

Innotiku Pilotti C

Liikkuvan videokuvan analysointi

Loppuraportti

Sisällysluettelo

1 Tiivistelmä	3
2 Selvitystyön taustat ja tavoitteet	3
2.1 Pilotin taustat	3
2.2 Pilotin tavoitteet.....	4
3 Järjestelmän kuvaus	5
3.1 Yleiskuvaus	5
3.2 Toiminnallinen kuvaus	6
3.2.1 Keskitetty videoanalyysi	6
3.2.2 Hajautettu videoanalyysi	6
3.2.3 Manuaalinen videoanalyysi	7
4 Pilotin tulokset ja johtopäätelmät	8
4.1 Toteutuneet tekniset tuotokset ja todetut haasteet	8
4.1.1 Tiedon keruu	8
4.1.2 Tiedon siirto	10
4.1.3 Tiedon käsittely ja integroinnit	11
4.1.3.1 Tiedon käsittely	11
4.1.3.2 Integroinnit	11
4.1.4 Tiedon tallennus (Analytiikkatietokanta)	11
4.1.5 Tiedon käyttö ja visualisointi	12
4.1.6 Videoanalyysimenetelmät	12
4.1.6.1 MUVIS.....	12
4.1.6.2 Eutecus	13
4.1.6.3 Vatic	14
4.2 Eri analytiikkamallien ja tulosten vertailua	15
4.2.1 Miten vertailut tehtiin	15
4.2.2 MUVIS1-mallin analyysi	17
4.2.3 MUVIS2-mallin analyysi	19
4.3 Vastaukset asiakkaan vaatimuksiin	20
4.4 Johtopäätökset.....	25
4.5 Jatkokehitysideoita.....	26
4.5.1 Jatkokehitys – potentiaalisia käyttötapauksia	26
4.5.2 Jatkokehitys – järjestelmän kehittäminen	32
4.5.3 Ratkaisun joukkoistamismahdollisuudet	36
4.6 Loppusanat	37
5 Termit ja lyhenteet.....	38
6 Lähdeluettelo	39
7 Muutoshistoria.....	40

1 Tiivistelmä

Tavoitteena oli pilotoida liikkuvilla kameroilla kuvatun videomateriaalin ja sille tehdyn videoanalyysin soveltuvuutta Helsingin olosuhteissa asiakkaan tarpeisiin Tiedon ehdottamien kumppanien tuotteita käyttäen. Käyttötapauksiksi valittiin liikenne- ja ihmisvirtojen ennustaminen.

Tieto toteutti järjestelmän, jonka avulla projektin yhteydessä kerätty videomateriaali saatiin kerättyä, analysoitua ja visualisoitua. Lisäksi arvioitiin eri analysointimenetelmien käyttökelpoisuus ja laatu. Mallien arviointikäyttöön saatiin yhteensä noin 60 000 havaintoa.

Järjestelmä tunnisti ja luokitteli kuvissa esiintyneet henkilöautot parhaimmillaan 95 %:n tarkkuudella. Muiden kohteiden osalta tunnistamisprosentit jäivät alhaisemmiksi.

Tulokset olivat mielenkiintoisia ja varsin rohkaisevia käytännön sovellutusten suhteen. Vaikka parhaimmillaan tulokset näyttivät hyvältä, niin käytännön kannalta videoanalyysimallit vaativat kuitenkin vielä tilannekuvakäyttöä ajatellen jatkokehitystä. Mahdollisuus opettaa analytiikkaa haluttuihin käyttötarkoituksiin lisää tulosten osumatarkkuutta ja koko ratkaisun käyttömahdollisuuksia. Tällä hetkellä teknologia ei ole vielä aivan riittävän kypsä täysin reaaliaikaiseen videoanalytiikkaan suurille määrille tietolähteitä johtuen tiedonsiirron haasteista ja suuresta datan prosessointitarpeesta. Reaaliaikaisuudesta tingittäessä ratkaisu on toteutuskelpoinen.

Liikkuvan kuvan analytiikan hyödyntämisessä nähtiin kaksi pääkäyttötapausryhmää: 1) Historiatietoon perustuvaa analysointia suunnittelun ja päätöksenteon tueksi (analytiikkaa kerätään ei-reaaliaikaisesti pidemmän aikaa), sekä 2) reaaliaikaista tietoa poikkeustilanteiden tilannekuvan selvittämiseksi paikallisesti.

Ehdotamme, että pilotin jälkeen pyritään toteuttamaan ekosysteemi (analytiikkapilvi), jonne videota/kuvaa voidaan kerätä; jossa sitä voidaan analysoida ja josta analytiikkatietoa voi tarjota reaaliaikaisesti tietoa tarvitseville. Analytiikkapilven toiminnallisiin kuuluu sen hallinta ja operointi, sekä analytiikan opettaminen ja konfigurointi. Analytiikkapilven kautta voisi myös jakaa viranomaisdataa avoimien ja standardoitujen rajapintojen kautta kaikille tarvitseville.

2 Selvitystyön taustat ja tavoitteet


2.1 Pilotin taustat

Helsingin kaupunki haluaa edistää liikenteen reaaliaikaisen tilannekuvan kehitystä. Liikenteen tilannekuva on ajantasainen näkymä liikenteeseen, väyliin, kulkuvälineiden sijaintiin sekä olosuhteisiin liittyvään tietoon. Liikenteen tilannekuva voi olla esim. ajantasainen graafinen näkymä liikennelaitteisiin ja liikennettä kuvaaviin tunnuslukuihin, ja kertoa mm. lyhyen ajan ennusteen liikennemäärästä, liikenteen sujuvuudesta, häiriöistä, täsmällisyydestä sekä vallitsevista olosuhteista. Tilannekuvasta voidaan välittää tietoa loppukäyttäjille, palveluntarjoajille ja muille tiedon hyödyntäjille. Tilannekuvaan perustuvalla tilannetiedolla on keskeinen tehtävä arjen matkojen ja kuljetusten sujuvuuden ja ennustettavuuden sekä liikenteen turvallisuuden edistämiseksi.

Ajantasainen tilannekuva tukee suurta joukkoa liikenteen viranomais- ja kaupallisia palveluita. Näitä ovat mm. liikenteen ohjauksen, kysynnän ohjauksen, häiriöiden hallinnan ja turvallisuustiedotuksen palvelut. Laadukas tilannekuva paitsi mahdollistaa nämä palvelut myös

lisää niiden vaikuttavuutta. Tilannekuvan laadun parantamisen investointikustannusten odotetaan palautuvan onnettomuus-, ruuhka- ja päästökustannusten vähenemisen myötä sekä uutena liiketoimintana. Tilannekuva mahdollistaa häiriötilanteisiin puuttumisen häiriötilanteiden nopean tunnistamisen, paikallistamisen ja ennustamisen ansiosta [1].

Alla olevassa kuvassa (Kuva 1) on esitetty, miten kameroiden tuottaman tiedon analyysi palvelee laajempaa liikenteen tilannekuvan muodostamista ja siihen liittyviä tilannekuvapalveluita.



Kuva 1. Liikenteen tilannekuva.

Yksi tietolähdekanava on liikennettä kuvaavien videokameroiden tuottaman kuvan analysointi liikennettä kuvaavaksi metadatakksi. Helsingin kaupunki haluaa pilottihankkeiden avulla hankkia tietoa erilaisten videokuvaan perustuvien analysointimenetelmien toimivuudesta Helsingin olosuhteissa.

Tämän pilotin, jossa Tieto on mukana, tarkoituksena on tukea liikenteen reaaliaikaisen tilannekuvan valvontaa ja ennustettavuutta ja se keskittyy Kuva 1 esitettyyn kohtaan "C", eli liikkuvan videokuvan analysointiin.

2.2 Pilotin tavoitteet

Pilotin ensisijaisena tavoitteena on kerätä tietoa videokuvaan perustuvien analysointimenetelmien toimivuudesta Helsingin olosuhteissa. Pilotissa on käytetty Tiedon ehdottamien kumppanien videoanalytiikkatuotteita.

Projektin toisena tavoitteena oli pilotoida videoanalytiikan toimivuutta kahdella esimerkkikäyttötapauksella:

- Liikennevirtojen ennustaminen
- Ihmisvirtojen ennustaminen


Lisäksi pilotin aikana tulee löytää vastaukset asiakkaan toiminnallisiin ja teknisiin vaatimuksiin, jotka on listattu kappaleessa "4.3, Vastaukset asiakkaan vaatimuksiin".

3 Järjestelmän kuvaus

Kappaleessa 3.1 kuvataan ratkaisu yleisellä tasolla ja kappaleessa 3.2 on kerrottu ratkaisun toiminnallisuus.

3.1 Yleiskuvaus

Tavoitteena oli rakentaa järjestelmä, joka pystyy keräämään liikkuvaa videokuvaa, analysoimaan sen ja visualisoimaan tiedon käyttötapauksien mukaisesti. Pilotissa käytetyn järjestelmän yleiskuvaus on esitetty alla (Kuva 2. Yleinen arkkitehtuuri).



Kuva 2. Yleinen arkkitehtuuri

Alimmalla tasolla on "Tiedon keruu"-kerros, jonka päätehtävänä on kerätä videokuvaa, sijaintitietoa ja muuta mahdollista käyttötapauksissa tarvittavaa dataa (myös ulkoisista lähteistä) halutussa muodossa.

Kerätty data siirretään "Tiedon käsittely ja integrointi"-kerrokseen eri tiedonsiirtomenetelmin (Ethernet, WiFi, 3G, 4G, 5G, yms.), jossa se prosessoidaan tietomallin mukaiseksi ja tallennetaan tietokantaan ("Tiedon tallennus").

"Tiedon käyttö"-tasolla on mahdollisuus lisälogiikkaan tiedon rikastamiseksi, tiedon visualisointia, ja sen hyödyntämistä asiakkaan liiketoimintaprosesseissa.

Edellä mainittujen kerrosten lisäksi ratkaisun keskeisenä toiminnallisena elementtinä on **videoanalytiikka** (kuvassa punaisin reunuksin esitetyt laatikot), jonka avulla kuvattu videomateriaali analysoidaan.


3.2 Toiminnallinen kuvaus

Järjestelmän tarkoitus on tarjota laadukasta analytiikkatietoa ja muuta metadataa asiakkaan käyttötapausten toteuttamiseksi. Videoanalytiikka on tärkein osa ratkaisua ja siksi haluamme esitellä koko ratkaisun toiminnallisuus videoanalytiikan näkökulmasta.

Pilotissa käytimme kolmea eri ratkaisua videokuvien analysoimiseksi (Kuva 2): Keskitettyä videoanalytiikkaa, hajautettua videoanalytiikkaa ja manuaalista videoanalytiikkaa. Manuaalinen videoanalysointi tehtiin pelkästään validoimaan kahden ensimmäisen ratkaisun kyvykkyys löytää haluttu informaatio videoilta.

3.2.1 Keskitetty videoanalyysi

Tässä ratkaisussa (Kuva 3) liikkuvasta ajoneuvosta kuvattu videomateriaali (Kuvassa numeroitu ympyrä 1) siirretään keskitetysti palvelimelle (2), jossa ne analysoidaan (3). Analytiikan tuottama metadata muokataan tietomallin mukaiseksi (4) ja tallennetaan tietokantaan yhdessä sijaintitiedon kanssa (5). Tämän jälkeen analyysin tuloksia voi tarkastella visualisointityökalujen avulla (6).




Kuva 3. Keskitetyn videoanalyysin yleiskuva.

3.2.2 Hajautettu videoanalyysi

Tässä ratkaisussa ajatuksena on siirtää videoanalytiikka keskitetyltä palvelimelta lähelle kuvanlähdettä ja samalla hajauttaa videoanalytiikan vaatimaa suurta laskentatarvetta useammalle yksikölle (Kuva 4).

