaamisen OD-matriisin ilmaisimien avulla saatavien liikennetietojen perusteella, tekee simuloinnin erilaisilla muuttuvilla opasteilla ja valitsee parhaat opasteet kuormitusasteen minimin perusteella.	Tiedot kevyiden (lyhyiden) ja raskaiden (pikien) ajoneuvojen määrästä ja nopeudesta 300 induktiosilmukalta 5 min välein	Tiedot OD-matriisiin kalibroinnista, muuttuvien opasteiden tiedot 15 min välein		Tesitattu kahdella rinnakkaisella moottoritilla Darmstadtin ja Heidelbergin välillä	Kuormitusaste putoi ruuissa 10% ja ruuhkatonama aikana kasvoi saman verran
2. Tekoäly	Satu Innamaa	Short-Term Prediction of Traffic Situation Using MLP-Neural Networks. Konferenssi cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 8 s.	Suomi	2000	Eri tekijöiden vaikutus lyhyen ajan ennusteisiin. Parhaan neuroverkon ja inputin löytäminen	Omat mallit keskinopeuden ja liikennemäärän ennustamiseen	5 minuutin havainnot nopeudesta ja liikennemäärästä	Nopeus- ja liikennemääräennuste e seuraavalle 15 minuutille	Sopii yksittäiselle tielle, verkolle huonommin.	Tesitattu Länsiväylällä (myös vt 3:lla Valkaakoskella)	Nopeusennusteissa systemaattista virhettä, liikennemääräennusteet onnistuivat paremmin. MSE nopeudelle 5-7, MSE liikennemäärälle 36000-66000. Liikennemääräennusteista 64 % ja nopeusennusteista 99 % mahtuu 10 %:n virhemarginaalin sisään.
3.	B. S. Kerner, M. Aleksic, H. Rahborn, A. Haug	Methods for the Tracing and Prediction of Traffic Flow Patterns in the Congested Regime. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 8 s.	Saksa	2000	Liikennevirran ennustaminen, Mallit, joita ei tarvitse aina validoida olosuhteiden muuttuessa	Liikennemallanne jaettu kolmeen luokkaan: vapaa, jonotunut ja ruuhkautunut. Ruuhkat ja muut liikennetilanteet jäljitetään automaattisesti ja ruuhkan etenemisnopeutta käytetään liikennetilanteen ennustamiseen.	Liikennemäärä ja nopeus (vapaa, jonotunut, ruuhkautunut) ja niiden eteneminen tienveroilla	Eri liikennetilanteet (traffic objects)	Tesitattu Hessesissä moottoritilla		
4. Tilasto, tekoäly	Giovanni Huisken, Martin van Maarseveen	Congestion Prediction on Motorways: a Comparative Analysis. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 7 s.	Hollanti	2000	Esitellä ja vertailla eri menetelmiä lyhyen ajan ennusteiden laatuun	lineaarinen regressio, akasjarja-analyysi, monikerrospaneuvonverkko, radiaalinen funktion network, sumea logiikka, itseorganisoituvia kartta	Liikennemäärä, nopeus, nopeuden keskihajonta ja varausaste induktiosilmukoilla	Ohko ruuhkaa odotteitaivassa vai ei		Tesitoida kerätty Hollannissa neljän viikon ajalta	ARIMA, MLP, RBF ja sumea logiikka antoivat hyvin samankaltaisia tuloksia. MLR epäonnistui ja SOM jätettiin pois suuren virheellisyyden takia.
5. Tilasto	Charles A Karl Jr, Roslyn S Trayford	Delivery of Real-Time and Predictive Travel Time Information: Experiences from a Melbourne Trial. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 8 s.	Australia	2000	Reaaliaikaisen ja ennustetun tiedon jakaminen liikenteen käyttäjille tekstiviesteinä, kokemukset	Autoilijoille lähetetään ennen matkaa viesti, jossa kerrotaan ennustettu matkailka. Matkan aikana voidaan myös lähettää informaatiota esim. onnettomuuksista. Matemaattinen ennusmalli, joka käyttää historiatietoa sekä ajantasaisista liikennetietoa viivyytsten ja matka-aikojen ennustamiseen.	Liikennetietoa induktiosilmukoilla, liikennevalotista, videokameralla, GPS/GSM-paikannus, säätäetöjä	Matka-ajan ennuste kerätty koko kaupungin alueelta, ei vain moottoritilla. Autoilijoille tulee jalkaa sekä reaali-ennusteletoa ja tiedonjakoon tulee olla montia eri kanavia.	Tesetöjä Melbourneissa (70 autoilijaa)	Reitinvalintaan vaikuttavat matka-ajan lisäksi mm. tieuukka, luotettava saapumisaika ja omat mielipyykset. Informaatio on sitä hyödyllisempää, mitä aiemmin se annetaan. Reitinvalitioa kannattaa suosittelaa vasta tietyn hyödyn (kynnysarvo) jälkeen	
6.	Gunnar Lind	Strategies for Route Choice Information - Factors influencing the Magnitude of User Benefits. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 8 s.	Ruotsi	2000	Miten eri tekijät reitinvalintaa koskevassa informaatiassa vaikuttavat käyttäjien toimintaan, mitkä tekijät vaikuttavat reitinvalintaan						

ENN. MENETELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
7. Sji + sim	G. Järjies, C. R. Diane	Prediction of Vehicle Travel Times Using Ancillary Information Sources. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 9 s.	Australia	2000	Matka-ajkojen ennustaminen	Dynaaminen simulointimalli. Ajoneuvot jaettu luokkiin saapumisajan mukaan (suhteessa liikennevalojen kiertoon)	Jokaisen linkin keskimääräinen, minimi- ja maksiminopeus, ajoneuvojen sijainti ja liikennevalojen kierto	Ajoneuvon lähtöaika -valo-ohjausta risteyksestä. Näistä muodostuu N:n risteysten jälkeen 2 ^N eri ajon-akavaihtoehtoa eri todennäköisyyksillä.	Voidaan käyttää vain valo-ohjatulla tielosuoksilla	Testattu simuloiduilla bussilla TRITRAM-simulointiohjelmalla	Ajoneuvon ennustettu lähtöaika risteyksestä poikkeaa alle 10 sekunnilla oikeasta ajasta n. 90 % ennustetta. Jos ajoneuvo myöhästyy vihrästä, ennustevirhe kasvaa radikaalisti (systemaattinen virhe).
