

**Lari Salminen**

**Markovin piilomallit ajoneuvojen autonomisissa  
toiminnoissa**

Tietotekniikan kandidaatintutkielma

12. toukokuuta 2021

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

**Tekijä:** Lari Salminen

**Yhteystiedot:** lajyalsa@student.jyu.fi

**Ohjaaja:** Leevi Annala

**Työn nimi:** Markovin piilomallit ajoneuvojen autonomisissa toiminnoissa

**Title in English:** Hidden Markov models in the autonomous processes of vehicles

**Työ:** Kandidaatintutkielma

**Opintosuunta:** Tietotekniikka

**Sivumäärä:** 29+0

**Tiivistelmä:** Tässä tutkielmassa tarkastellaan Markovin piilomallien käyttöä ajamista avustavien ja itseohjautuvien ajoneuvojen alalla. Tutkimuksessa havaittiin, että niiden käyttö on ollut yleistä etenkin kuljettajan aikomusten ennustamisessa. Vanhana koneoppimisen menetelmänä piilomallit ovat laskennallisesti edullisia ja luotettavaksi havaittuja ajasta riippuvien havaintojen käsittelemiseen.

**Avainsanat:** Markovin piilomallit, koneoppiminen, itseohjautuvat ajoneuvot

**Abstract:** This thesis examines the use of hidden Markov models in the field of assisted and autonomous vehicles. The study found that their use has been common especially in prediction of driver intentions. As an old machine learning method they have been found computationally cheap and reliable in processing time-dependent observations.

**Keywords:** hidden Markov models, machine learning, self-driving vehicles

## Kuviot

Kuvio 1. Esimerkkikaavio kolmitilaisesta Markovin prosessista.....	5
Kuvio 2. Piilomallissa jokainen tila mihin siirrytään tuottaa jonkin havainnon. ....	7

## Sisällys

1	JOHDANTO .....	1
2	ITSEOHJAUTUVAT JA AVUSTAVAT AUTOT .....	2
3	MARKOVIN MALLIT .....	5
	3.1 Markovin ketjut.....	5
	3.2 Markovin piilomallit .....	6
4	MARKOVIN PIILOMALLIT KULKUNEUVOISSA .....	14
	4.1 Kuljettajan aikomusten ennustaminen.....	14
	4.2 Kuljettajan tilan arviointi .....	17
	4.3 Autonomiset toiminnot.....	18
5	YHTEENVETO.....	21
	LÄHTEET .....	22

# 1 Johdanto

Moottoriajoneuvot ovat parin viime vuosikymmenen aikana alkaneet muuttua yhä älykkäämmiksi. Yksinkertaisimmillaan ne ovat alkaneet varoittaa ja tiedottaa kuljettajaa eri asioista kuten kaistan rajoista ja auton nopeudesta. Myös ajamista avustavissa järjestelmissä on alkanut kehitys, jossa vaaratilanteissa hyödynnetään tekoälyä ohjaamaan ajoneuvoa kuljettajan sijaan. Autonomisista ajoneuvoista olisi suuri hyöty yhteiskunnalle. Ne muun muassa vähentäisivät liikenneonnettomuuksia, parantaisivat liikennettä ja mahdollistaisivat vanhusten ja sairaiden matkustuskyvyn säilyttämisen (Broggi ym. 2016).

Viime vuosina teknologia on edistynyt jo niin pitkälle, että idea täysin autonomisista kulkuneuvoista on alkanut siirtyä scifikirjallisuudesta arkitodellisuuteen, ja niin tieteellinen kuin kaupallinenkin kiinnostus on kohdistunut sen toteuttamiseen käytännöllisesti ja turvallisesti. Autonomisen kulkuneuvon täytyy pystyä tekemään päätöksiä sensoreista saatujen havaintojen perusteella, joihin liittyy tuntemattomia tekijöitä. Auton täytyy esimerkiksi osata tunnistaa jos toinen tielläkulkija aikoo vaihtaa kaistaa, mutta sensorit eivät voi nähdä mitä sen toisen auton sisällä tapahtuu, vaan päätös täytyy tehdä sillä hetkellä saatavilla olevien havaintojen avulla.