Toiminnollisuus menee seuraavasti: Kuvattu video (1) syötetään suoraan analytiikkayksikölle, joka analysoi videon reaaliajassa (2). Analysoitu metadata siirretään (3) palvelimelle jatkokäsittelyyn (4) ja tallennettavaksi tietovarastoon (5), josta sitä voidaan visualisoida ja käyttää syötteenä haluttuihin prosesseihin (6). Ajoneuvojoukolta (fleet) ei siirretä videota keskitetylle palvelimelle – vain haluttu metadata.




Kuva 4. Hajautetun videoanalyysin yleiskuva.

3.2.3 Manuaalinen videoanalyysi

Manuaalinen videoanalyysi tehdään käsin validointiin valitulle videomateriaalille ja näin saatua metadataa käytetään avuksi vertailtaessa muiden menetelmien toimivuutta (validointi). Ratkaisu on esitetty alla olevassa kuvassa (Kuva 5).

Validointiin varta vasten kerätyt videot (1) siirretään palvelimelle (2), jossa ne analysoidaan (3). Manuaalinen analysointi tarkoittaa käytännössä videokuvien kohteiden ja niiden attribuuttien merkitsemistä käsin kuvakohtaisesti (annotointi). Käsin annotoitujen videoiden metadata siirretään jatkoprosessointiin (4), tietovarastoon (5) ja on sieltä visualisoitavissa muun metadatan tavoin (6).



Kuva 5. Manuaalisen videoanalyysiratkaisun yleiskuva.

Tiedon siirrolla ei tässä vaihtoehdossa ole merkittävää roolia – videot siirretään Annotointi-palvelimelle tarpeen mukaan. Manuaalisella analyysillä tuotettua metadataa yhdessä kerättyjen videoiden kanssa voi käyttää koneellisten analyysiratkaisujen opettamiseen.

4 Pilotin tulokset ja johtopäätelmät

Tässä luvussa kerrotaan minkälaisia tuloksia saavutettiin, mitä pilotin aikana toteutettiin, mitä haasteita kohdattiin ja millaisia johtopäätöksiä tuloksista tehtiin.

4.1 Toteutuneet tekniset tuotokset ja todetut haasteet

Pilotin tuotoksena toteutettiin järjestelmä, jonka avulla kerättiin tarvittava videomateriaali, analysoitiin se, tallennettiin analytiikan tuotokset tietojärjestelmään ja visualisoitiin informaatiota käyttötapausten mukaisesti.

Tässä kappaleessa on kuvattu mitä tuloksia saavutimme ja millaisia haasteita kohtasimme Helsingin olosuhteissa. Haasteiden yhteydessä on lisäksi kerrottu miten kyseistä haastetta voidaan taklata välittömästi tai mahdollisesti vasta tulevaisuudessa.

4.1.1 Tiedon keruu

Videomateriaalin ja sijaintitiedon keruu onnistui hyvin käyttöön valitulla laitteistolla (Android älypuhelin) ja siihen toteutetulla ohjelmistolla. Tiedon keruu maanteilla on kohtalaisen yksinkertaista kameran kattaessa yleensä kaiken tarpeellisen. Kaupunkialueella kuvan sisältö monimuotoistuu, eli siihen tulee maantien verrattuna mukaan mm. useampia kaistoja, pysäköintipaikat väylän varrella, suurempi joukko risteysia, yms., ja muutenkin liikennemäärät kaikkien kohteiden osalta kasvavat. Käytännössä kuitenkin tämä lisäinformaatio ei vaikuta varsinaiseen tiedonkeruuseen muuten kuin että suuren informaatiomäärän vuoksi videon

laatuvaatimukset kasvavat (mm. valovoima, optiikan laatu, resoluutio, bittivirta ja näytteenottotaajuus).

Alla olevassa taulukossa on listattu toteutuksen aikana ja videomateriaalin keruun yhteydessä vastaan tulleita tiedonkeruun haasteita.

Haaste	Ratkaisu haasteeseen
Videokuvan huono laatu. Kun videokuva on kerätty, sen laadun parantaminen on haastavaa ja joskus jopa mahdotonta. Lisäprosessointi tuo lisäkustannuksia ja viiveitä datan käsittelyyn.	Käytettävän kaluston hinta-laatu-suhde pitää valita käyttötarpeen ja budjetin mukaan. Kuvan laatuvaatimusten kasvaessa myös laitteiston hinta kasvaa.
Kulkuneuvon ulkopuoliset esteet vastaan tulevan kaistan ja kameran välissä. Esimerkiksi puistoteiden puut ajoväylien välissä tai kookkaat ajoneuvot blokkavat näkyvyyden eteenpäin tai muille kaistoille	Tähän ei käytännössä ole ratkaisua – ”varjoalueita” analysoitavien kohteiden suhteen tulee videokuvassa aina olemaan. Kaupunkisuunnittelua mm. puistobulevardien osalta ei kannata tehdä videoanalytiikan ehdoilla, vaan kaupunkilaisten viihtyvyyden kannalta.
Kameran tarkennus tarkentaa väärällä tavalla. Esimerkiksi sateella kuva tarkentuu helposti tuulilasin sadepisaroihin tai sama ongelma astuu esiin myös tuulilasin likaantuessa riittävän paljon. Myös valaistuksesta johtuvat (kirkas ilma tai pimeällä) heijastumat voivat pilata kohdistuksen.	Kameran tulee kiinnittää siten, että heijastumat minimoituvat. Tuulilasi on myös pidettävä puhtaana. Kameran automaattisen kohdistuksen vaihtaminen kiinteään kohdistukseen (äärettömään) vähentää parhaiten tätä ongelmaa.
Sijaintitiedon puuttuminen. Tätä esiintyy GPS-katveissa ja mahdollisesti kuvaamisen alussa ennen kuin GPS-signaali on kunnossa.	Ohjelmiston tulee osata hoitaa puuttuva GPS-tieto arvioimalla sijainti edellisen/seuraavan tarjolla olevan tiedon perusteella. Signaaliyhteyden nopeaan luomiseen voidaan vaikuttaa laadukkaalla GPS-piirillä ja esim. avusteisella GPS-yhteyden konfiguroinnilla matkapuhelinverkon avulla (A-GPS, [2])
Epätasainen tiestö ja siitä johtuva häiriö kameraan.	Hyvä laitteiston kiinnitys ja laadukas optinen kuvanvakain auttavat tähän. Käyttämässämme laitteissa värinää sai vähennettyä huomattavasti mekaanisesti asentamalla kännykkäteline siten, että se nojasi sopivasti taustapeiliin.
Asentaminen kuvaavaan kulkuneuvoon siten, että kulkuneuvon laitteet eivät estä näkyvyyttä, kuvaan ei tule heijastumia, eikä	Asennus riippuu kulkuneuvosta ja laitteistosta – yleensä sopiva paikka laitteelle löytyy, mutta joskus voi joutua keksimään erikoisratkaisuja ongelmien ratkaisemiseksi

kuvauslaitteisto haittaa kuljettajan tai matkustajien näkyvyyttä.	tai tinkimään esimerkiksi matkustajien näkyvyydestä.
Kontrastivaihtelut. Kontrastivaihteluita esiintyy mm. tunneleihin menosta ja sieltä poistumisesta ja vaikkapa suunnan muuttuessa aurinkoon päin tai auringosta pois päin. Aamulla/illalla myös vasta-aurinko luo lisähaasteita kuvan laadulle.	Tätä voidaan korjata mm. lipoilla, vastavalosuojilla ja suodattimilla ja opettamalla analytiikka eri kontrastitilanteisiin.
Pimeäkuvaus. Kuvan laatu kärsii huomattavasti valonpuutteesta ja analytiikan haasteet kasvavat.	Kulkuneuvon hyvät ajovalot ja katuvalot auttavat tilannetta. Videoanalytiikan opettaminen pimeäolosuhteisiin suuremman materiaalin avulla parantaa analytiikan tuloksia..

4.1.2 Tiedon siirto

Videot ja metadata tulee siirtää kuvauslaitteistosta tietojärjestelmään, jotta niitä voidaan hyödyntää käyttötapauksissa. Siirrettävän tiedon määrä moninkertaistuu jos siirrettävän tiedon joukossa on videokuvaa (keskitetty analytiikka, validointitarve, algoritmien inkrementaalinen opetus, jne.). Nykyinen 2G, 3G ja jopa 4G eivät käytännössä riitä luotettavaan videokuvan siirtoon reaaliaikaisesti mobiiliverkon yli. 4G parhaimmillaan (lähellä tukiasemaa ja vähän muita käyttäjiä) riittää ja jos videon resoluutiota/laatua heikennetään, niin videon siirto saadaan toimimaan 4G verkon yli. Videon laadusta tingittäessä analytiikan laatu puolestaan heikkenee ja saattaa vaarantaa koko käyttötapauksen merkityksen. Videon laadun ja analytiikan laadun korrelointia ei tutkittu pilotin aikana, vaan se kuuluu jatkokehitysideoihin.

Käytännössä vasta 5G teknologia mahdollistaa videon reaaliaikaisen siirron ja sitä kannattaakin pilotoida heti kun 5G verkkoja on tarjolla (mahdollinen pilotti jonkin teleoperaattorin kanssa).

WiFi-verkon yli dataa voidaan siirtää (myös video), mutta kattavuus on rajoitettua. Jos esimerkiksi kamera on kiinnitetty bussiin, niin reitin varrella ei WiFi-verkkoja juurikaan voi hyödyntää – varikolla/päätepysäkeillä täyttyneet puskurit voitaisiin tyhjentää WiFi-verkossa, mutta tällöin joudutaan tinkimään reaaliaikaisuudesta.

Tiedon siirron haasteet:

Haaste	Ratkaisu haasteeseen
Siirtonopeus ilmarajapinnassa (mobiiliverkko)	2G, 3G ja käytännön tilanteissa myös 4G eivät riitä reaaliaikaisen videokuvan siirtoon. Mobiiliverkkojen kapasiteetti videosiirtoon tulee käytännössä riittäväksi vasta 5G-teknologian myötä
WiFi peitto	WiFi:ä voidaan käyttää hyödyksi paikallisesti, mutta jatkuvaan tiedonsiirtoon halutun reitin varrella se ei kykene

Pilotissa videot puskuroitiin puhelimen muistiin ja ulkoiselle kiintolevylle ja siirrettiin analysoitavaksi manuaalisesti palvelimelle.

4.1.3 Tiedon käsittely ja integroinnit

4.1.3.1 Tiedon käsittely

Pilotissa käytettiin useita tietolähteitä (Kamera, GPS, Eutecus, Vatic) ja sitä myötä myös eri tietoformaatteja oli useita ja tiedon tallentaminen määritellyn tietomalliin vaati prosessointia.

Toteutimme joukon Java-prosesseja, jotka noutivat, prosessoivat ja tallensivat dataa tietokantaan GPS-laitteelta, MUVIS-palvelusta, Eutecus-laitteesta ja Vatic annotointi-ratkaisusta.

Haasteet tiedon käsittelyssä:

Haaste	Ratkaisu haasteeseen
Tiedon synkronointi	Videokuva, sijaintitieto ja sensorit tulee pystyä synkronoimaan riittävän tarkasti, jotta tuloksia voi tulkita luotettavasti. Erillisillä sovelluksilla kerättävät tiedot (video, GPS, sensorit) voi olla haastavaa synkronoida jälkikäteen. Ohjelmisto, joka hoitaa kaiken tiedon keräyksen ja data synkronoinnin ratkaisee tämän haasteen.
Suuret tietomassat	Jos dataa tuottavien lähteiden määrä kasvaa suureksi (suuri ajoneuvojoukko ja joukkoistaminen), niin järjestelmää pitää pystyä skaalaamaan ylöspäin helposti. Hyvän arkkitehtuurisuunnittelun jälkeen tämä ei ole muuta kuin budjetointiasia.