8. Tilasto, tekoäly	S. Rosswog, P. Wagner	A Comparative Study of Traffic State Predictions: Alitted Template Technique (FTT) versus Neural Networks. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 5 s.	Saksa	2000	FTT-menetelmän ja monikerrosperrooni neuroverkkojen vertailu	FTT-menetelmässä ennustetaan tilastotiedon pohjalta parantaneen ennusteita tärinän hetken liikennetiedolla.	Tilastotietoa liikenteestä	Liikennemäärä tiedystä laskentapioteissä		Testi Kölnissä touko-lokakuussa 1999	FTT-menetelmällä keskivirhe 12% 15 min ennustella ja 13% tunnin ennustelle. Neuroverkolla keskivirhe 9% 15 min ennustella.
9. Tilasto	Tomoaki Okada, Norihiro Izumi	Providing Information of Predicted Travel Time for Use of Travel Planning Stage. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 7 s.	Japani	2000	Matka-ajkojen ennustaminen liikenneinformaatiota varten	Ennusteet perustuvat liikenteen kausi-, viikko- ja vrk-vaihteluun. Ennusteita tarkistetaan nykyhetken liikenteen ja muiden tietojen (esim. tiettyt) avulla. Käytäjäpöytä www:ssä	Liikennemäärä ja nopeusdataa päivättyihin matkajen keskiarvo ja vaihteluvälit. Lisäksi muuta tietoa eri reiteistä.	Internetissä kerrotaan jokaisen päivätyyppin matkajen keskiarvo ja vaihteluvälit. Lisäksi muuta tietoa eri reiteistä.		Kehitetty Tokion Metropolitan Expresswayta varten	
10.	Fumitaka Kurauchi, Yasunori Iida, Taku Atzawa	An Evaluation on Effect of Travel Time Information from Real-Time Origin-Destination Matrices Estimation Model. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 8 s.	Japani	2000	Tulkia miten liikenne reagoi informaatioon matka-ajista	Kirjoittajien kehittämä malli jossa estimoidaan liikennemäärä lähtö-määräpaikkojen välillä (OD-matriisi)	Rampojen ja linkkien liikennemäärät ja linkkien nopeudet	Reitinvaihto-todennäköisyys	OD-matriisin esimointimalli sopii lähinnä moontiteille	Testattu Hanshinin moontiteillä Osakan lähellä lokakuussa 1997	
11. Tilasto	Rik van Grol, Domenico Inaudi, Eric Kroes	On-Line Traffic Condition Forecasting Using On-Line Measurements and a Historical Database. Konferenssi-cd, 7th World Congress on Intelligent Transport Systems, 6-9 November, 2000, Turin, Italy, 10 s.	Hollanti	2000	Lyhyen ajan ennusteiden tuottaminen	Tilastollinen kehitys läydenneytynä reaaliaikaisilla tiedoilla	Tilastotietoa jokaisesta päivätyypistä	Liikennemäärä ja nopeus		Testattu moontiteillä Hollannissa	Reaaliaikaiset liikennetiedot paransivat tuloksia vain vähän. Pidemmän aikavälin ennustella reaaliaikaisesta tiedosta ei ollut hyötyä.
13. Tilasto	Billy M. Williams, Brian L. Smith	Traffic Condition Forecasting for ITS Operations. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada, 7 s.	USA	1999	Menetelmien ennustearkkuiden ja helpotkäytisyyden vertailu liikenne-ennusteiden tuottamisessa	Kausittainen aikasarja-analysi ja ei-parametrinen regressio	Aikasarjalle 30 min ja ei-parametrille regressiomallille 15 min liikennemäärä	Liikennemäärä		Aikasarjamalli testattu Renscasta vuosien 1984-1990 aikana kerättyä dataa. Ei-parametrinen malli testattu vuonna 1993 kerättyä dataa.	Molemmat mallit pärjäsivät lähes yhtä hyvin MAP:En mittatuna (mean absolute percent error)

ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
14. Tilasto- Kalman-suodatus	Masato Iwasaki, Kazuki Sato	Short-Term Prediction of Speed Fluctuations on a Motorway Using Historical Patterns. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada, 10 s.	Japani	1999	Liikenneliikenteen ennustaminen historiadatan (liikenneliikenne) avulla (la, pyhä) ja tämän hetken liikennemittausten perusteella	Liikenne-ennusteet tehdään autoregressiivisellä mallilla, jonka parametrien kertominen määritykseen käytetään laajennettua Kalman-suodatusta	5 min liikennemäärä ja keskinopeus	Keskinopeus tietyssä laskentapisteessä	Sopii moottoritielle. Mallin on hankala ennustaa yllättäviä tilanteita. Ennusteissa ongelmia etenkin ruuhkan muodostuessa ja alkajassa purkauu.	Testattu Tornein moottoritiellä Tokion läheillä	Pidemmällä aikavälillä päästiin parempiin tuloksiin antamalla historiadatalle suurempi painoarvo.