Yksi tapa mallintaa tällaista tilaa ajan mittaan vaihtavaa systeemiä jossa varsinaisia tiloja ei voida suoraan havaita ovat Markovin piilomallit (Hidden Markov models, HMM), jotka ovat saaneet nimensä venäläisen matemaatikon Andrei Markovin mukaan, ja joiden perusteorian julkaisi Baum ja Petrie (1966). Markovin piilomallit on tunnettu jo 60-luvulta lähtien, ja niiden käyttö on viime vuosikymmeninä noussut hallitsevaan asemaan (Mor, Garhwal ja Kumar 2020) monilla tieteenaloilla.

Kirjallisuuskartoituksen tarkoituksena on tarkastella, miten tätä vanhaa koneoppimisen menetelmää käytetään lähiaikoina yhä kiihtyvämmin kehittyvällä autonomisen ajamisen alalla. Seuraavassa kappaleessa käsitellään erilaisten autonomisten toimintojen historiaa, ja erilaisia sensoreita joiden avulla autonominen ajoneuvo tekee päätöksiä. Sitten esitellään Markovin ketjut, ja niiden pohjalta jatketaan Markovin piilomalleihin. Kappaleessa 4 katsotaan, miten piilomalleja on hyödynnetty niin avustavissa kuin autonomisissakin ajoneuvoissa.

## 2 Itseohjautuvat ja avustavat autot

Ensiaskleet aktiiviseen ajamisen avustukseen otettiin jo 70-luvun lopulla kun lukkiutumisenestojärjestelmät siirtyivät sarjatuotantoon, jota seurasi luistonesto joitain vuosia myöhemmin (Bengler ym. 2014). Ensimmäinen massatuotettu kulkuneuvo joka oli vakiona varustettu ajonvakautusjärjestelmällä, joka aktiivisesti yrittää pitää kulkuneuvon hallinnassa, ilmestyi markkinoille vuonna 1998 (Lie ym. 2006), ja on vuodesta 2014 eteenpäin pakollinen varuste Euroopan Unionin sisällä myytävissä autoissa (Bengler ym. 2014). Galvani (2019) määrittelee tällaiset pelkästään yhtä ajoneuvon sisäistä dataa (esim. pyörän nopeutta) lukevat järjestelmät kuljettajan apujärjestelmiksi (Driver Assistance System, DAS).

90-luvulla alkunsa saivat myös aktiiviset järjestelmät jotka tarkkailevat ympäröivää maailmaa ulkoisilla sensoreilla, kuten erilaiset pysäköintiä avustavat järjestelmät ja sopeutuvat vakionopeudensäätimet jotka pystyvät pitämään turvallisen välimatkan edellä ajamaan autoon (Bengler ym. 2014). Koska tällaiset järjestelmät eivät vain tarkkaile ulkomaailmaa, mutta myös joutuvat tulkitsemaan sitä dataa jonkinlaista tekoälyä käyttäen, Galvani (2019) erottaa ne yllä mainituista DAS-järjestelmistä kutsumalla niitä edistyneiksi kuljettajan apujärjestelmiksi (Advanced Driver Assistance System, ADAS). Jo muutamia vuosia myöhemmin alkoi kehitys järjestelmiin, jotka pystyivät sekä varoittamaan törmäyksistä että jarruttamaan automaattisesti niiden vakavuuden lieventämiseksi (Kodaka ym. 2003). Myös satelliittipaikannusta hyödyntävät navigaatiojärjestelmät alkoivat ilmestyä autoihin, ja matkapuhelinteknologian yleistyessä alkoivat muuttua yhä edullisemmiksi ajan myötä (Bengler ym. 2014).