4.1.3.2 Integroinnit

Erilaisia rajapintoja järjestelmässä on monia, mutta pilotin aikatauluraamien sisään mahtui vain välttämättömimmät, eli integroinnit analytiikkaratkaisuihin (MUVIS, Eutecus ja Vatic).

Rajapinnat sisäänpäin ulkoisista tietolähteistä ja rajapinta ulospäin muille tiedonkäyttäjille analytiikkatietokannasta ei kuulunut pilotin sisältöön. Ulkoisten tietolähteiden integroiminen ei ole teknisesti ongelmallista jos vain oikeaa tietoa on saatavilla joko julkisena tai maksullisena palveluna. Analytiikkatiedon julkaiseminen palveluna ulkoisijoille toimijoille on toteutettavissa ja rajapinnaksi suosittelemme REST-protokollaa.

4.1.4 Tiedon tallennus (Analytiikkatietokanta)

Kaikki metadata talletettiin relaatiotietokantaan MS SQL-Server-tietokantaan, joka pystytettiin MS Azure virtuaalipalvelimelle.

Tietomäärien kasvaessa voidaan alkaa käyttämään Big Data-järjestelmää, joka kykenee käsittelemään suuria tietomääriä ja mahdollistaa suurten tietomäärien analytiikan ja visualisoinnin.

Pilotin aikana ei esiintynyt ongelmia/haasteita tiedon tallentamisen yhteydessä.

4.1.5 Tiedon käyttö ja visualisointi


Pilotissa kerättyä videoanalytiikan tuottamaa metadataa ei syötetty sisäisille eikä ulkoisille prosesseille, vaan tyydyimme pelkästään visualisoimaan sitä hyväksi todetulla raportointiratkaisulla (Tableau, [3]). Visualisointityökalu mahdollistaa tulosten tarkastelun interaktiivisesti, jolloin on helpompi tutkia mallien tarkkuuteen ja liikenteen määrään liittyviä tekijöitä.

4.1.6 Videoanalyysimenetelmät

Pilotissa käytettiin kolmea eri analysointiratkaisua: Keskitetty videoanalyysi (MUVIS), hajautettu videoanalyysi (Eutecus) ja käsin tehty videoanalyysi (Vatic).

4.1.6.1 MUVIS

MUVIS-ratkaisussa käytetyt konvoluutioverkot ovat nykyään huipputeknologiaa audiovisuaalisissa tunnistustehtävissä (Kuva 6). Syviä konvoluutioverkkoja käytetään menestyksekkäästi monissa tällaisissa koneoppimistehtävissä, kuten kohteentunnistuksessa ja puheen kääntämisessä.



Kuva 6. Konvoluutioverkko.

Tässä pilotissa käytimme 16-kerroksista VGG-mallia [4], joka oli ennalta koulutettu käyttäen 1000 luokan ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2012 [5] -tietoaainestoa ja lisäksi koulutettu 12 kiinnostavan luokan (pyörä, henkilö, vene, bussi, auto, juna, moottoripyörä, puu, lintu, kissa, koira, lentokone) osalta pilottihankkeen kohteentunnistustulosten kohentamiseksi. Mallin lisäkoulutuksessa verkkojen syötteenä käytettiin 224x224 RGB-kuvia, jotka oli esikäsitelty vähentämällä koko tietokannan keskimääräinen RGB-arvo jokaisesta kuvan pikselistä. Verkossa käytettiin erikokoisia suotimia (3x3 ja 1x1) piirteiden oppimiseksi joko 16 tai 19 kerroksen yli ja max pooling-operaatio suoritettiin 2x2 pikselin ikkunassa 2 pikselin harppauksin. Valittujen kiinnostavien luokkien lisäkoulutus suoritettiin optimoimalla häviö monen tehtävän osalta (SoftMax luokitteluverkolle ja L1-normalisoitu häviö ehdotusverkolle) käyttäen gradientteihin perustuvaa back-propagation-menetelmää. Koulutimme kaksi konvoluutioverkkoa, jotka samanaikaisesti ennustivat kohteiden rajoja ja kunkin sijainnin kohdemaisuuspistemäärää. Tässä ratkaisussa koulutimme ensin konvoluutioverkon tuottamaan ehdotuksia, joita käytettiin vuorostaan luokitteluverkon koulutuksessa. Luokittelulla hienosäädettyä verkkoa käytettiin


puolestaan alustamaan ehdotuksia. Prosessi toistettiin kahdesti, sillä verkot jakoivat konvoluutiokerroksensa.

Alue-ehdotuksia varten luu'timme pientä verkkoa yli viimeisen jaetun konvoluutiokerroksen tuottaman konvoluutiopiirrekartan. Tämä pieni verkko otti syötteekseen nxn ikkunan konvoluutiopiirrekartasta. Menetelmämme luokitteli ja tuotti rajaavia suorakaiteita suhteessa oletussuorakaiteisiin monilla skaaloilla ja kuvasuhteissa. Testausta varten säilytimme 300 parasta kohde-ehdotusta maksimien vaimentamisen jälkeen. Piirrevektorit irrotettiin näistä kohdesijainneista käyttäen tilatason pyramidiyhdistämistä ja annettiin VGG-mallin viimeisille kerroksille kohteiden luokitusta varten. Käytimme 0.001 oppimisnopeutta 60 tuhannelle minijoukoille ja 0.0001 nopeutta seuraaville 20 tuhannelle minijoukoille PASCAL VOC-tietoaineistosta. Liikemääräksi asetimme 0.9 ja painovaimennukseksi 0.0005.

Minijoukkojen koot olivat 1 ja 64 ehdotus- ja luokitteluverkoille. Koulutuksen aikana käytimme eri tavoin skaalattuja kuvia, jotta kohteet tunnistettaisiin skaalauksesta riippumatta. Lisäkoulutukseen käytimme tietokannan kasvattamista satunnaisten kuvien horisontaalisilla käännöksillä.

4.1.6.2 Eutecus

Pilotissa käytettiin hajautetun videoanalytiikan ratkaisuna Eutecus- ReCo Pro -laitteistoa ja ADAS-ohjelmistoa. ADAS-ratkaisu on suunniteltu toimimaan osana autoon integroitua kuljettajan ajonaikaista apujärjestelmää. Ohjelmisto kykenee tunnistamaan vain rajatun joukon kohteita (jalankulkijat, pyöräilijät ja autot – näiden avulla ei voida erotella julkista ja ei-julkista liikennettä). Analytiikka-algoritmeja käyttäjä pystyy säätämään graafisen käyttöliittymän avulla (Kuva 7).



Kuva 7. Eutecus MVE GUI.

Ohjeistus ja dokumentaatio säätöjen tekemiseen ovat puutteellisia ja niiden avulla tai sitten itse analytiikan toimimattomuuden vuoksi emme saaneet Eutecusta toimimaan hyvin. Jo silmämääräisesti näkee, että kohteiden tunnistaminen Eutecuksen avulla on haasteellista (Kuva 8).




Kuva 8. Eutecus analytiikkaesimerkki.

Silminnähävistä ongelmista huolimatta analysoimme validointivideot myös Eutecuksen avulla saadaksemme kokemusta laitteiston käytöstä. Koska Eutecus on suunniteltu erilaisiin käyttötapauksiin, kuin missä pilotissa oli kyse, emme lähde arvostelemaan ratkaisua sen enempää ja toteamme vain sen soveltumattomuuden tämän pilotin tarpeisiin.

4.1.6.3 Vatic

Validointiin tarkoitettu videomateriaali annotoitiin käsin Vatic-työkalulla [6]. Esimerkki käyttöliittymästä näkyy alla olevassa kuvassa (Kuva 9). Työkalulla kirjattiin videoihin seuraavat tiedot:

- Kaistatiedot: Kaista1-Kaista3 tai "Ei tiellä"
- Kohdelaji: Auto, Kuorma-auto, Bussi, Raitiotievaunu, Jalankulkija, Pyöräilijä, Muu
- Miten kohde näkyy videossa: Osittain, Kokonaan, Ei lainkaan
- Miltä suunnalta kohde näkyy videossa: Edestä, Takaa, Sivulta
- Säätila: Aurinkoinen, Pilvinen, Sateinen, Sumuinen, Lumisateinen, Pimeä



Kuva 9. Vatic - esimerkki käyttöliittymästä.

Lopputuloksena oli joukko käsin annotoituja videoita (20 kpl), joita voitiin käyttää tarkastelemaan MUVIS- ja Eutecus-videoanalyysien toimivuutta.

Käsin annotointi on varsin työlästä ja kohtalaisen monotonista suuremmalle videomäärälle tehtynä. Mielenkiintoiseksi Vatic-työkalun ja videoiden annotoinnin tekee Vatican tarjoama suora tuki globaalisti toimivan "Amazon Mechanical Turk"-työvoimamotorin käytölle. Eli annotointitehtäviä voidaan julkaista edellä mainitussa työvoimamotorissa ja toriin kirjautuneet "resurssit" voivat ottaa julkaistun työn itselleen ja annotoinnin valmistuttua saavat työstä sovitun palkkion. Tällä tapaa annotoinnin voi ulkoistaa suhteellisen helposti.


4.2 Eri analytiikkamallien ja tulosten vertailua

Tässä luvussa kerrotaan miten analytiikkaratkaisuja/-malleja vertailtiin ja esitellään lyhyesti tulokset. Tarkemmat tulokset on nähtävissä erillisessä dokumentissa.

4.2.1 Miten vertailut tehtiin

Menetelmien tulosten vertailua kutsutaan validoinniksi. Validointi koostui eri vaiheista: Videoiden manuaalinen annotointi (verrokkimetadatan luonti), analysoidun ja annotoidun metadatan prosessointi ja tallentaminen yhteiseen tietokantaan ja tilastollinen analyysi menetelmien välillä.

Pilotissa videoanalyysin tulosten validointi on rajattu esineiden paikannus ja tunnistustehtävien onnistumisen mittaamiseen eri sääolosuhteissa ja eri liikennevälinetyypeille. Näiden arvioimiseksi annotoitu materiaali yhdistettiin mallien tuloksiin yksi kuva kerrallaan. Joka kuvaan liittyy referenssimateriaali ja ennusteet. Molemmat ovat listoja, joita ei voi suoraan yhdistää. Sen vuoksi etsittiin lähimmät parit annotointien ja tulosten esineiden välillä, minimoiden kokonaisuutensa Unkarilaisella algoritmilla. Alla näkyy esimerkki (Kuva 10), jossa kolme ennustettua esinettä (mustat laatikot) yhdistetään lähimpiin annotoituihin esineisiin. Kuvaan jää esineitä, joille ei löydy paria ja ne pysyvät mukana mallien arviointia varten.




Kuva 10. Validointiesimerkki.

Tärkeimpiä mittareita videoanalyysille ovat tasapainotettu tarkkuus (balanced accuracy), sensitiivisyys (sensitivity), spesifisyys (specificity) ja täsmällisyys (precision). Lisäksi paikannuksen arvioimiseksi käytetään euklidista etäisyyttä (Euclidean distance) annotoinnin ja ennusteen suorakulmioiden keskipisteen välillä sekä suorakulmioiden leikkauksen suhdetta niiden unioniin (intersection over union, IOU).

Usein video-analyysi ehdottaa useita mahdollisia luokkia ennustamalleen havainnolle. Tällöin käytetään yleisesti haku- ja rankingtehtäviin sopivaa keskimääräistä täsmällisyyttä (mean average precision). Pilotissa oli käytössä vain todennäköisimmät luokat, mikä yksinkertaistaa arviointia ja tulkintaa.

Validoinnissa oli mukana yhteensä 5 tuhatta kuvaa, joissa oli n. 18 tuhatta esinettä. Validointi- ja yhdistelyprosessista syntyi yhteensä 60 tuhatta havaintoa eri olosuhteissa ja eri mallien tuloksena. Alla (Kuva 11) näkyy havaintojen jakautuminen ajoneuvoihin ja säätiloihin.