15. Sij + sim	Winfried Kronjäger, Dagmar Herrmann	Travel Time Estimation on the Base of Microscopic Traffic Flow Simulation. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada, 5 s.	Saksa	1999	Liikenneliikenteen ennustaminen mikrosimuloinnin avulla (simulointiohjelma VIDELO)	Logittimalli reitinvälille	OD-matriisit, tietoa tieverkosta ja liikennevaloisista, tietoja tapahtumista, tietolista, liikennevirrasta, nykyinen matka-aika	Linkkien matka-ajat ja nopeudet	Sopii kaupunkiverkolle	Testattu Berliinissä 94 km, 50 risteyskesken sijottelumallin suhteen on vielä tehtävä.	Kehitystyötä reaaliaikaisen datan soveltamisen ja liikenteen sijottelumallin suhteen on vielä tehtävä.
16. Tilasto- tekoäly	Yang Zhaozheng, Chu Lanyu	A Study on the Locally-determined Dynamic Route Guidance System in China. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada, 9 s.	Kiina	1999	Parhaan mallin valinta liikenneliikenteen ennustamiseen, dynaaminen reitineuvonta	Tilastotietoon perustuva malli, jos reaaliaikaisista dataa ei ole saatavilla, ARIMA-malli, kun liikenneliikenne vaihtelee, Neuroverkkomalli, kun liikenneliikenne muuttuu nopeasti. Ei-parametriset mallit neuroverkon sijaan, jos opetusdataa laatu huono.	Liikenneliikenteen mallisimulointi, kameroilta, testiatuista, poliisilta, tilastoista	Linkkien matka-ajat	Tesattu Changchun Ciyissä		
17.	Laurence R. Rillet, Dongjoo Park, Byron Gajewski	Estimating Confidence Interval for Freeway Corridor travel Time Forecasts. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada, 8 s.	USA	1999	Luottamusvälin löytäminen ennustetulle matkalle	Taylorin sarjalla esimoidaan tiejakson matka-ajan ennusteen keskiarvoa ja varianssia linkkien ennustettujen matka-ajan keskiarvon ja varianssin perusteella.	Linkkien ennustetut matka-ajat, eri linkkien matka-ajojen korrelaatio	Luottamusväli reitin keskimääräiselle matkalle		Tesattu Houstonissa Texasissa 11 km tieosuudella lokakuussa 1996	Ensimmäisen asteen Taylor-sarja vaikuttaa olevan riittävä arvioimaan ennusteen luottamusväliä
18. Sij + sim	Rik van Grol, Karel Lindveld, Simonetta Manfredi, Mehdi Danech-Pajouh, Stef A. Smulders, Rik J.M. van Grol, Joe Whittaker	DACCOR: On-Line Travel Time Estimation/Prediction Results. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada, 12 s. Evaluation of a Model for the Real-Time Short-Term Prediction of Traffic Conditions on Motorway Networks. Conference Title: Intelligent Transportation: Realizing the Future. Abstract of the Third World Congress on Intelligent Transport Systems, s. 224-225	Hollanti, Italia, Ranska	1999	EU-projekti DACCORin esittely, matkalle ennustaminen	Ilmaisvälin ennustaminen: makroskooppinen liikennevirtamalli Statistical Traffic Model (STM) ja Behavioural Traffic Model (B TM), johon kuuluu dynaaminen OD-matriisi ja sijoittelu. Verkkoennustaminen: dynaaminen ennustemalli ja hetkellinen ennustemalli	Liikennemäärä, nopeus, varausaste ja näistä johdetut matka-aika, tiheys ja jonon pituus	Matka-aika	Puutteellisia testejä Pariisissa ja Italiassa moottoritieillä sekä Amsterdamin kehätiellä		Testeissä ongelmia ruuhkittomuuden ym. takia. STM heikohko ja riippuvainen monitoroinnista. BTW suorittui vähän paremmin

ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
19. Sji + sim	Darryn Paterson, Geoff Rose	Dynamic Travel Time Estimation on Instrumented Freeways. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 11 s.	Australia	1999	Makroskooppiseen liikenneteoriaan ja deterministiseen jonoteoriaan perustuva soluautomaattimalli (recursive cell processing model) matka-ajan ennustamiseen.	Vapaan virran matka-ajkaan lisätään viivytys, joka on saatu mittamalla erilaisten pullonkaulojen palveluakaa	Pistenopeuksia ilmaisimilla, pullonkaulojen ja rampplen ym. kuormitusaste (processing rate)	Matka-ajka	Mootoritehtäviin	Testejä 15 km riejaksolla Melbourneassa	MSE 2.3 Yllälvöi matka-ajkaa hieman
20.	Hojung Kim, Kyonghee Choi, Byungja Ahn	Evaluation of Estimated Shortest Travel Time in Dynamic Traffic Network Using TRAF-NETSIM. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 8-12 November 1999, Toronto, Canada. 6 s.	Korea	1999	Nopeimman reitin löytäminen	Lyhyin matka-ajka esitelmään paraneuulla Dijkstra-algoritmilla (lyhimmän reitin löytäminen) käytetään viimeajan matka-ajkojen keskiarvoja. Saatua tulosta verrataan simuloituihin tuloksiin	Dynaaminen OD-matriisi, nykyinen matka-ajka	Reitti, jonka matka-ajka on lyhin		Mallin arviointi tehtin simulointiohjelmalla TRAF-NETSIMin avulla	
21. Kaiman-suodatu s, tekoäly, tilasto	Young-hn Lee, Chan Young Choi	Development of a Link Travel Time Prediction Algorithm for Urban Expressway. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Korea	1998	Kaiman-suodattimen, neuroverkkojen ja aikasarjajäljennys mallin avulla ennustamisessa		Liikennemäärä, nopeus, varausaste	Nopeus	Kaiman suodatinta ja neuroverkko rajoitettavdatan kerääminen ja mallin siirrettävvyys paikasta toiseen.	Testattu Olympic Expresswayn kahden tuntiin datalla 1998	Kaiman-suodatus osoittautui parhaaksi ennustemalliksi. Kaiman suodatus MSE 9.9, ARIMA MSE 10.3, neuroverkko: MSE 13.8