Muutamaa viime vuotta lukuunottamatta tutkimus on keskittynyt ADAS-järjestemien kehitykseen täysin autonomsen ajamisen sijaan, lähinnä lainsäädäntöön liittyvistä syistä (Broggi ym. 2016). Lopullinen päämäärä jossa moottorikulkuneuvot pystyvät itsenäisesti liikkumaan mihin tahansa matkustajat haluavat, missä olosuhteissa tahansa, on vielä vuosien päässä. On kuitenkin eri autonomian asteita, joita autot voivat saavuttaa teknologian parantuessa. Society of Automotive Engineers (2018) määrittelee standardissaan kuusi eri tasoa nollassa viiteen, missä viides taso on se täysin autonominen maali, ja nollassa auto pystyy lähinnä varoittamaan kuljettajaa eri asioista ja ehkä jopa tekemään hätäjarrutuksen kuskin puolesta. Tasot jakautuvat suurin piirtein kahteen eri osa-alueeseen: 0-2 ovat avustetun ajamisen osa-alueita,

ja 3-5 ovat autonomista ajamista. Vielä kolmannella tasolla kulkuneuvo saa määritelmän mukaan pakottaa kuljettajaa ajamaan itse. Neljännellä tasolla kulkuneuvo pystyy jo toimimaan täysin itsenäisesti, mutta vain tietyissä tilanteissa – yleensä ne tarvitsevat erillistä infrastruktuuria päätöksenteossaan eivätkä siten pysty ajamaan kaikkialla. DAS ja ADAS-järjestelmien välisillä eroilla ei näiden automaatiotasojen kannalta ole merkitystä, vaan molempia esiintyy kaikilla automaation tasoilla (Galvani [2019](#)).

Muitakin määritelmiä autonomian eri tasoille on olemassa. Saksan valtion maantietutkimuksen instituutti BAST määrittelee viisi eri tasoa, missä avustettu ajaminen on toisella tasolla ja kolme autonomista tasoa erottuvat sen perusteella kuinka paljon kuljettajaa vaaditaan vahtiin ajoneuvon tilaa (Gasser ja Westhoff [2012](#)). Yhdysvaltain maantieliikenneturvallisuushallinto antaa myös viisi eri tasoa, mitkä perustuvat osittaisen automaation määriin (NHTSA [2013](#)).

Paden ym. ([2016](#)) luokittelee autonomisen kulkuneuvon tehtävät hierarkkisesti. Ensin sensorit keräävät dataa, ja sitten päätöksenteko tehdään neljässä eri kerroksessa: Ylimpänä suunnitellaan reitti karttadatan perusteella. Seuraavana hierarkiassa on päätös käyttäytymisestä. Tähän kerrokseen kuuluu yleiset tehtävät kuten mm. käännökset, liikennevaloihin pysähtyminen ja muiden tielläliikkujien kuten myös lakien huomioonottaminen. Kun tehtävä liike on tiedossa, täytyy kulkuneuvon suunnitella tehtävän suorittava polku jonka se pystyy tekemään turvallisesti ja matkustajille mukavasti. Badue ym. ([2020](#)) lisää seuraavaksi vielä esteenväistön omaksi kerroksekseen, mikä muokkaa polkua jos se havaitsee, että törmäys ympäristön tai jonkun toisen tielläliikkujan kanssa tapahtuisi polulla. Lopuksi sen täytyy ohjata fyysisten ohjaimien avulla itsensä polkua pitkin, reaktiivisesti samalla korjaten prosessin aikana syntyneitä virheitä.

Nykymaailman kulkuneuvoihin pystytään asentamaan monia erilaisia sensoreita joilla voidaan havaita ympäristöä. Yurtsever ym. ([2020](#)) luettelee muun muassa tutkan, valotutkan, ultraäänen ja erityyppiset kamerat kuten stereo- tai lämpökamerat, joiden valintaan voivat vaikuttaa mm. kantama, tarkkuus, koko ja paino. Yleensä tutkaa käytetään pidemmän välimatkan esteiden tunnistamiseen, ja infrapuna- sekä ultraäänitunnistimilla lähellä olevia esteitä (Broggi ym. [2016](#)).