Kuva 11. Havaintojen jakautuminen ajoneuvoihin ja sääolosuhteisiin.

Pilotissa verrattiin keskitetyn videoanalytiikkaratkaisun, MUVIS, kahden mallin, MUVIS1:n ja MUVIS2:n, tuloksia. Hajautetun ratkaisun, joka perustui Eutecus-järjestelmään, analysoinnin tuloksia ei otettu vertailuun mukaan.

Mallit tunnistivat henkilöautoja (personal vehicle), busseja (bus), jalankulkijoita (pedestrian), pyöräilijöitä (cyclist), moottoripyöriä (motorcycle) ja junia (train). Referenssimateriaalissa oli henkilöautoja, busseja, jalankulkijoita, pyöräilijöitä, raitiovaunuja (tram) ja rekkoja (truck). Puuttuvat havainnot koodattiin tyypillä "NotFound". Esineluokkia yhdisteltiin kulkumuotokategorioiksi seuraavasti:

- Ei-julkiset kulkuneuvot: Henkilöauto, moottoripyörä (Personal: personal vehicle, motorcycle)
- Julkiset kulkuneuvot: Linja-auto, raitiotievaunu, juna (Public: bus, tram, train)
- Ei-motorisoitu: Jalankulkija, pyöräilijä (Non-motorized: pedestrian, cyclist)
- Kuljetus: Kuorma-auto (Freight: truck)

4.2.2 MUVIS1-mallin analyysi

MUVIS-analytiikkaratkaisu vaatii opetetun mallin (katso luku 4.1.6.1) kohteiden tunnistamiseen. Pilotin aikana teimme 2 eri mallia: MUVIS1- ja MUVIS2, joita testasimme ja analysoimme.

MUVIS1 suoriutui 35 tuhannen havainnon luokittelusta kohtalaisesti. Tarkkuus parani 53%:sta 67%:iin, kun puuttuva luokka poistettiin (Taulukko 1). Tämä johtui osittain mallin herkkyydestä, mikä aiheutti joitakin olemattomia ennusteita.

Taulukko 1. MUVIS1-mallin tuloksia.

Puuttuva luokka mukana		Puuttuva luokka poistettu	
Number of Records	34 743	Number of Records	27 837
Accuracy - type	53%	Accuracy - type	67%
Accuracy - category	54%	Accuracy - category	68%
Sensitivity - object detection	86%	Sensitivity - object detection	86%
Precision - object detection	78%	Precision - object detection	100%
Median relative intersection	31%	Median relative intersection	31%
Median distance	43	Median distance	43

Alla (Kuva 12) näkyy yhteenveto mallin toiminnasta eri sääolosuhteisiin ja kulkutavoilla. Laatikot kuvastavat havaintomääriä ja tummempi väri parempaa suorituskkyä. Tässä tapauksessa referenssinä on annotaatiot, jolloin värinä oleva oikeiden havaintojen osuus on sensitiivisyys. Selkeästi henkilöautot tunnistetaan parhaiten. Pimeällä säällä on yllättäen positiivinen vaikutus henkilöautojen tunnistamiseen. Tämä voi liittyä siihen, että malli on ylipäättään sensitiivisempi henkilöautoja kuin muita luokkia kohtaan.

Weather condition	Personal vehicle	Bus	Pedestrian	Cyclist	Tram	Truck	Other
Cloudy	78	25	21	0	0	0	
Snowy	69	0	24		0	0	
Sunny	77	39	42	29	0	0	0
Dark	95	5					
Rainy	89	28	8				

Measure selector - size
Percent correct

Measure selector - color
Percent correct

Axis selector
Annotation object type

Kuva 12. MUVIS1 malli tuloksia eri sääolosuhteissa.

Alla luokkakohdaiset mittarit (Taulukko 2). Pyöräilijöitä on sen verran vähän, että he pyöristyvät 0%:iin.

Taulukko 2. Luokkakohtaisia mittareita.

Type details - Personal vehicle		Type details - Bus		Type details - Pedestrian		Type details - Cyclist	
Balanced accuracy	64%	Balanced accuracy	62%	Balanced accuracy	62%	Balanced accuracy	60%
Sensitivity	80%	Sensitivity	29%	Sensitivity	34%	Sensitivity	19%
Specificity	48%	Specificity	95%	Specificity	91%	Specificity	100%
Precision	72%	Precision	31%	Precision	15%	Precision	40%
Prevalence	62%	Prevalence	7%	Prevalence	5%	Prevalence	0%

4.2.3 MUVIS2-mallin analyysi

MUVIS2 on toinen kahdesta pilotissa MUVIS-ratkaisulle luoduista malleista. Se on käytännössä epäherkempi, mutta toisaalta se taas analysoi videokuvaa nopeammin. MUVIS2 mallin tuloksia voi tarkastella alla (Taulukko 3).

Taulukko 3. MUVIS2 mallin tuloksia.

Puuttuva luokka mukana		Puuttuva luokka poistettu	
Number of Records	28 501	Number of Records	27 837
Accuracy - type	47%	Accuracy - type	49%
Accuracy - category	48%	Accuracy - category	49%
Sensitivity - object detection	56%	Sensitivity - object detection	56%
Precision - object detection	96%	Precision - object detection	100%
Median relative intersection	32%	Median relative intersection	32%
Median distance	45	Median distance	45

Koska MUVIS2:den herkkyys ei ole kovin lähellä MUVIS1:tä, niin esineitä löydetään vähemmän (MUVIS1: 37743 vs. MUVIS2: 28501).

Objektikohtaisia tuloksia MUVIS2-mallille alla (Taulukko 4, Kuva 13).

Taulukko 4. MUVIS2 mallin objektikohtaisia tuloksia.

Type details - Personal vehicle	Type details - Bus	Type details - Pedestrian
Balanced accuracy 66%	Balanced accuracy 54%	Balanced accuracy 54%
Sensitivity 61%	Sensitivity 10%	Sensitivity 9%
Specificity 71%	Specificity 98%	Specificity 99%
Precision 87%	Precision 38%	Precision 47%
Prevalence 76%	Prevalence 9%	Prevalence 6%

Alla (Kuva 13) näkyy yhteenveto mallin toiminnasta eri sääolosuhteissa ja eri kulkutavoilla. Laatikot kuvastavat havaintomääriä ja tummempi väri parempaa suorituskkyä.

Weather condition	Personal vehicle	Bus	Pedestrian	Cyclist	Tram	Truck	Other
Cloudy	58	3	4	0	0	0	
Snowy	31	0	10		0	0	
Sunny	57	25	11	0	0	0	0
Dark	85	0					
Rainy	83	0	0				

Measure selector - size: Percent correct
 Measure selector - color: Percent correct
 Axis selector: Annotation object type

Kuva 13. MUVIS2 tuloksia eri sääolosuhteissa.

4.3 Vastaukset asiakkaan vaatimukseen

Tässä kappaleessa annetaan vastaukset tarjouspyynnössä kirjattuihin vähimmäisvaatimukseen ja toivottuihin lisäominaisuuksiin.

ID	Vaatus	Vastaus
1. Kamerakuvan analysointi ja metatiedon tuottaminen seuraavista tietolajeista		
1A1	Liikennemäärät: Tiekohtainen	Tämä on peruskäyttötapa ja toimii jo nykyisellään hyvin maanteilla, joilla ei ole pysäköintipaikkoja. Tarkkoihin liikennemääriin tulee laskea vain liikkuvat autot ja esimerkiksi videokuvassa näkyvät kadulle tai kadun ulkopuolelle pysäköidyt autot tulee pystyä poistamaan laskuista. Tämän opettaminen analytiikalle vaatii lisätyötä, jota pilotissa ei ehditty tekemään.

1A2	Liikennemäärät: Kaistakohtainen	Tämä vaatii kaistantunnistuksen opettamisen analytiikalle. Sitä ei pilotin aikana ehditty toteuttamaan ja testaamaan.
1B1	Kuljutavat: Henkilöauto	MUVIS tunnisti henkilöautot pilotissa parhaiten. Henkilöauton tunnistamiseen tarkoitetut käyttötapaukset ovat varsin hyvin toteutettavissa.
1B2	Kuljutavat: Joukkoliikenne	Bussi ja juna tunnistetaan. Raitiovaunua ei tällä hetkellä ole tuettu, mutta se on mahdollista opettaa erikseen.
1B3	Kuljutavat: Tavaraliikenne	Pilotissa käytetyissä MUVIS-malleissa ei kuorma-autoja ollut opetettu, eikä niitä tunnistettu. Mahdollista opettaa erikseen.
1B4	Kuljutavat: Jalankulkijat	Jalankulkijoiden tunnistaminen on tuettu.
1B5	Kuljutavat: Pyöräilijät	Pyöräilijöiden tunnistaminen on tuettu.
1C	Kulkusuunnat	Tunnistetun kohteen kulkusuunta on mahdollista päätellä analytiikan toimesta. Tämä vaatii lisäopetusta mallille, jotta se osaa kertoa tunnistetun kohteen lisätietona näkykö kohde edestä, takaa, sivulta (suunta vasemmalle/oikealle) tai ylhäältä. Pilotissa käytössä olleet analytiikkamallit eivät kyenneet tunnistamaan löydettyjen kohteiden kulkusuuntaa.
1D1	Nopeudet: Tiekohtainen keskiarvo	Teoriassa mahdollista laskea videokuvasta kaikkien kuvasta havaittujen kohteiden nopeus kun tiedetään videota kuvaavan kulkuneuvon nopeus, etäisyyksien muutokset kuvien välillä ja videon näytteenottotaajuus. Nopeuden arviointi pitää tehdä 2 tai useamman perättäisen videokuvan perusteella ja tällöin tarvitaan lisäanalytiikkaa: kohteiden identifiointi (tracking) kuvissa, jotta tiedetään, että liikkunut kohde on yksi ja sama kahden kuvan välillä. Kohdekohtaisen identifioinnin toteutus vaatii lisälogiikkaa analytiikalle – autojen identifiointi eri kuvien välillä onnistuu esimerkiksi rekisterinumeron avulla. Käytännössä etäisyyttä ei pystytä arvioimaan kovin luotettavasti liikkuvan kuvan perusteella. Käytännössä ajoneuvoon asennetut tutkat/etäisyyssmittarit tarjoaisivat helpomman tavan arvioida kohteiden etäisyyksiä kuvaavan kulkuneuvon suhteen.
1D2	Nopeudet: Kaistakohtainen keskiarvo	Katso vastaus edeltä – sama haaste kuin tiekohtaisessa nopeuden laskemisessa. Tässä astuu kuvaan vielä kaistantunnistus lisävaatimuksena.