22. Tilasto, tekoäly	Jinsoo You, Tschangho John Kim	Toward Developing an Expert GIS-Based Travel Time Forecasting Model with Congestion Pattern Analysis. Konferenssi cd, 6th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 13 s.	Korea	1998	Tarkastella ennustamiseen käytettyjä menetelmiä ja kehittää niiden pohjalta myös GIS-dattaa hyödynnävä malli	Mallissa on mukana paikkatietojärjestelmä (GIS) liikennetietokannasta ja historiatietokannasta ja poljilla sekä hatakeskuksilla liikenteen seuranta, datan käsittely ja luokittelu sekä ennusteiden teko (neuroverkot ja ES-expert systems)	Liikennetietoa ilmaisimilla, testiautoista, historiatietokannasta ja poljilla sekä hatakeskuksilla	Liikennemäärä ja matka-ajka		Ei käytössä	
23. Kaiman-suodatu s, tekoäly, tilasto	Seungjae Kim, Juyoung Kim, Bumchul Cho	Comparison of Models for Predicting Short-Term Travel Speeds. Konferenssi-cd, 6th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 9 s.	Korea	1998	Menetelmiä, jolla ennustetaan pistenopeuksia ja sitä kautta matkanopeuksia	Usean muuttujan regressio, aikasarja-analyysi (ARIMA), neuroverkot, Kaiman-suodatus	Kunkin solmun nopeuden ennustamiseen käytetään edellisen ja seuraavan solmun liikennedatata (nopeus, liikennemäärä, varausaste) edellisellä alka-askelleella. Data kerätään kuvankäsittelyllä a777 (image processing detector)	Pistenopeus		Testiattu oikealla liikennedatalla	Sellysasteen ja MSE:n perusteella neuroverkko ja Kaiman-suodatus antoivat parhaat tulokset
24.	Young Wook Park	A Model for Dynamic Traffic Flow Guidance System. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.		1998	Dynaaminen reitinvalintaohjelmien kehittämiseen (systemioptimi)	Auotollille lähetetään esim. kännykkään lyhyen ajan ennusteeseen perustuva reitinvalintasuositus ja tieto nykyisistä liikenneolista.	Dynaaminen OD-matriisi, reaaliaikainen liikenteen generoitdata sekä jokaisen linkin ja reitin nykyinen matka-ajka	Reitinvalintaohdotuk		Testiattu simuloimalla	
25.	Satoshi Matsumura, Hitoshi Yamashita, Shusaku Iwaki, Hiroyuki Sugimura	Experimental Verification of Travel-Time Prediction Method. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea. 8 s.	Japani	1998	Matka-ajan ennustaminen kirjoittajien kehittämällä mallilla	Matka-ajka lasketaan joka linkille ja sen jälkeen jokaiselle reitille perustuen tilastoidun ja tämän hehkisen matka-ajan erotukseen	Yleinen matka-ajka (mitattiin testiajoneuvolla), tämän hetken matka-ajka (automaattinen ajoneuvotunnistus, erilaiset ilmatimet)	Matka-ajka		Testiattu Osakan ja Takatsukin kaupungin väliellä kahdeksalla reitillä kahdeksan päivän aikana 1997	Matka-ajan ennusteissa virheiden osuus (error rate) 11,4 %.

ENN. MENE- TELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
26. Tilasto	Toru Ootaka, Kana Hashiba	Travel Time Prediction Based on Pattern Extraction from Database. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea, 8 s.	Japani	1998	Matka-ajan ennustaminen kirjoitajien kehittämällä mallilla	Matka-alkaa arvioidaan liikennelantien perusteella. Ennuste tehdään usean muuttujan regressiolla.	Tietokanta liikennelantien, nykyinen matka-aika ja liikennemäärä	Matka-aika		Testattu simulomalla. (Data kuitenkin oikeaa liikennelantien Yokohamasta.)	Matka-ajan ennusteissa virheiden osuus (error rate) 7,74 %. Korrelaatiokerroin 0,93
27.	Takeshi Kurokawa, Keiichi Ogawa	A Study on Travel Time Prediction Method on Inter-City Expressways Using Traffic Capacity at the Bottleneck. Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea, 8 s.	Japani	1998	Tuottaa informaatiota ennustetuista matka-ajoista tienkäyttäjille	Keskimääräinen matka-aika ennustetaan erikseen ruuhkaantuneelle ja vapaalle virralle ajoneuvojen määrän ja pullonkaulan välityskyvyn avulla	Ajoneuvojen määrä kullakin tieosuudella, pullonkaulun välityskyky, nopeus, liikennemäärä ja -tiheys sekä tiegeomatria	Matka-aika		Testattu Torinien moottoritilla yhden päivän aikana 1995	Korrelaatiokerroin 0,96
28. Tekoäly	Youngchan Kim, Daeho Kim, Do Gyeong Kim	Estimation of Link Travel Time Using Vehicular Detection Devices in TRACS (Traffic Adaptive Control System). Konferenssi-cd, 5th World Congress on Intelligent Transport Systems, 12-16 October 1998, Seoul, Korea, 8 s.	Korea	1998	Estiä TRACS-systeemin avulla tehtäviä matka-akaennusteita	Tietoa liikenteestä TRACS-järjestelmän avulla. Ennustemallit sumeaa logiikkaan ja neuroverkkoihin perustuen	Liikennemäärä ja liikensuunnat	Sumeaa logiikkaa käytävässä mallissa matkanopeus ja neuroverkkomallissa matka-aika	TRACS on valvontajärjestelmän hallintaan tarkoitettu ohjelma	Testattu Soulessa	Neuroverkko: MSE 6,7-13 sumea logiikka MSE 20,6-38,2. Ennusteet parantivat kun käytettiin useampaa ilmaisinta.