Teknologisen näkökulman lisäksi autonomisen ajamisen täytyy myös rakentaa hyväksyntää kuluttajien keskuudessa. Kyriakidis, Happee ja Winter (2015) kartoittivat kansainvälisen kyselyn avulla ihmisten mielipiteitä automaatiota kohtaan. Keskimäärin vastaajien mielestä manuaalisesti ajaminen on nautinnollisin ajamisen tapa, mutta 69% vastaajista olivat kuitenkin sitä mieltä, että autonomiset ajoneuvot saavuttavat 50% markkinaosuuden vuoteen 2050 mennessä. Suurin huoli vastaajien kesken oli ajoneuvojen ohjelmistojen hakkerointi tai väärinkäyttö, mutta myös lakiin ja yksityisyydenturvaan liittyvät asiat tulivat esille. Työ kuitenkin jatkuu kaikilla osa-alueilla, ja asenteet voivat muuttua. Kuten lukkiutumisenesto- ja luistonestojärjestelmät osoittivat, ihmiset ajan mittaan hyväksyvät ajamisen automatisoinnin luotettavilla järjestelmillä, minkä voidaan olettaa olevan totta myös tulevaisuudessakin (Broggi ym. 2016).




### 3 Markovian mallit

Tässä kappaleessa esitellään Markovian piilomallien perusteet ja niihin tarvittavat esitiedot. Ensin aiheena ovat Markovian ketjut, joiden päälle ymmärrys piilomalleista rakennetaan. Piilomalleihin liittyen esitellään myös kolme keskeistä ongelmaa, joihin vastaamalla piilomallien avulla työskennellään. Kappale mukailee pitkälti Rabinerin (1989) artikkelia aiheesta.

#### 3.1 Markovian ketjut

Markovian ketjut ovat stokastisia, eli ajassa satunnaisia askelia ottavia prosesseja. Tässä tapauksessa askeleella tarkoitetaan tilanvaihtoa yhdestä toiseen (tai takaisin samaan). Ne erottuvat muista samantapaisista systeemeistä sillä, että sen seuraava tila riippu vain systeemin senhetkisestä tilasta, eikä mistään aiemmasta tilasta. Tilasiirtymistä voidaan muodostaa aikasarja  $S$  (Markovian ketjujen tapauksessa voidaan myös puhua havaintosarjasta  $O$ ), esimerkiksi  $S = \{S_3, S_3, S_3, S_1, S_1, S_3, S_2, S_3\}$ , mikä kuvaa kolmetilaisen Markovian ketjun havaittuja tilanmuutoksia ajan kuluessa. Kuvitellaan vaikka että eri tilat kuvaavat säätä:  $S_1$  aurinkoista,  $S_2$  pilvistä ja  $S_3$  sadetta, ja aikaväli esimerkiksi keskipäivällä joka päivä.



Kuvio 1. Esimerkkikaavio kolmetilaisesta Markovian prosessista.

Markovin ketjussa tilalla  $i$  on joku todennäköisyys siirtyä tilaan  $j$ , jota merkitään  $a_{ij}$ . Näistä voidaan koostaa tilasiirtymämatriisi  $A$ . Matriisin rivi on lähtötila ja sarake maali, jolloin jokaisen rivin summa täytyy olla 1 - joku tilasiirtymä tapahtuu ajan edetessä, vaikka se olisikin takaisin samaan. Kuvio 3.2 näyttää esimerkkimatriisin joka voisi kuvata kuvion 1 tilasiirtymätodennäköisyyksiä.

$$A = \begin{bmatrix} 0.33 & 0.33 & 0.34 \\ 0.05 & 0.55 & 0.40 \\ 0.70 & 0.20 & 0.10 \end{bmatrix} \quad (3.1)$$