1E1	Häiriöt ja onnettomuudet	Onnettomuuden tunnistaminen kuvasta on haastavaa. Onnettomuuskuvien perusteella voidaan mallia opettaa, mutta onnettomuuksien tilannekuvien ainutkertaisuuksista johtuen, voi riittävän kuvamateriaalin löytäminen olla haastavaa. Ja riittääkö sekään tunnistamaan varmuudella onnettomuustilanteen, sillä opetuksessa käytettyjen kuvien ympäristö on kuitenkin aina erilainen. Tähän paras ratkaisu on integroida hälytyskeskuksen tiedot järjestelmään ja hyödyntää sitä onnettomuustilanteiden paikallistamiseen. "Häiriöitä" voidaan ajatella poikkeuksina normaalista ja niiden tunnistaminen riippuu itse häiriöstä ja siitä, löydetäänkö sille jotain tyypillistä ja tunnistettavaa tuntomerkkiä. Esimerkiksi tietyö voitaisiin tunnistaa liikennemerkistä tai joistain tietyömerkinnöistä kadun varrella. Videoanalytiikka soveltuu häiriöihin, jotka ovat selkeästi tunnistettavissa ja opetettavissa analytiikkamalleille. Jos kamera olisi paikallaan, niin tällöin "poikkeukset normaalista" olisi helpompi opettaa, mutta liikkuvan videokuvan kohdalla "normaalin" määrittely on paljon haastavampaa.
2. Metatieto		
2A	Aikaleima	Tämä on järjestelmän perustietoalkio ja tuki sille löytyy jo pilotissa.
2B	Paikkatieto	Paikkatiedon keruu vaatii GPS-laitteen ja ohjelmiston, jolla sijaintia pystyy tallentamaan tiedostoon ajan ja paikan funktiona. Pilotissa käytettiin omaa Android-ohjelmistoa videon kuvaukseen ja sijaintitiedon tallentamiseen.
3. Analysoitu tieto jaetaan metatietona avoimen rajapinnan kautta standardimuotoisten tiedonjakoformaattien (esim. DATEX II) muodossa [8]		
3	Avoin rajapinta	Pilotissa rajapintaa ei toteutettu, mutta käytännössä ehdotamme REST-rajapintaa metadataan. Formaatti on sovittavissa ja ehdotettu formaatti sopii siihen mainiosti
4. Suunnitelma kameroiden asentamisesta liikkuviin ajoneuvoihin		
4	Kameroiden asentamisesta liikkuviin ajoneuvoihin	Pilotissa kamerat asennettiin 9 eri kulkuneuvoon (8 autoa ja 1 polkupyörä). Älypuhelin, sille ajoneuvomalliin sopiva kiinnitysratkaisu, sekä virtalähde puhelimelle tarjoaa parhaan vastineen rahalle. Datan keruu tarvittavine ohjelmistoineen ja tiedonsiirto hoituu älypuhelimella.
5. Tietolajien analysointi eri sääolosuhteissa		

5A1	Pilvinen / muuten suhteellisen tasaiset valaistusolosuhteet	Nämä olosuhteet esiintyivät videoilla eniten. Kohteiden tunnistus toimi pilvisellä kelillä validoinnin perusteella hyvin (normi-tulos)
5A2	Voimakas kontrasti esim. rakennuksen varjo ja auringonpaiste samassa kuvassa	Voimakas kontrasti vaikeuttaa analytiikkaa ja lisää virhemarginaalia. Vasta-aurinko, tunneliin ajo ja tunnelista poistuminen sisältävät paljon voimakasta kontrastia.
5A3	Vesisade	Vesisade tuo videokuvaan jonkin verran häiriötä ja vaikeuttaa kohteiden tunnistusta. Tosin itse sade erottuu yllättävän vähän kuvasta. Suurin haaste on kuitenkin kuvan tarkentuminen tuulilasin vesipisaroihin, jolloin itse liikennekuva jää sumeaksi ja kohteiden tunnistaminen vaikeutuu. Pyyhkimet ja kameran tarkennuksen säätö korjaavat tätä ongelmaa.
5A4	Lumisade	Lumisateella on samat haasteet kuin vesisateella. Luminen maasto voi lisätä kontrastia, mutta toisaalta taas kohteiden erottelu helpottuu hieman. Esimerkiksi jalankulkijat erottuvat lumista taustaa vasten helpommin kuin vihreää/ruskeaa taustaa vasten.
5A5	Sumu, näkyvyys < 50 metriä	Validointivideoihin emme saaneet taltioitua sumuista säätä. Sumu heikentää luonnollisesti hieman kohteiden tunnistusta, mutta silmämääräisesti sumu näkyy videokuvassa yllättävän heikosti – paljaalla silmällä sumua tuntuu olevan sakeana, mutta kameran kuvassa sitä ei näy paljoakaan.
5B	Pimeä / katuvalaistusta vastaava tilanne	Pimeällä varsinkin autojen tunnistus toimi yllättävän hyvin. Autojen valoilla on tässä todennäköisesti suuri merkitys. Jalankulkijoita tunnistetaan jos valaistus riittävä, mutta usein jäävät helposti pimeään/varjoon. Kuvaavan ajoneuvon ajovalot tuo esiin kohteita hyvin, mutta ajovalojen keilan ulkopuolelle jääviä kohteita ei tunnisteta niin hyvin ilman, että katuvalo luo niihin valoa.
6. Kamerakuvasta analysoitavat muut tietolajit ja/tai tilannekuva-analyysi		
6A	Liikenteen sujuvuus ja ruuhkat esim. tiekohtaisesti ja kaistakohtaisesti	Liikenteen sujuvuudesta ja ruuhkista saa käsityksen mm. liikennetiheyden avulla. Referenssitietoa halutun analysoitavan paikan suhteen tulee kuitenkin olla tietovarastossa eri viikonpäivien ja eri vuorokauden ajankohdan mukaan. Tällöin voidaan päätellä "normaaliliikenne" eri ajankohtina ja kun tähän yhdistää vielä kameran nopeudet ja esim. kiihtyvyyssanturien tiedot, niin

		sujuvuudelle voidaan laskea erilaisia tunnuslukuja. Sama pätee ruuhkatilanteen määrittämiselle – esimerkiksi tietyn ajoneuvotiheyden ylitys tietyssä ajankohtana ja tietyssä kohdassa voidaan tulkita ”ruuhkaksi”.
6B	Vallitsevat olosuhteet (sää, keli)	Älypuhelimien antureiden ja sääpalveluiden avulla saa parhaiten tiedon vallitsevista olosuhteista. Itse videokuvasta voidaan myös tehdä johtopäätöksiä, mutta vaatii sääolosuhteiden opettamisen analytiikalle.
6C	Vapaat pysäköintipaikat	Tässä tulee olla lähtötietona mitkä ovat varsinaisia pysäköintipaikkoja – lähdetietona esimerkiksi kaupungin pysäköintipaikkakartta.
6D	Liikennemäärien ennustettavuus esim. 15 minuuttia eteenpäin	Kellon ajan, olosuhdetiedon ja sijainnin avulla voidaan ennustaa liikennemäärä historiatietoon pohjautuen. Onnettomuustilanteen sattuessa ennustettavuus on vaikeaa, sillä ennusteet vaativat suuren määrän historiatietoa ja tietyn sijainnin suhteen onnettomuustietoja tuskin löytyy paljoa historiatietokannasta. Jotain yleistä arviota kokemustiedon perusteella voi tietysti soveltaa onnettomuustilanteisiin ja näin saada jonkinmoinen ennuste onnettomuuden vaikutuksesta liikenteeseen.
6E	Historiatietoon pohjautuvat ennusteet vuorokausisyklissä (1-24 h) ja viikkosyklissä (1-7 vrk)	Historiatietojen ja tilastollisten menetelmien avulla voidaan toteuttaa ennusteita.
6F	Poikkeustilat / herätteet	Samat haasteet kuin kohdassa 1E1. Jos jokin poikkeustila tai heräte on helposti kuvattavissa/hahmotettavissa, se voidaan opettaa analytiikalle. Esimerkiksi hälytysajoneuvojen ja tietä huoltavien/kunnostavien ajoneuvojen vilkkuvalot voidaan tunnistaa kuvasta. Tiellä oleva tunnistamaton kohde tai vaikkapa tulva voi myös toimia herätteenä.
6G	Tarjoaja voi myös ehdottaa muiden kameroiden kuvan avulla tuotetun (esim. joukkoistamalla kerätyn) tiedon yhdistämistä. Toimittajan tulee	Ideoita liikkuvan kuvan ja muiden tietolähteiden soveltamisesta on kerrottu kappaleessa 4.5.1.

	silloin vastata kameroiden tuottamaan kuvaan liittyvästä tietosuojasta ja toiminnallisuudesta.	
6H	Edellä kuvatut lisäominaisuudet ovat esimerkkejä mahdollisista tietolajeista. Tilaaja toivoo ehdotuksia myös muista kaupunkiliikenteen tilannekuvan muodostamisen kannalta kiinnostavien tietojen analysoinnista.	Näitä ajatuksia/ehdotuksia on listattu kappaleessa 4.5.1.

4.4 Johtopäätökset

Pilotissa testattiin erilaisia videokeruu laitteistoja, datan (video ja sijaintitieto) siirtoa, käsittelyä, tallentamista ja visualisointia, sekä ennen kaikkea syväoppimismenetelmiin (deep learning) pohjautuvaa videokuvan analysointia. Analytiikkaa testattiin pilotissa lähinnä yksittäisten asioiden tunnistamisen kannalta. Se luokkiin pohjan ylemmän tason datan käytölle, jossa esimerkiksi liikennemuotojakautumia hyödynnetään operatiivisen tilannekuvan muodostamisessa ja pitkäjänteisessä kaupunkisuunnittelussa.

Videoanalyysin ennustemallit toteutettiin yhteistyössä Tampereen teknillisen yliopiston kanssa. Mallit tuottavat kuvan perusteella listan esineistä sijainteineen ja rajoineen. Mallien tuloksia vertailtiin validoinnissa annotoituun havaintojoukkoon. Parhaan mallin luokittelutarkkuus oli 67 %, kun havaintoihin verrattuna ylimääräiset ennusteet poistettiin. Sensitiivisyys todellisiin esineisiin oli 56 % ja täsmällisyys 96 %. Sääolosuhteet vaikuttivat odotettua vähemmän mallien toimintaan; tärkeämpää tulosten kannalta oli mallin parametrit sekä mallin opetuksessa käytetty koulutusmateriaali. Liikennemuodoista mallit tunnistivat parhaiten henkilöautot, joiden sensitiivisyys ja spesifisyys olivat 80 % ja 64 %. Muiden liikennemuotojen kohdalla sensitiivisyys oli 19 % - 34 %.

Videoanalyysimallit vaativat tilannekuvakäyttöä ajatellen jatkokehitystä. Videomalleja kehittäessä on tärkeää käyttää kouluttamiseen suuri määrä annotoitua dataa (kuvia, joissa kohteet, niiden sijainnit ja muut attributit ovat valmiiksi tiedossa). Käytettäessä 500 000 havaintoa ja 200 eri luokkaa kattavaa analytiikkamallia, voidaan odottaa 50 % - 65 % keskimääräistä täsmällisyyttä.

Teknisessä mielessä löysimme eri komponenteista ratkaisun, jonka pohjalta voi lähteä kehittämään tuotantokäyttöön tarkoitettua pienimuotoista ei-reaaliaikaista järjestelmää, mutta laajamittaiseen laadukkaan ja täysin reaaliaikaisen videokuvan keruuseen ja analysointiin siitä ei ole vielä sellaisenaan. Käytännön toteutuksen kannalta suurimmat haasteet ovat tiedonsiirto nykyisten matkapuhelinverkkojen yli reaaliajassa ja useammasta lähteestä (>10) kerättävän

videokuvan analysointiin tarvittavan laskentakapasiteetin tarve (erillisen grafiikkapiirin tarve ehdoton). Karkeasti voi arvioida, että jokaisen videon analysointiin reaaliajassa tarvitaan yksi palvelin, jonka kokoonpano on minimissään seuraava: SSD-levyt, 4-ytiminen CPU ja M1 grafiikkapiiri (GPU, Titan X). Toki yhden palvelimen kapasiteettia voidaan kasvattaa ja palvelimien määrää lisätä (skaalautuvuus) ja täten voidaan analysoida useampaa videota samaan aikaan. Järjestelmän investointia tulee suhteuttaa analytiikan avulla saavutettavaan hyötyyn – voi olla, että lopulta saavutetaan suuriakin säästöjä kaupunkisuunnittelussa ja/tai liikennesuunnittelussa, ja investointi suurempaankin analytiikkajärjestelmään nähdään näin kannattavaksi.