29. Tekoäly	Habo Chen, Mark Dougherty, Howard Kirby	An Investigation of Detector Spacing and Forecasting Performance Using Neural Networks. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany, 7 s.	Britannia	1997	Ilmaisimen optimaalinen sijoittaminen neuroverkoilla lyhyen lyhyen ajan ennusteiden kannalta	Ilmaisimen sijoittelua arvioitu sekä simulomalla että oikealla maastoinstituutilla					Ilmaisimen hanteellinen välimatka on n. 1 km. Tihedämmällä sijoituksella ei useinkaan saavuteta suurta hyötyä kustannuksiin nähden.
30. Tilasto	Wolfgang Schober, Matthias Glatz	Assessing the Potential of Short-Term Prediction in a Dynamic Route Guidance System by Evaluating its Floating Car Data. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany, 8 s.	Saksa	1997	Vertailta pelkän historiatietä ja pohjalla tehtyjä matka-akaennusteita vertailupäivien tietojen avulla tehtyihin ennusteisiin	Kunakin reitin matka-aika ennustetaan sekä tilastotietojen että vertailupäivien tietojen perusteella.	Tilastotieto eri viikonpäivistä, tilannekijastot	Reittisuositus		Testattu Berliinissä 650 instrumentoidulla ajoneuvolla	Normalittaneissa 2-4% matka-ajan säästö vertailupäivä käyttäen.
31. Tilasto	Masato Iwasaki, Masuo Kotani, Kazuki Saito	Classification of Historical Mean Speed Pattern on a Motorway for Prediction of Near-Future Traffic Flow States. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany, 6 s.	Japani	1997	Tutkia, miten historiatieto voitaisiin hyönteillä lyhyen ajan ennusteiden laatuiseksi ja erityisesti ruuhkailtaneiden ennustamisessa.	Vaihtoehtoina luokitella data vuosittaisen 5 min nopeuden keskiarvon, päivätyypin (arki, la, pyhä), säätyypin tai liikenneolon (ruuhka, vapaa vira) mukaan	Liikennemäärä, raskaan liikenteen määrä, keski nopeus ja liikensuunnat				Ennusteita voitaisiin parantaa suodattamalla (smoothing), painottamalla uusia havaintoja ja päivittämällä tietokantaa
33.	Leonid Engelson	Recursive Forecasts of Travel Time for Congested Networks. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany, 7 s.	Ruotsi	1997	Rekursiivisten ennusteiden periaatteiden tarkastelu	Malli, joka ottaa huomioon kuljettajien reaktiot matka-akaennusteisiin. Tienkäyttäjille on kehitetty mallin rekursiivisuudesta, siis että heidän ei tarvitse huomioida toisten tienkäyttäjien reaktioita ennusteeseen vaan se on otettu huomioon mallissa. Mallit tienkäyttäjien käyttäytymiselle ja liikenneverkon toimintaa varten.	Liikennemäärä, raskaan liikenteen määrä, keski nopeus ja liikensuunnat	Käytettyjä mallia: Isolla verkolla monidimensioinen epälineaarinen systeemi, jonka ratkaiseminen vaikeaa.	Ei käytössä.		

ENN. MENETELMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
34.	Jean-Marc Morin, Joel Bomier, Raymond Feve	Travel Times on Inter-Urban Motorways: On-Line Estimation and Drivers Information Needs. Some Results in France. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany, 7 s.	Ranska	1997	Matka-ajkojen ennustaminen kolmella eri mallilla, tienkäyttäjien tietotarpeet	Kolme eri estimaattia todelliselle tienkäyttäjän kokemalle matka-ajalle: TPI=hetkellinen matka-ajalle (oletetaan, että liikennelämpö ei muuttomattomana) TPR=rekonstruoitu matka-ajalla (hetkellät perille saavuttien matka-ajalla) TPP=ennustettu matka-ajalla. Kolme ennustemallia: analyttinen malli, simuloimallit (MITHRASIMRES) ja varastomalli.	Analyttinen malli: induktiosimuukoilla 6 minuutin tiedot liikennemäärästä, nopeudesta ja varausasteesta. Testialueilla ilmaisimet n. 9 km välein.	Matka-ajka	Samat mallit eivät välttämättä sovi erityyppisille teille (matkan pituus ja tarkoituksen lisäksi) ja ilmajämsien ja opasteiden sijoitus ovat erilaisia)	Testiattu Ranskassa	Kaupunkien yhdistävillä teillä ei tarvita yhtä tarkkoja matkakaennusteita kuin kaupunkien teiverkolla. Analyttinen malli: TPI epävakaa ja ennustee huonoja. TPR keskivirhe 10 %, Simuloimallit: TPR keskivirhe 20 %, TPP keskivirhe 25-30 %.