Koska tilasiirtymien todennäköisyydet ovat tiedossa, voidaan mallista laskea jonkun sarjan  $S$  todennäköisyys yksinkertaisesti kertomalla sarjassa esiintyvien tilasiirtymien todennäköisyydet keskenään (sarjan ensimmäisen tilan todennäköisyys on 1), ja näinollen ennustaa sen käytöstä jos esimerkiksi mitattaisiin päivittäistä säätä kuten aiemmin. Haasteena on tietenkin asettaa mallin todennäköisyydet todellisutta tai haluttua ilmiötä vastaavaksi, mikä voidaan tehdä mittaamalla aiemmista havainnoista saatuja todennäköisyyksiä. Esimerkiksi tekstinpätkästä voidaan muodostaa Markovin ketju tekemällä joka sanasta oma tila, ja laskemalla mikä sana sitä seuraa ja kuinka usein. Jokaisesta tilasta voidaan myös kysyä, kuinka kauan se keskimäärin pysyy sinä tilassa, eli tekee tilasiirtymän takaisin itseensä. Yksinkertaisesti odotettu keskimääräinen pysyvyys on käänteisluku siitä todennäköisyydestä, millä tila vaihtuu johonkin muuhun kuin itseensä. Ylläolevasta matriisista voidaan laskea, että ensimmäisellä rivillä –  $S_1$  eli aurinkoisella säällä – todennäköisyys siirtyä johonkin muuhun kuin itseään vastaavaan sarakkeeseen on noin kaksi kolmasosaa, joten sen käänteisluvusta saadaan selville, että aurinkoinen sää pysyy keskimäärin kolme kahdesosaa, eli puolitoista päivää.

## 3.2 Markovin piilomallit

Toistaiseksi ollaan käsitelty tilannetta, missä halutut tilat ovat suoraan mitattavissa. Laajennetaan sääesimerkkiä siten, että mittajalla ei ole suoraa tapaa nähdä mikä vallitseva sää on, mutta puoliltapäivin saapuvalla postinkantajalla on sisäkäytävälle tullessaan päällä joko t-paita, pitkähihainen paita tai sadetakki. Sää voi vaihtua nopeasti, joten mikään asuste ei anna suoraa vahvistusta siitä, minkälainen sää ulkona on tasan mittaushetkellä, mutta on huomatt-

tavasti todennäköisempää että ulkona sataa sillä hetkellä jos hänellä on sadetakki päällään. Tällaista mallia, jossa Markovin ketju ei ole suoraan havaittavissa mutta tilasiirtymän ohessa saadaan siitä probabilistisesti riippuva havainto, kutsutaan Markovin piilomalliksi.

Markovin ketjujen tapauksessa mainitsin, että aikasarjaa  $S$  voidaan myös kutsua havaintosarjaksi  $O$ , koska Markovin ketjusta saatavat havainnot ovat suoraan systeemin tiloja. Markovin piilomallissa on tavallisen Markovin ketjun, jossa on  $N$  eri tilaa, lisäksi joukko havaintoja  $M$ , ja jokaisella tilalla on omat todennäköisyytensä generoida yksi näistä havainnoista. Kuten tilasiirtymistä, näistä havainnon tuottamistodennäköisyyksistä voidaan luoda havaintomatriisi  $B$ .



Kuvio 2. Piilomallissa jokainen tila mihin siirrytään tuottaa jonkin havainnon.

Luodaan esimerkin vuoksi postimiesesimerkille havaintomatriisi. Rivit ovat säätilat niinkuin aiemminkin, sarakkeet ovat järjestyksessä t-paita, pitkähihainen, sadetakki.

$$B = \begin{bmatrix} 0.60 & 0.35 & 0.05 \\ 0.35 & 0.45 & 0.20 \\ 0.10 & 0.20 & 0.70 \end{bmatrix} \quad (3.2)$$

Koska varsinaiset tilat ovat piilossa, täytyy myös olla aloitustodennäköisyysjakauma  $\pi$ , mikä kertoo kuinka todennäköistä on, että joku tila on aikasarjan ensimmäinen. Tilaa ajanhetkellä  $t$  merkitään  $q_t$ .

$$\pi = (0.34, 0.33, 0.33) \quad (3.3)$$

Markovin piilomallilla on siis kaksi parametria: Tilojen määrä  $N$ , havaintosymbolien mää-

rä  $M$ , sekä kolme todennäköisyyksien mitta: tilasiirtymämatriisi  $A$ , havaintomatriisi  $B$ , ja alkutilajakauma  $\pi$ , eli

$$\lambda = (N, M, A, B, \pi) \quad (3.4)$$

Toisaalta, koska havaintomatriisin  $B$  dimensioista voidaan suoraan lukea tilojen ja havaintojen lukumäärä, voidaan Markovin piilomalli tiivistää kolmeen eri parametriin.