Käytännössä reaaliaikaisuudesta ja/tai videon laadusta tinkiminen eliminoi suurimmat teknologiset pullonkaulat. Tulevaisuudessa uudet ja nopeammat tiedonsiirtotekniikat, sekä palvelinten/grafiikkapiirien suorituskyvyn kehittyminen (erityisesti hinta/suorituskyky-suhde) tuovat helpotusta asiaan. Analytiikkaa voi myös soveltaa mm. vain joka viidennelletoista kuvalle (30fps /15 => analysoidaan 2 kuvaa/s) ja näin voidaan säästää prosessointitarpeissa. Analytiikan paketoiminen hajautetusti suoraan älypuhelimeen olisi optimaalista, mutta tarkoitukseen sopivia älypuhelimia joudutaan odotteleen varmaan vielä jokunen vuosi.

Liikkuvan kuvan analytiikan hyödyntämisessä nähdään kaksi pääkäyttötapausryhmää: 1) Historiatietoon perustuvaa analysointia suunnittelun ja päätöksenteon tueksi ja 2) Reaaliaikaista tietoa poikkeustilanteiden tilannekuvan selvittämiseksi paikallisesti. Ensimmäisen kohdalla liikkuvan kuvan datankeruu täytyy joukkoistaa, mikäli halutaan riittävän kattavaa reaaliaikaista dataa suunnittelun ja operatiivisen päätöksenteon tueksi.

Poikkeus-/häiriötilanteet ovat hyvin ajallisesti ja paikallisesti rajattuja, jolloin liikkuvan kuvan datankeruu voisi sopia niihin. Itse tiedon keruun ”käynnistäminen” häiriötilanteessa on haastavaa - mistä tiedetään/tunnistetaan häiriötilanne ja sen sijainti? Esimerkiksi liikenneonnettomuuden tunnistaminen kuvasta liikkuvan kameran kulkiessa onnettomuuspaikan ohi on analytiikalle haastava tilanne. Täten tällaisen häiriötilannetiedon saaminen ulkoisista tietolähteistä on todennäköisesti järkevintä. Poikkeustilanteissa jonoinformaation arvo usein korostuu ja videokuvaus voisi olla parempi toteuttaa yläpuolelta ennemmin kuin autosta.

Paras tulos tilannekuvan luomiseksi saadaan kun optimoidaan eri tiedonkeruutavat niin, että tärkeimmillä liikennöintipaikoilla on staattiset kamerat, julkisissa liikennevälineissä omat liikkuvat kamerat (tärkeät reitit ja liikennekuva niistä), minkä lisäksi saadaan kerättyä satunnaisotoksia ulkoistetuista lähteistä esimerkiksi lähettämällä kuvauskalustoa johonkin tiettyyn pisteeseen (kuvausauto tai lennokki). Tilannekuvan luomisen kannalta tärkeä askel on edellä mainittujen datalähteiden ja ulkoisten datalähteiden informaation yhdistely ja harmonisointi.


4.5 Jatkokehitysideoita

Tässä kappaleessa on ajatuksia miten videoanalytiikkaa voidaan kehittää ja mitä mahdollisuuksia videoanalytiikan osalta kaiken kaikkiaan nähdään.

4.5.1 Jatkokehitys – potentiaalisia käyttötapauksia

Alla muutama ajatus millainen järjestelmä tulevaisuudessa voisi olla. Ensimmäisessä kuvassa (Kuva 14) on kuvattu tulevaisuuden perusratkaisu, jossa tutkimus ja operatiivinen toimi hyödyntää varastoitua tietoa, joka on tuotettu analytiikalla ja integroimalla erilaisia tietolähteitä.


Tilannekuva – visio



Kuva 14. Tilannekuvan visio - jatkuva tiedon keruu.

Toisessa kuvassa (Kuva 15) on visio käyttötapaan, jossa havaitaan jokin poikkeustilanne ja sen myötä käynnistetään tiedonkeruu. Esimerkiksi ohjelmoitava lennokki voidaan lähettää kohteen päälle kuvaamaan tilannetta. Historiatiedon ja reaaliaikaisen tiedon perusteella voidaan tehdä arviota kuinka kauan poikkeustilanteen korjaaminen kestää ja minkälaisia vaikutuksia sillä on ympäristön liikennekuvaan. Lisäksi järjestelmän kautta voi lähteä tiedotuksia eri tahoille, esimerkiksi viranomaisille, taksikeskukseen, joukkoliikenteelle ja vaikkapa alueella liikkuville tai sinne päin kulkeville. Tilanteen vaikutuspiirissä oleville voidaan ehdottaa mm. ennustettuja odotusaikoja ja vaihtoehtoisia reittejä.


Tilannekuva – visio



Kuva 15. Tilannekuva visio - Pistemäinen tiedonkeruu.

Kolmannessa kuvassa on ajatuksena yhdistää käyttäjille eri väylien kautta tarjottavien kyselyiden (älylaitteilla, netissä, kirjein, yms.) tiedon yhdistämistä analytiikan avulla luotuun historiatietoon. Näin voidaan ymmärtää paremmin käyttäjien käyttäytymistä ja sen tiedon avulla voidaan taas kehittää tilannetta ja luoda kannustimia käyttäjille toimimaan vaikkapa joukkoliikennettä suosivammalla tavalla.

Tilannekuva – visio



Kuva 16. Tilannekuva visio - käyttäjätutkimustiedon hyödyntäminen.

Auton, älypuhelimien, ihmisten käyttämien erillislaitteiden **sensoreista** ja ulkopuolisista lähteistä saadaan paljon hyödyllistä tietoa ja olisi suorastaan järjenvastaista jättää se tieto hyödyntämättä. Usein yhden sensorin tieto yksinään ei välttämättä ole kovin merkityksellinen, mutta kun eri lähteiden dataa yhdistää saadaan aikaiseksi arvokasta informaatiota.

Alla muutamia ajatuksia mitä kaikkea mahdollisuuksia järjestelmään voisi tarjota. Taulukossa on aihe-alue ja ehdotettu käyttötapaus ja siihen liittyvää pohdintaa.

Liikenteen seuranta	
Liikenteen ympäristöystävällisyys. Seurataan videodataa kuvaavan kulkuneuvon kannalta)	Analytiikkadatan (liikennemäärät) ja antureiden metadatan (nopeudet, sijainti, kiihtyvyys) voidaan verrata vaikkapa autonvalmistajan päästötietoihin ja alueella kerättäviin ilmanlaatumittauksiin. Näin voidaan laskea vaikkapa joukkoliikenteen kulutusta/päästöjä muuttamalla liikenneratkaisuja saadun tiedon perusteella. Voitaisiko esimerkiksi jotenkin vähentää pysähtymisiä, kiihdytyksiä tai ruuhkaa?
Liikennenopeudet eri sääolosuhteissa tilastollisesti ja miten ne korreloivat onnettomuustilastoihin	Seurattavan ajoneuvojoukon (fleet) tilastoitujen nopeuksien (GPS-signaalin avulla) mukaan nähdään alueittain liikenteen keskinopeudet ja yhdistämällä tämä onnettomuustilastoihin voidaan päätellä riskialueet ja yhteydet nopeuksien ja onnettomuuksien välillä. Liikennejärjestelyiden avulla tehtyjä muutoksia voidaan samalla validoida ja päätellä onko

	muutoksilla ollut vaikutusta onnettomuuksien esiintymiseen.
Liikennenopeuksien ja ruuhkien ennusteet odotettavien sääolosuhteiden mukaan ja tämän tiedon hyödyntäminen erilaisissa liikennepalveluissa	Analytiikalla kerättävän tiedon (liikennetiheydet ja nopeudet) voidaan ennustaa liikenteen käyttäytymistä ja lähettää tiedotuksia/varoituksia paikallisesti.
Uusien palveluiden tarjonta kerättävän analytiikan pohjalta.	Kerättävä data mahdollistaa uusien palveluiden luomisen markkinoille.
Liikenteessä näkyvien symboleiden (liikennemerkkit, opasteet, mainokset, jne.) ja liikenteen sujuvuuden yhteydet	Analytiikan perusteella (merkkien tunnistus) ja eri kulkuneuvoon liitettyjen sensoreiden avulla voidaan vertailla miten ne vaikuttavat liikenteen tilannenopeuksiin tai liikennetiheyksiin.
Liikennemäärien kasvun ja kapasiteettitarpeen ennustaminen.	Analytiikan avulla kerätyn historiatiedon avulla voidaan nähdä liikennemäärien kehitys pidemmän ajan funktiona. Tämän avulla ennustaa tulevaisuuden liikennemääriä tai parantaa olemassa olevia menetelmiä
Julkisen liikenteen väylien toimivuus	Asennettaessa keruu julkisen liikenteen ajoneuvoihin, voidaan kuljettavan reitin varrelta kerätä valtavasti hyödyllistä tietoa ja tämän perusteella arvioida miten reitti toimii kokonaisuutena, miten julkisen liikenteen kaistat toimivat eri alueilla. Lisäksi voidaan seurata miten paljon julkisen liikenteen väylillä kulkee sinne kuulumattomia ajoneuvoja.
Joukkoliikenteen täsmällisyys	Jos videokamerat asennetaan joukkoliikenteen ajoneuvoihin, niin jo pelkästään aikaleimojen ja sijaintitiedon perusteella pystytään seuraamaan joukkoliikenteen täsmällisyyttä. Kaikki muu videoanalytiikka tulee tämän päälle bonuksena.
Joukkoliikenteen sijainti kartalla	Tähän onkin olemassa jo palveluita ja käytössä monella liikennöitsijällä. Videoanalytiikkaratkaisussa laitteistoa voi hyödyntää myös tämän palvelun suhteen. Erillistä laitteistoa ei tarvitse asentaa.
Ruuhkaraportointi	Autoilijoilla on kaupungin mobiilisovellus, jossa voi painaa nappia kun autoilija havaitsee ruuhkan – esimerkiksi kun ruuhka alkaa ja kun se päättyy. Kun vielä saadaan auton ruuhkassa kulkema reitti, nopeudet ja siihen käytetty aika,

	niin ruuhkasta saatava tieto on varsin kattavaa. Tässä ei tarvita videokuvaa välttämättä lainkaan. Tätä kun vielä kehittää siten, että puhelimen yksinkertaistettu analytiikka tunnistaa kuvasta ruuhkan ja tekee "raportoinnin" automaattisesti autoilijan puolesta.
Tiestön ylläpito	
Liikennemerkkien kunnon seuranta	Analytiikalle opetetaan tunnetut liikennemerkkit ja niiden kuntoa (vauriot, lunta, likaa) ja näkyvyyttä (ajoneuvon kannalta – onko sijainti hyvä ja näkyvyys hyvä eri kulkuneuvoille) voidaan analysoida videon perusteella.
Katuvalojen kunnon seuranta	Järjestelmälle voidaan opettaa, että tien varrella tietyllä alueella on katuvalot. Analytiikka tunnistaa lyhtypylväät ja näkee onko pylväiden päässä valo vai ei.
Tiestön/katujen kunnon seuranta	Älypuhelimien anturien avulla saadaan tarkkaa tietoa tiepohjan tasaudesta. Väriä, töyssyt ja kuopat huomataan helposti kiihtyvyyssantureiden avulla. Antureiden tiedon perusteella tehtyjä löydöksiä voidaan vielä tarkastella yhdessä videon avulla ja varmistaa mistä oli oikeasti kyse. Tähän tarkoitukseen optimoidussa ratkaisussa videokuvaa ei tarvita koko ajalta, vaan määriteltujen kriteereiden perusteella tunnistettujen poikkeamien avulla (esim. töyssy) talletetaan videota 10 sekuntia ennen ja 10 sekuntia jälkeen havaitun poikkeaman. Lisäksi videokuvasta voidaan oppia tunnistamaan tielle kuulumattomia esineitä.
Onnettomuuksien todennäköisyyksien ennustamista	Sään ja tien kunnon perusteella voidaan tehdä myös onnettomuuksien todennäköisyyden ennustamista
Kuljettajan ajonohjausta/seuranta	
Kuljettajan kunnon/terveyden/vireystilan seuranta ja turvallisuuden parantaminen	Tässä tapauksessa yksi kamera kohdistetaan kuljettajaa kohden. Hänen kasvojen ilmeet ja kehon kieltä tulkitsemalla voidaan havaita mahdollisesti kuljettajan vireystilan laskeminen alle kulkuneuvon ajoon vaadittavan (rattiin nukahtaminen). Tai havaitaan sairaskohtaus. Tulevaisuudessa tämä informaatio voidaan