35.	Akira Miyata, Kiyotaka Murakami, Takasama Akijama, Atsushi Abe	The Correction of the Forecasting Travel Time by Using AVI Data. Konferenssi-cd, 4th World Congress on Intelligent Transport Systems, 21-24 October 1997, Berlin, Germany, 7 s.	Japani	1997	Perinteisillä limaisilla kerätyn liikennetiedon avulla ennustettujen matka-ajkojen korjaaminen automaattisen ajoneuvon tunnistamisen avulla	Ajoneuvot tunnistetaan automaattisesti rekisterikilpien perusteella. Matka-ajalle otetaan päivitetään esimoidulla matka-ajolla.	Nopeus ilmaisimien avulla ja automaattisella ajoneuvotunnistuksella väillä.	Matka-ajka ja liikennemäärä tulo- ja poistumisrampin välillä.	Ongelmia ajoneuvojen automaattisessa tunnistamisessa, koska koko rekisterinumusta ei lueta (kaksi eri aubaa voidaan sekoittaa keskenään)	Testiattu Hanshinin moottoritieverkolla	
36. SI + sim	Jean-Marc Morin, Bernard Baradel, Joel Bomier	On-Line Short Term Simulation and Forecast of Motorway Traffic Patterns: Field Results Obtained on ASF Network in France. 3th World Congress on Intelligent Transport Systems, 14-18 October 1996, Orlando, USA, 9 s.	Ranska	1996	Liikennetianteiden ennustaminen	OD-matrisin ennustaminen (MITHRA) ja liikennevirran makroskooppinen simulointi (SIMRES)	MITHRA tarvitsee usean vuoden OD-matrisin (liikennelaskennat) ja lämmän hetken liikennemäärän lähtöliikkeen. SIMRES tarvitsee reaaliaikaista mittaustietoa liikennemäärästä, nopeudesta ja varausasteesta. Data kerättiin 49:ssä mittauspisteessä	Liikennetianteiluok a (värikoodattu kortti). Rinnakkain esitetään nykyilanne ja ennustettu liikennetiante (2 tunnin päästä).		Testiattu Ranskassa kesällä 1995 välillä Vienne-Montpellier/Lancon	Liikennemäärän 2 tunnin ennusteen suhteellinen nelikeskivirhe (MRQE = mean relative quadratic error) 24-28 %
38.	Matthew P. D'Angelo, Hatham M. Al-Deek, Morgan C. Wang	Travel-Time Prediction for Freeway Corridors. Transportation Research Record, No. 1676, s. 184-191.	USA	1999	Matka-ajkojen ennustaminen liikenneinformaatiota varten	Sekä yhden muuttujan (nopeus) että usean muuttujan (nopeus, liikennemäärä, varausaste) epälineaarinen atkasajamalli	Induktiosimuukoilla tiedot nopeudesta liikennemäärästä ja varausasteesta 30 s välein	Nopeuden ja sitä kautta tiejakson muuttuessa eli 5 min välein.	Puutteita liikenneolojen muuttuessa eli ruuhkan syntyessä ja purkauksessa. Ei ole testattu onnettomuustilanteissa.	Testiattu Orlandossa Floridassa 19 km tiejaksoilla	Yhden muuttujan malli: 98% ennusteista 10% virhemarginaalinh sisällä. Virhettä eniten ruuhkan syntyessä ja purkauksessa. Yhden muuttujan malli suoritui paremmin kuin usean muuttujan malli.
39.	Dongpo Park, Laurence R. Rillet	Forecasting Multiple-Period Freeway Link Travel Times Using Modular Neural Networks. Transportation Research Record, No. 1617, s. 163-170.	USA	1988	Matka-ajkojen ennustaminen liikenneinformaatiota varten	Tilastoidut matka-ajat jaetaan luokkiin valvontatonta ryhmittelytekniikkaa (tsoogonisoiva kartta ja sumea logiikka (fuzzy c-means clustering)) käyttäen ja jokaiselle luokalle luodaan oma neuuoverikko matka-ajkojen ennustamista varten	Liikennetianteiluokilla tiedot nopeudesta liikennemäärästä ja varausasteesta 30 s välein	Liikenne matk-ajat seuraaville 5-25 minuutille	Huomioitava ryhmittelyyn käytettävät parametrit ja niiden painoarvot, ryhmien määrä sekä ominaisuuksien erotelu (feature extraction)	Testiattu Houstonissa Texasissa 27,6 km tiejaksoilla. Dataa kerätty vuoden ajan.	Sumea logiikkaa käytävä ryhmittelytekniikka antoi lieman parempia tuloksia kuin SOM. Ennustevirhe sumeaa logiikkaa käyttäen 8,1-15,7 % (kasvaa ennustejakson pituuden kasvaessa)

ENN- MENE- TELIMÄ	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
40.	Trekoälly Satu Innamaa	Short-Term Prediction of Highway Travel Time Using MLP-Neural Networks. 8th World Congress on Intelligent Transport Systems, 30 Sept. - 4 Oct. 2001, Sydney, Australia, 12 s.	Suomi	2001	Salvittää, minkälaisilla syötöillä saadaan aikaseksi paras matka-alkaennuste ja miten järjestelmän rakenne vaikuttaa ennusteeseen	Kullekin osalinkeille ja osalinkeilyhdistelmille oma neuroverkko.	Korrelaation perusteella valittuja eri linkkien erilaisia keski- ja mediaanimatka-aikoja sekä matka-ajan keskihajontoja (kamerat, automaattinen ajoneuvon tunnistus) sekä liikennemääriä, keski nopeuksia ja keskihajontoja (LAM-pisteet)	Matka-alkaennuste kullekin osalinkeille ja osalinkeilyhdistelmille ja seuraavaan minuuttiin aikana keskihajontoja (kamerat, automaattinen ajoneuvon tunnistus) sekä liikennemääriä, keski nopeuksia ja keskihajontoja (LAM-pisteet)		Testiattu v4-llä välillä Lahti-Henola	Paras malli ennusti oikein 90% ajasta ruuhkailkenneessä. Mallien hyvyys vaihteli suunnan ja sen mukaan, oliko linkki jaettu osalinkeihin vai ei. Malli ylliarvot matka-aikoja hieman.