$$\lambda = (A, B, \pi) \quad (3.5)$$

Jotta Markovin piilomalleista olisi mitään hyötyä, niille on kolme keskeistä ongelmaa joille mallin käyttäjä yleensä haluaa vastauksen:

1. Havaintosarjasta  $O$  ja mallista  $\lambda = (A, B, \pi)$ , miten laskea  $P(O|\lambda)$ , eli todennäköisyys havaintoketjulle oletuksella että malli pätee?
2. Havaintosarjalle  $O$  ja mallille  $\lambda$ , miten valitaan vastaava tilasarja  $Q$ , joka on jossain mielessä optimaalinen, eli selittää havainnot parhaiten?
3. Miten säädetään mallin parametreja  $\lambda = (A, B, \pi)$  jotta voidaan maksimoida  $P(O|\lambda)$ ?

$P(O|\lambda)$  voidaan myös ajatella mittaavan mallin sopivuutta havaintoihin, ja sen avulla voidaan vaikka mitata kilpailevien mallien suorituskykyä. Vastaus on laskettavissa suoraan, mutta ei polynomisessa ajassa, eli tehokkaampi keino on löydettävä jotta ratkaisu löytyy myös käytännössä. Tällainen tehokkaampi algoritmi on olemassa, ja sitä kutsutaan eteenalgoritmiksi (Forward algorithm).

Ensin esitellään muuttuja  $\alpha_t(i)$ , joka määritellään

$$\alpha_t(i) = P(O_1 O_2 \cdots O_t, q_t = S_i | \lambda) \quad (3.6)$$

eli todennäköisyys havaintosarjalle aikaan  $t$  asti (mikä on osa  $T$ :n pituisesta sarjasta) ja sille että ajassa  $t$  tila on  $S_i$  oletuksella että malli  $\lambda$  pätee. Sen arvo voidaan laskea rekursiivisesti seuraavia laskuja hyödyntäen:

$$\alpha_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N. \quad (3.7)$$

$$\alpha_{t+1}(j) = \left[ \sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1}), \quad 1 \leq t \leq T-1, \quad 1 \leq j \leq N. \quad (3.8)$$

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (3.9)$$

Lasketaan sääesimerkin avulla todennäköisyys sille, että malli tuottaa havaintosarjan  $O = \{t\text{-paita, pitkähihainen, pitkähihainen, sadetakki}\}$ , tai niiden järjestysnumeroita käyttäen  $O = \{1, 2, 2, 3\}$ . Laskennassa täytetään taulukkoa, jossa riveillä on eri tilat ja sarakkeina T eri ajanhetkeä, tässä tapauksessa neljä. Lauseessa (3.7) lasketaan ensimmäiseen sarakkeeseen todennäköisyys sille, että käsiteltävissä oleva tila on alkutila JA että se tuottaa havainnon  $O_1$ .

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0,204			
pilvistä	0,1155			
sadetta	0,033			

Loppu taulukko täytetään lausetta (3.8) käyttäen. Se on hyvin samankaltainen kuin edeltävä lause, mutta aloitustodennäköisyyden sijaan lasketaan summa niille todennäköisyyksille, että edellisen sarakkeen tiloista päädytään juuri sille riville. Toisen sarakkeen ylimmälle solulle lasku avattuna olisi siis  $\alpha_2(1) = (\alpha_1(1)a_{11} + \alpha_1(2)a_{21} + \alpha_1(3)a_{31})b_{12}$ . Siihen asti kulkeva todennäköisyys  $\alpha_t(j)$  tarkoittaa siis taulukossa  $\alpha_{sarakke}(rivi)$ , eli toisinpäin kuin tilasiirtymä- ja havaintomatriiseista saatavat  $a_{ij}$  ja  $b_{ij}$ .