	kytkeä kulkuneuvon autopilottiin/ajonestoon. Videokuvan lisäksi järjestelmä voi kerätä kuljettajan aktiivirannekkeen/sykemittarin tietoja ja ääntä ja käyttää niitäkin päätöksenteossa. Lisäksi tiedon pohjalta voidaan opastaa/informoida/herättää kuljettajaa (interaktiivinen järjestelmä) Tietoa voidaan käyttää vai paikallisesti autossa tai kerätä keskitettyyn tietojärjestelmään, jossa löytyy taas paljon lisäkäyttötapauksia tiedon hyödyntämiselle esimerkiksi ammattiliikenteessä.
Kuljettajan ajotaitojen arviointia	Kuljettajan älypuhelimien sensoreiden, videokuvalla analysoitujen kohteiden (liikennemerkkien, muu liikenne, jne.) ja auton sensoreiden (kaasunkäyttö/jarruttaminen/vaihteiden vaihto...) tietoa voidaan hyödyntää monenlaiseen käyttötapaukseen. Esimerkiksi suomalaisten yleisten ajotapojen ymmärtämisellä voidaan yrittää vaikuttaa ajokulttuuriin. "Arvosana" jokaisen ajoreissun jälkeen voisi parantaa ajotaitoja. Lisäksi esimerkiksi autokoulut tai yksityiset ajo-opettajat voisivat hyödyntää ratkaisua (automaattinen inssi-ajo ehkä kuitenkin vielä futuristinen ajatus tässä vaiheessa).
Liikennesääntöjen noudattamisen seuranta	Reagoimista esimerkiksi nopeusrajoituksiin ja liikennemerkkeihin voidaan seurata analytiikkadatan avulla. Liikennemerkkien osoittama nopeus vs. todellinen GPS:stä/auton järjestelmästä saatu nopeus tai pysähdytäänkö Stop-merkin mukaisesti jne.
Turvallisuusratkaisuja	
Onnettomuustilanteiden analysointi	Jos kuvaavat kamerat ovat julkisessa kulkuneuvossa, niin kaikki onnettomuudet, joissa kyseinen kulkuneuvo on osallisena tallentuu kameralle. Tämä on lähinnä lisäbonus ratkaisulle – erillistä kameraa tähän tarkoitukseen ei enää tarvita. Videokuvaa voidaan analysoida onnettomuutta edeltävältä ajalta ja seurata tilanteen kehittymistä sen jälkeen. Luonnollisesti myös itse

	onnettomuudesta löytyy todistusaineistoa videolta. Erilaiset sensoritiedot täydentävät onnettomuuden analysointia ja selvittelyä. Kerättyä onnettomuusvideota voidaan käyttää analyyttikkamallien opetuksessa.
--	--

4.5.2 Jatkokehitys – järjestelmän kehittäminen

Kuten jo tässä raportissa on aiemminkin mainittu yksi suuri potentiaaleista on erilaisen tiedon yhdistäminen ja sen myötä erilaisten näkökantojen löytäminen. Seuraavassa taulukossa on listattu ehdotuksia mitä ulkoista dataa voisi hyödyntää yhdessä videoanalytiikan kanssa ja mitä hyötyjä siitä olisi.

Taulukko 5. Ulkoisia tietolähteitä ja niiden hyödyntäminen.

Ulkoinen palvelu	Hyöty/Käyttö
Sääpalvelut	Vaikka älypuhelimien antureista voidaan jo päätellä paljonkin säätilasta, voi julkisen sääpalvelun tieto tuoda vielä lisäarvoa. Kustannukset ovat myös yksi tekijä - esimerkiksi analyyttikkamallin opettaminen kuvasta tulkitsemaan säätilaa on paljon työläämpää kuin tiedon nouto sääpalvelusta. Säätila on tärkeä olosuhdetekijä videoanalytiikan toimimisen suhteen ja se on merkittävä tekijä myös liikenteen sujuvuuden kannalta.
Liikenneonnettomuustiedot – reaaliaikainen tieto tai historiallinen tieto	Reaaliaikaisen liikenneonnettomuustiedon avulla voidaan ohjata videoanalytiikkaratkaisua (lähettää vaikkapa lennokka onnettomuuspaikalle). Pitkäaikaisella liikenneonnettomuustilastoilla voidaan yhdessä videoanalytiikan historiatiedon avulla kartoittaa riskialttiit paikat ja pohtia voitaisiinko liikennesuunnittelulla välttää tulevaisuudessa onnettomuuksia.
Reaaliaikainen pysäköintitieto	Pysäköintikartat, pysäköintipalveluiden tieto (Easypark/Parkman) ja videoanalytiikan tieto yhdessä auttavat selvittämään pysäköinnin kokonaistilaa. Edellä olevien lähteiden avulla tiedetään missä saa pysäköidä, missä näistä on tyhjiä paikkoja ja missä paikoissa on auto pysäköity (ja mitkä niistä on maksettu

	palvelun avulla). Näitä tietoja voidaan käyttää pysäköintiratkaisujen suunnittelussa.
Liikennevalojen tiedot	Liikennevalojen tietojen yhdistäminen videoanalytiikkaan auttaa ymmärtämään valojen ajoituksen vaikutuksen liikenteen sujuvuuteen. Esim. Tampereen/Oulun liikennevalo API [10])
Staatistien liikennekameroiden tiedot	Paikallaan olevat kamerat on asennettu tärkeisiin liikenteen solmupisteisiin, mutta staattisuudesta johtuen niiden vaikutusalue on rajallinen. Liikkuvan videon keruuta voidaan käyttää staattisen videon jatkeena selvittäessä vaikkapa liikenteen etenemistä jonkin kriittisen risteyksen jälkeen. ”Liikkuvia videokameroita” voi myös sijoittaa staattisesti/väliaikaisesti johonkin haluttuun sijaintiin. Esimerkiksi rakennuksen ikkunaan tai pysäköity autoon.
Teiden kunnossapitotiedot	Tiestön kunnossapitotiedot (toteutetut, työn alla, aikataulutetut säännölliset, aikataulutetut epäsäännölliset, jne.) voidaan yhdistää videoanalytiikan datan kanssa ja näin voidaan nähdä kunnossapidon vaikutukset liikennemääriin ja historiatiedon avulla voi ennustaa tulevien kunnossapitotoimenpiteiden vaikutusta liikenteeseen. Tätä tietoa voisi myös jakaa palveluna vaikkapa ammattiliikennöitsijöille.
Kaupungin/tapahtumatoimistojen/yms. tapahtumakalenterit	Erilaiset massatapahtumat ja joskus pienemmätkin tapahtumat vaikuttavat liikenteeseen ja pysäköintitilanteeseen merkittävästi (nämä voisi tulkita ”poikkeuksiksi”). Tapahtumien vaikutus liikenteeseen historiallisesti ja sen myötä tietojen hyödyntäminen tulevien tapahtumien liikennevaikutusten ennusteissa on järkevää ja täydentää tilannekuvan kokonaispalettia.

Koska pilotissa käytössä ollut analytiikkaratkaisua voidaan opettaa tulkitsemaan videota paremmin ja tulkitsemaan uusia asioita/kohteita kuvasta, lisää ne huomattavasti ratkaisun tulevaisuuden mahdollisuuksia. Alla olevassa taulukossa listattu muutamia asioita, joita

analytiikalle voisi opettaa (tässä ei ole listattu luvun 4.3 taulukossa listattuja asiakkaan vaatimuksissa esiintyneitä asioita enää toiseen kertaan).

Taulukko 6. Analytiikkamallille mahdollisesti opetettavia asioita

Opetettava asia	Käyttötapaus/Hyöty
Rekisterikilpien tunnistus	Kuvasta tunnistettavien ajoneuvojen rekisteritunnuksen avulla voidaan löytää varastettuja kulkuneuvoja. Lisäksi jos tietoturvasyiden vuoksi rekisterinumero halutaan sumentaa kuvasta, se tulee ensin tunnistaa – muuten sumentaminen ei onnistu.
Kasvojen tunnistus	Liikenteessä kuvatusta videokuvasta tuskin tunnistaa kasvoja (laatu ei riittäne kuin joskus aivan lähitilanteessa ja pysähdyksissä ollessa), mutta videoanalytiikkaa voisi hyödyntää myös staattisissa kameroissa joissain tärkeissä paikoissa (virastot, pankkiautomaatit, liikkeet, asemat, jne.)
Kohteiden tunnistus ja seuranta kuvien välillä (tracking)	Tämä on tärkeä toiminnallisuus, jos halutaan identifioida kohteita ja seurata niitä useamman kuvan yli. Ilman trackingia kohteet tulkittaisiin vain yksittäisiksi kohteiksi, eikä tiedetä, että kyseessä on kahdessa kuvassa itse asiassa yksi ja sama kohde. Kohteiden tunnistus on haasteellista, mutta Esineiden seuranta onnistuu mallintamalla peräkkäisten kuvien eroja yhdessä tunnistusmallin tulosten kanssa. Ajoneuvojen kohdalla rekisterikilpien tunnistus on yksi ratkaisu tunnistukseen. Kasvojen tunnistus toimisi henkilöiden identifiointiin.
Jatkuvan oppimisen järjestelmä	Videota kerätään säännöllisesti eri olosuhteista ja kohteista ja käytetään algoritmien opettamiseen systemaattisesti.
Sään tulkinta videokuvasta	Analytiikalle tulisi opettaa säätilan tunnistamiseen käytettäviä asioita, kuten pitää löytää kuvasta "taivas" ja tulkita onko taivaalla pilviä vai ei (aurinkoinen/pilvinen). "Ilmasta" voi havaita häiriönä sadetta/räntää/lunta.

	Videoanalytiikan lisäksi paikallisen sään päättelyyn voi käyttää tietoa älypuhelimien valosensorista, barometristä ja auton lämpömittarista.
--	--

Yksi merkittävä kokonaisuus, jota pilotissa ei ehditty toteuttamaan, ja mikä tuo paljon lisää potentiaalia ratkaisuun on lisälogiikan rakentaminen metadatan päälle.

Lisälogiikka	Käyttötapaus/Hyöty
Pysähtymisen syy	Kun todetaan auton olevan pysähdyksissä, tarkistetaan kuvasta mikä on sen syy: esimerkiksi Stop-merkki, suojatie ja jalankulkija, jono, liikennevalo, este, pysäköinti. Tämä vaatii analytiikan lisäopetusta, jotta lisäkonteksti tunnistetaan kuvasta.

Teknisiä kehitysideoita on listattu alla olevassa taulukossa.

Taulukko 7. Teknisiä kehitysideoita.