41.	Tilastö Nick Hounsell, Saeed Ishiaq	Journey Time Forecasting for Dynamic Route Guidance Systems. Proceedings of the Second DRIVE-II Workshop on Short-Term Traffic Forecasting, 1994/11 (Report intro-vvg 1994-19), s. 1-18.	U.K.	1994	Ennustaa matka-aika sekä normaalisia että häiriötilanteissa	Normaaleissa olosuhteissa akasjarjanalit (Holt-Winters, Kalman-suodatus, Box-Jenkins, Berlinin LISB). Häiriötilanteissa häiriö paikannetaan ja sen kesto ja vakavuus arvioidaan. Ennustetaan, mihin linkeihin häiriö vaikuttaa ja ennustetaan näiden matkat-ajat häiriön vakavuuden perusteella. Uuden mittauksen perusteella arvioidaan, onko tilanne normalisoitunut.	CONTRAMI- simulointiohjelmalla kootu tietokanta häiriötilanteista, tietoa liikennetilanteesta tietyn välialojen	Linkin matka-aika		Mallia testattu vertaamalla ennustettuja tuloksia simuloimalla saatuihin tuloksiin	Normaaleissa olosuhteissa parhaiten toimi Kalman-suodatus. Häiriötilanteissa matka-alkaennusteissa MAPE 47-68% (malli ylliarvot matka-aikaa). Ennustettaessa linkkien määrää, joihin häiriö vaikuttaa, MAPE oli 31-55%. Virheprosentti aleni, kun ennustetta korjattiin mittaus tuloksiin (matka-aika edellisellä aika-asteella) perustuen.
42.	Tilasto Filippo Logi, Dieter Wild, Dieter Wild	An Intelligent Predictor for Urban Traffic. Pattern-Based Forecasting. Proceedings of the Second Meeting of the Euro Working Group on Urban Traffic and Transportation, 15-17 September, 1993, Paris, France (Access Intrets no 38), 1994/04, S. 83-109.	Saksa	1994	Lyhyen ajan ennusteden tuottaminen tilastotiedon pohjalta	Liikennetilanteet luokitellaan viikonpäivän ja muiden ympäristömuuttujien mukaan ja ennusteet tehdään vertaamalla nykytilannetta näihin luokkiin.	Liikennemäärä	Liikennemäärä halutulla linkeillä	Sopii kaupunkiverkolle ja kaupunkien välille. Ennusteiden onnistuminen riippuu tietokannan täydellisyydestä (kaikki eri tilanteet mukana), ryhmittelyn onnistumisesta ja ruuhkan toistuvuudesta.	Testiattu Köhmissä 1993 ja 1994 paremmin kuin vertailuna käytetyt triviaali- (tietokannan keskiarvoon perustuva) ja lukuva keskiarvo-malli. RMSE 2,8-4,9 (4,5 min - 1 h).	Pidempiakaisilla (yli 15 min) ennusteilla kehitetty malli ennusti paremmin kuin vertailuna käytetyt triviaali- (tietokannan keskiarvoon perustuva) ja lukuva keskiarvo-malli. RMSE 2,8-4,9 (4,5 min - 1 h).
43.	Y.S. Chen, H.J.M. van Groi, Ch.D.R. Lindveld, P. Mijler, S. Smulders	Link/Network Performance Models: Results in DYNA. Proceedings of the Second DRIVE-II Workshop on Short-Term Traffic Forecasting, 1994/11 (Report intro-vvg 1994-19), s. 153-74.	Hollanti	1994	Lyhyen ajan liikenne-ennusteden tuottaminen, erityisnäkökulma verkkotasolla	Ruuhkan todennäköisyyttä arvioidaan liikennemäärän tai -tiheyden perusteella ja huomioidaan kapasiteetin aleneminen ruuhan takia	250 mittauspistettä, joilla saadaan liikennemäärä ja nopeus sekä näistä johdettu liikennetheys	Nopeus, ruuhkan todennäköisyys	Sopii keskikokoiselle verkolle.	Testiattu Rotterdamin ympäristössä toukokuussa 1994	Ruuhkatomana aikana ennusteessa on viivettä. Ennusteet olivat kuitenkin hieman parempia ruuhkatomana aikana kuin ruuhkaissa.