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0,204	0,04810575	0,01938662	0,00088348
pilvistä	0,1155	0,06185025	0,02492565	0,0035339
sadetta	0,033	0,027489	0,01107807	0,01236866

Lopullinen tulos saadaan lauseessa (3.9) yksinkertaisesti summaamalla yhteen viimeisen sarakkeen todennäköisyydet, mikä pyöristettynä on noin 0,0168. Luku itsessään ei kerro pal-

joa, sillä malli pystyy tuottamaan suuren määrän erilaisia neljän pituisia havintosarjoja, joten todennäköisyys yksittäiselle sarjalle on melkein aina hyvin pieni. Kuten ennen algoritmin lauseita todettiin, se on kuitenkin hyödyllinen verrattaessa muiden mallien todennäköisyyksiin tuottaa sama havintosarja. Algoritmi voidaan suorittaa polynomisessa ajassa, mikä tekee siitä käytännöllisen myös suurille tila-avaruuksille ja havaintoketjuille.

Toiseen kysymykseen voi olla monia eri menettelytapoja riippuen siitä, miten määrittelee optimaalisen tilasarjan. Sille, että etsitään yksi paras sarja  $Q$  mikä selittää koko havintosarjan  $O$  sillä oletuksella että malli pätee on olemassa algoritmi, jonka keksi Andrew Viterbi (Viterbi [1967]) ja sitä kutsutaankin usein Viterbin algoritmiksi. Määritellään muuttuja

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P(q_1 q_2 \dots q_t = i, O_1 O_2 \dots O_t | \lambda) \quad (3.10)$$

mikä on todennäköisin polku ajanhetkellä  $t$  joka selittää aiemmat havainnot ja päättyy tilaan  $S_i$ . Induktiivisella päättelyllä saadaan

$$\delta_{t+1}(j) = [\max_i \delta_t(i) a_{ij}] b_j(O_{t+1}) \quad (3.11)$$

Ylläolevasta täytyy kirjata muistiin millä  $t$ :n ja  $j$ :n arvoilla se maksimoituu. Sitä varten otetaan käyttöön taulukko  $\psi_t(j)$ . Algoritmin aloitus on seuraava:

$$\delta_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N. \quad (3.12)$$

$$\psi_1(i) = 0 \quad (3.13)$$

eli samalla tavalla kuin eteen-algoritmissa alustetaan taulukon ensimmäinen sarake havaintotodennäköisyyksillä, ja parhaan tuloksen seurannan sarake nolnaan, koska ei ole mielekästä kysyä mistä tilasta todennäköisimmin saavuttiin ensimmäiseen tilaan. Ensimmäinen taulukko alustuu täsmälleen samalla tavalla kuin aiemmassa esimerkissä:

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0,204			
pilvistä	0,1155			
sadetta	0,033			

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0			
pilvistä	0			
sadetta	0			

Alun jälkeen tehdään loppu taulukko rekursion avulla:

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(O_t), \quad 2 \leq t \leq T, \quad 1 \leq j \leq N. \quad (3.14)$$

$$\psi_t(j) = \operatorname{argmax}_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}], \quad 2 \leq t \leq T, \quad 1 \leq j \leq N. \quad (3.15)$$

Aiemmin näytettyyn eteen-algoritmiin verraten menetelmä toimii hyvin samalla tavalla, mutta aiemmalla ajanhetkellä olevien todennäköisyyksien summaamisen sijaan otetaan vain suurin todennäköisyys, ja kirjataan aputaulukkoon ylös mikä tila  $i$  tuotti sen todennäköisyyden.