Tekninen kehitysehdotus	Käyttötapaus/Hyöty
Videoanalytiikan upottaminen älypuhelimeen	Videoanalytiikan vieminen kameran viereen hajauttaa laskentaa ja alentaa huomattavasti tiedonsiirron vaatimuksia (jos videoita ei haluta siirtää metadatan lisäksi). Tällä hetkellä analytiikka vaatii kuitenkin niin paljon laskentavoimaa, että nykyisen älypuhelinkannan resurssit ei riitä. Älypuhelin tarvitsee kaistaa myös kameran, GPS:n, sensoreiden, käyttöjärjestelmän ja tarvittavien muiden ohjelmistojen ajamiseen, sekä tiedonsiirtoon. Ideana kannattaa kuitenkin pitää mielessä.
Tiedonsiirto - 5G käyttöönotto	5G:n hyödyntäminen ja testaaminen reaaliaikaiseen videokuvan siirtoon. 5G:n teknisten määritelmien puolesta kapasiteetti pitäisi riittää. Tämä tulee kuitenkin testata käytännössä – miten liikkuvuus, peitto ja muiden käyttäjien saman resurssin

	yhtäaikainen käyttö vaikuttaa 5G:n nopeuteen.
Sääntökone metatiedon käsittelyyn ja päättelyn tekoon	Metadatan päälle voidaan rakentaa lisälogiikkaa ja itse metadatan ja vaikkapa ulkoisen tiedon perusteella voidaan tehdä erilaisia päätelmiä tehdä

4.5.3 Ratkaisun joukkoistamismahdollisuudet

Kuten aiemmin on mainittu, liikkuvan kuvan datan keruussa suositellaan joukkoistamista, jotta saadaan riittävän kattavaa ajankohtaista/reaaliaikaista dataa tarvittavaan tilannekuvan saamiseksi. Joukkoistamisella tarkoitetaan yleensä yrityksen toimintojen ulkoistamista asiakkaiden suoritettavaksi siten, että asiakas otetaan osaksi prosesseja tuottamaan lisäarvoa yritykselle itselleen. ”Asiakkaan” määritelmään sen enemmän takertumatta tässä luvussa on listattu kaikenlaisia mahdollisia käyttäjäkuntia, joita joukkoistamisessa voisi harkita.

Joukkoistaminen vaatii toimiakseen sen, että kaikki osapuolet saavat tilanteesta jotain hyötyä. Videokuvaan vastaan asiakkaan tulee saada jotain sopivaa vastetta takaisin.

Alla olevassa taulukossa on ajatuksia/ideoita joukkoistamisen toteuttamiseksi.

Joukkoistamis-mahdollisuus	Käyttötapaus/Hyöty
Julkinen liikenne – bussit, raitiovaunut	Asentamalla kamerat julkisen liikenteen ajoneuvoihin, voidaan kerätä tietoa itse joukkoliikenteen toimisesta ja liikenteestä yleensä kyseisen reitin varrelta. Säännöllinen reitti ja säännöllinen aikataulu ovat tämän fleetin ominaisuuksia ja etuja. Vastapalveluna videoiden keruulle liikennöitsijä saa myös hyödyllistä informaatiota liiketoimintansa kehittämiseen.
Taksit	Taksien reitit vaihtelevat asiakastarpeiden mukaan. Joitakin vakioireittejä (vakioasiakkaita) saattaa löytyä. Helsingissä löytyy myös erilaisia suosikkikohteita taksimatkoille, kuten lentoasema, rautatieasema, jotkut palvelut ja liikkeet, mutta muuten reitit ovat varsin satunnaisia. Taksien avulla voi myös tilata maksusta halutun reitin pelkästään videoanalytiikan käyttötapauksen kattamiseksi. Taksien saama hyöty liittyy myös datan hyödyntämiseen liiketoiminnan kehittämiseksi. Lisäksi videokuva tarjoaa turvaa ja todistusaineistoa mahdollisten onnettomuuksien yhteydessä. Lisäksi taksikunnalle voi tarjota vastapalveluksena tietoa ruuhkista, liikenneonnettomuuksista ja liikenteeseen vaikuttavista tapahtumista (esim. tapahtumakalenteritiedot, erikoiskuljetukset).
Logistiikkaoperaattorit	Posti, DHL, Rekkaфирmat, lähettipalvelut yms. Tavaraliikennettä on tien päällä paljon. Monesti tavarankuljetus seuraa vakioireittejä,

	mutta tarjolla on myös satunnaisia reittejä. Perustelut tämän fleetin käyttöön ovat samat kuin edellisessä taksien käytössä.
Kaupunkilaiset	Suurimmalla osalla kaupunkilaisista on kameralla varustettu älypuhelin. Kuva tai video varustettuna sijaintitiedolla on kerättävää perustietoa. Sen lisäksi jotakin sensoridataa kannatta harkita käyttötapauksesta riippuen. Erilaisia käyttötarkoituksia, joihin kaupunkilaisia voi valjastaa löytyy useita: - Onnettomuustilannekuvan lähettäminen: Kuvia voi käyttää analytiikan opettamiseen, viranomaisten todisteeksi; eettisyyden rajoissa kuvia voi tarjota lehdistölle, jne. - Huonokuntoisen liikennemerkin kuvaaminen - Esteet tiellä/kadulla - Liukas/auraamaton/hiekoittamaton katu - Palautepalvelu – palautetta/mielipiteitä/ehdotuksia liikennetkaisuuihin - Teemalla ”kappale kauneinta kaupunkia” voi kerätä kaupunkilaisilta näyttäviä kuvia vaikkapa matkailun edistämiseen Palkkiona voi tarjota kaupungin palveluita tai alennuksia niihin (esim. matkalippuja, liikuntapalveluita, jne.). Palkkiota voi antaa kuvakohtaisesti tai jonkin pisteidenkeruumekanismien avulla. Esimerkiksi kuvia pisteytetään ja tietyllä pistemäärällä oikeutetaan palkkioon ja/tai nostoa seuraavalle tasolle. Palveluun lähetettyjä kuvia/videoita voidaan arvioida videoanalytiikalla, eli onko kuva hyödyllinen, riittävän laadukas jne.
Pilottiajajafleet	Ajatuksena on kerätä joukko vapaaehtoisia, jotka palkkiota vastaan voisivat suorittaa (video)kuvaustehtäviä, joita julkaistaan palvelussa. Palveluun rekisteröidytään ja rekisteröidy käyttäjät saavat tietoa tarjolla olevista tehtävistä heti kun niitä julkaistaan (appsiin/sähköpostiin/SMS/yms.). ”Kuvauskeikan” jälkeen käyttäjä lataa keräämänsä materiaalin palveluun ja saa tehtävänannossa mainitun palkkion. Analogiaa palvelulle löytyy monista mielipidemittaus-palveluista.

4.6 Loppusanat

Pilotti oli erittäin hyödyllinen ja opettavainen projekti. Opimme paljon videon analysointiin vaadittavan ratkaisun teoriasta, toteutuksesta, haasteista ja mahdollisuuksista. Alussa asetetut tavoitteet saavutettiin varsin hyvin ja matkan varrella syntyi valtava joukko ideoita, joiden avulla ratkaisua voidaan kehittää ja viedä eteenpäin tulevaisuudessa..

Suuret kiitokset kaikille pilottiin osallistuneille!

5 Termit ja lyhenteet

ADAS	Automatic Drivers Assistance System – kuljettajan automaattinen ajonohjausjärjestelmä. Eutecus järjestelmässä käytetty ohjelmisto.
Annotointi	Annotointi on videon manuaalista merkitsemistä. Kuva kuvalta merkitään siinä havaittavat kohteet (kohdelaji, sijainti kuvassa ja mahdolliset lisämääreet)
EUTECUS	Videoanalytiikkaratkaisu, joka pystyy analysoimaan kuvaa reaaliajassa suoraan kamerasta. Yhdysvaltalainen yritys, jonka ensin Sensity osti elokuussa, ja jonka puolestaan Verizon osti Syyskuussa
Fleet	Ajoneuvojoukko
IOU	Intersection over union Videoanalysoinnin validoinnissa käytetty mittari, joka kertoo vertailtavien kohdetta rajaavien suorakulmioiden leikkauksen suhdetta niiden unioniin
Metadata	Videoanalytiikan tuottamaa tietoa videon/kuvan sisällöstä. Pilotissa metadataan lasketaan myös sijaintitieto. Periaatteessa metadataksi voi kutsua kaikkea analytiikan, GPS:n, sensoreiden ja ulkoisten tietolähteiden tuottamaa täsmätietoa, jota hyödynnetään käyttötapauksissa.
MUVIS	Multimedia Video Indexing and Retrieval System
ReCo Pro	Eutecus-järjestelmän keskusyksikkö, jossa videoanalytiikka toimii
VATIC	Videoiden annotointityökalu: Video Annotation Tool from Irvine, California

6 Lähdeluettelo

- [1] Liikenne- ja viestintäministeriö, "Kohti uutta liikennepolitiikkaa. Älyä liikenteeseen ja viisautta liikkujille. Toisen sukupolven älystrategia liikenteelle," [Online]. Available: <https://www.lvm.fi/documents/20181/799943/%C3%84ly%C3%A4+liikenteeseen+ja+viisautta+liikkujille+Toisen+sukupolven+alystrategia/c939f45a-dbf7-4032-8735-a7e869524c6f?version=1.0>.
- [2] Wikipedia, "A-GPS," [Online]. Available: <https://fi.wikipedia.org/wiki/A-GPS>.
- [3] TABLEAU, "Tableau Software," 2016. [Online]. Available: <http://www.tableau.com/>.
- [4] VGG. [Online]. Available: http://www.robots.ox.ac.uk/~vgg/research/very_deep/.
- [5] "ImageNet," [Online]. Available: <http://image-net.org/>.
- [6] VATIC, "Video Annotation Tool from Irvine, California," 2011. [Online]. Available: <http://web.mit.edu/vondrick/vatic/>.
- [7] DATEX II. [Online]. Available: <http://www.datex2.eu/content/datex-background>.
- [8] ITS Factory, "Traffic Light API," 2015. [Online]. Available: <http://data.itsfactory.fi/files/trafficlights/>.
- [10] DATAMODEL, "Validation and visualization data models.," [Online]. Available: <https://docs.portal.tieto.com/share/page/document-details?nodeRef=workspace://SpacesStore/cdfa9712-f57a-4a7b-b29f-544017509fb0>.
- [11] Eutecus, "Eutecus, Inc," 2016. [Online]. Available: <https://eutecus.com/about/>.
- [12] P. Sermanet, D. Eigen, X. Zhang, M. Matieu, R. Fergus ja Y. LeCun, "OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks," 2014. [Online]. Available: <https://arxiv.org/pdf/1312.6229.pdf>.
- [13] S. Sivaraman ja M. M. Trivedi, "Looking at Vehicles on the Road: A Survey of Vision-Based Vehicle Detection, Tracking, and Behavior Analysis," 2013. [Online]. Available: <http://romisatriawahono.net/lecture/rm/survey/computer%20vision/Sivaraman%20-%20Looking%20at%20Vehicles%20on%20the%20Road%20-%202013.pdf>.
- [14] Technical University of Tampere, "MUVIS framework," 2013. [Online]. Available: <http://muvis.cs.tut.fi/index.html>.
- [15] "DATASOURCES," [Online]. Available: <http://image-net.org/challenges/LSVRC/2016/results#det>.
- [16] Samsung, "Galaxy NEO," [Online]. Available: <http://www.samsung.com/fi/consumer/mobile-devices/smartphones/galaxy-s/SM-G903FZKANEE>.
- [17] Samsung, "Galaxy A3 (2016)," [Online]. Available: <http://www.samsung.com/fi/consumer/mobile-devices/smartphones/galaxy-a/SM-A310FZDANEE>.
- [18] Amazon Mechanical Turk. [Online]. Available: <https://www.mturk.com/mturk/welcome>.

7 Muutoshistoria

Versio	Päiväys	Tekijä	Tarkistaja	Hyväksyjä	Muutoshistoria
V0.1	2016-10-10	Rauno Roppo	<nimi>	<nimi>	Luonnos
V0.2	2016-11-14	Martti Sutinen			Luonnos
V1.0	2016-11-15	Rauno Roppo			Asiakkaalle toimitettava luonnos (luottamuksellinen)
V2.0	2016-11-25	Rauno Roppo	Mikko Lehtonen		Asiakkaalle toimitettava julkinen versio
V2.1	2016-12-12	Rauno Roppo			Stilistisiä virheitä korjattu