ENN- MENE- TELMA	TEKIJÄ(T)	LÄHDE	MAA	VUOSI	TAVOITE	TOIMINTA	INPUT	OUTPUT	MALLIN RAJOITUKSET	KÄYTTÖSSÄ?	TULOKSET
44.	Tilasto, sij + sim Ch.D.R., Lindveld, E.P., Kroes, H. de Ruiter	DYNA: Real Time Congestion Prediction: Colloquium Vervoersplanologisch Spuurwerk 1992. Innovatie in Verkeer en Vervoer. 26-27 November 1992. Rotterdam. Deel III. s. 875-893.	Hollanti	1992	Liikennelliantienojen ja matka- alokojen ennustaminen kaupunkien välisellä moottoritieverkolla	Tilastollinen malli (STA) liikennedatan suodatukseen ja hyvin lyhyen ajan (1-15 min) ennusteiden tekoon. Dynaaminen liikenteen sijoittelumalli (DTA) lyhyen ajan (15-60 min) ennusteiden tekoon. Reaaliaikainen OD-matriisin estimointimalli (ODME)	Liikennemäärä, keskinopeus ja ennusteiden välinen välitietä n. 3 km. Tilastotietoa liikenteestä (tiasioitua OD-matriisil), tietoa liikenneverkon infrastruktuurista, tietoa onnettomuuksista, tietoa tietoisista tapahtumista jne.	Linkkihoitainen tieto liikennemäärästä, matka-ajasta ja ennusteiden välinen välitietä (on/ei) autoliijan reitinvaihtoa DTA tekee ennusteen hitaasti ja vaatii OD- matriisin lähtötiedotukseen.	STA sopii vain hyvin lyhyen ajan ennusteisiin, koska se ei ota huomioon autoliijan reitinvaihtoa DTA tekee ennusteen hitaasti ja vaatii OD- matriisin lähtötiedotukseen.	Testataan Rotterdamin ympäristössä.	
45.		http://www.sytadin.tm.fr/	Ranska	2001	Matka-ajokojen estimointi liikennedeksi SIER	Mitrausten perusteella arvoidaan onko liikenne keskimääräistä vai tavallista vilkkaampaa tai vähäisempää. SIER- indeksi kertoo, kuinka paljon vepaasta virrasta poiketaan.	Liikennetiedot (nopeus, liikennemäärä) 6 minuutin välein 3000 laskentapistettä, jonka vanaisempaa, vilkkaampaa, erittäin perusteella lasketaan "liikennetietoluokkaa" (SIER-index). Tietokanta SIER-indeksin arvosta ja vaihteluista useilla kuukausilla.	Tieto siitä, onko liikenne keskimääräistä, vanaisempaa, vilkkaampaa, erittäin perusteella lasketaan "liikennetietoluokkaa" (SIER-index). Tietokanta SIER-indeksin arvosta ja vaihteluista useilla kuukausilla.	Käytössä Pariisin alueen pääteverkolla		
46.	Tilasto, tekoäly	Traffic Volume Time-Series Analysis According to the Type of Road Use. Computer-Aided Civil and Infrastructure Engineering, 2000/09. s. 365-373. Sharma, Phil Osborne, Itekhari Kalyar	Kanada	2000	Neuroverkon ja autoregressiivinen käyttö liikennemäärän ennustamisessa.	Tietä on jaettu viiteen tyyppiin matkan tarkoituksen (oma- ja työmatkojen osuus) ja matkojen pituuden mukaan ja kalleille luokille on tehty oma malli.	Liikennemäärä	Kolmeotista edelleen päivän liikenteen perusteella ennustettiin seuraavan päivän liikennemäärä.		Testattu Albertassa	Neuroverkoennusteet onnistuivat autoregressiivisella paremmin. Ennusteet onnistuivat paremmin säännöllistä työmääräliikennettä välittävillä teillä. Keskimääräinen virheiden osuus (error rate) oli autoregressiivisella 6.39-15.62 % ja neuroverkolla 5.87-13.53 %. Maksimirviheet olivat 22.8 % ja 164 %. mutta 95 %:n virheet olivat 15- 45 % luokkaa.
47.	Sij + sim F. Meissner, M. Cremer	The Role of Macroscopic Simulation for Proper Route-Guidance Decisions. Proceedings of the Prometheus Workshop on Traffic Related Simulation, December 1992, Stuttgart. s. 38-53.	Saksa	1992	Lyhyen ajan ennusteet reititneuvontaa varten	Ennusteet tehdään makroskooppisella simulointimallilla SIMONElla (Simulation of Motorway Networks)	Liikennetietoisuus, keskinopeus, liikennemäärä jokaiselle simulointimallin leijaksoilla (joiden pituus on 300-600m)	Kokonaismatka, kokonaismatka- aika, kokonaisviritys, yksittäisen reitin matka- aika ja politoarveen kulutus			Reititneuvontaa käytettiin näkökulmasta, koska tällöin autoliijat kokevat opastuksen hyödylliseksi. Joissain tilanteissa käytäjäoptimi voi joutaa ongelmaan ja tämän takia reititneuvontaa täytyy kontrolloida myös systeemiopintoin avulla.
48.	Tilasto	Traffic Control and Communication Centre. Leading the way in traffic management. VicRoads. Sähköpostitiedustelu Steve Beanilta VicRoadsilta. VicRoadsin Internet-sivut http://www.vicroads.vic.gov.au/	Australia	2001	Matka-ajokojen ennustaminen liikenneinformaatiota varten	Matka-ajokojen moottoritieosuksilla estimoidaan mitattu liikennemäärään ja nopeuteen perustuen. Matka-ajat esitetään liittymävälittain informaatiolla, jolla tiedotetaan myös onnettomuuksista, tietoisista ja huonosta kelistä. Värkkoodilla kerrotaan myös onko liikennettä tavallista enemmän tai vähemmän.	Liikennemäärä ja nopeudet induktiosimulointia ja videokameroina. Tietoa kerätään 500-750 m vällein.	Matka-ajokojen liittymävälille	Toimitut Australian Melbournin ympäristössä maaliskuusta 1998.		Matka-ajoinformaatiota pyritään alle kahden minuutin tarkkuuteen ja usein tulokset ovat tätä parempia.



ISSN 1457-9871
ISBN 951-726-829-7
TIEH 3200719