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0,204	0,023562	0,00339864	0,0000848232
pilvistä	0,1155	0,030294	0,007497765	0,00082475415
sadetta	0,033	0,013872	0,00242352	0,0020993742

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0	1	3	3
pilvistä	0	1	2	2
sadetta	0	1	2	2

Viimeisellä ajanhetkellä  $T$  todennäköisin tila on se, mille saavutettiin suurin todennäköisyys sarakkeessa, eli tässä tapauksessa sade:

$$q_T^* = \operatorname{argmax}_{1 \leq i \leq N} [\delta_T(i)] \quad (3.16)$$

Kaikki edeltävät tilat saadaan tarkistamalla mikä tila on merkitty aputaulukkoon sillä rivillä, missä todennäköisyys on suurin:

$$q_t^* = \psi_{t+1}(q_{t+1}^*) \quad (3.17)$$

	$O_1$	$O_2$	$O_3$	$O_4$
aurinkoista	0	1	3	3
pilvistä	0	1	2	2
sadetta	0	1	2	2

Eli havainnot parhaiten selittävä tilasarja  $Q$  olisi siis  $\{aurinko, pilvi, pilvi, sade\}$ . Todennäköisyys tälle tilasarjalle on juuri se viimeisen todennäköisimmän tilan todennäköisyys, mikä tässä tapauksessa on kolmannen rivin tulos, eli noin 0,21%:

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad (3.18)$$

Tässä tapauksessa löydetyt tilat olivat juuri ne, mitä voisi odottaa: Aurinkoisella säällä postimiehellä on t-paita, pilvisellä pitkähihainen ja sateella sadetakki. Näin ei aina kuitenkaan käy. Jos esimerkiksi ensimmäinen puolisko havaintoja on sadetakkia, ja toinen puolisko pitkähihaista, eli  $\{3, 3, 2, 2\}$ , niin algoritmi laskee todennäköisimmäksi tilasarjaksi  $\{pilvi, sade, aurinko, pilvi\}$ . Syy tähän voidaan nähdä tarkastelemalla tilasiirtymämatriisia: Sadetilalla on tässä mallissa paljon suurempi todennäköisyys siirtyä aurinkoon kuin itseensä, mikä vaikuttaa enemmän kuin se, että se on tila mikä todennäköisimmin tuottaa sadetakkihavainnon.

Vastaus kolmanteen kysymykseen, eli miten mallin  $\lambda$  parametreja säädetään siten että se suurin piirtein approksimoi haluttua ilmiötä, on huomattavasti monimutkaisempi. Siitä ei myöskään yleensä kirjoiteta paljoa, vaan tutkijat keskittyvät siihen, miten signaalia käsitellään siten, että siitä saadaan havaintoketjuja koulutettavalle HMM:lle. Tästä syystä asiaan



käytettävää algoritmia ei käsitellä tässä katsauksessa kovin syvällisesti. Riittää tiedostaa, että koulutusalgoritmi on olemassa, ja se saavuttaa vain lokaaleja maksimeja, eli satunnaisilla aloitusarvoilla mahdollisesti saavutetaan eri lopputulos, joita voidaan sitten vertailla keskenään.

On myös pidettävä mielessä, että tässä kappaleessa käsiteltiin vain piilomalleja, missä on rajallinen määrä yksittäisiä havaintosymboleita. Yleensä tutkimuksessa havainnot ovat useammista eri arvoista koostuvia vektoreita, tai jatkuvaa dataa. Niiden käsittelyyn liittyvä matematiikka jätetään myös lukijan omalle mielenkiinnolle luettavaksi Rabinerin (1989) tutoriaalista, sillä kappaleen tarkoituksena oli havainnollistaa piilomallien toimintaa perustasolla.

## 4 Markovin piilomallit kulkuneuvoissa

Tässä kappaleessa yhdistetään edellä olleet asiat ja tarkastellaan Markovin piilomallien käyttöä avustetussa ja autonomisessa ajamisessa. Koska HMM:t ovat soveltuvia säännöllisyyksien tunnistamiseen, niin sen käyttö enimmäkseen rajoittuu eri sensoreista saatavan datan prosessointiin. Ensin tarkastellaan, miten niitä käytetään kuljettajan aikomusten ennustamiseen, jotta muun muassa ajamista avustavat toiminnot pystyvät tekemään tehtävänsä oikeaan aikaan kuljettajaa häiritsemättä. Sitten on vuorossa kuljettajan tilan valvominen, esimerkiksi juopumisen tai väsymyksen tunnistaminen, jotta älyauto pystyy estämään mahdollisen onnettomuuden. Lopuksi käsitellään yleiset autonomiset toiminnot joita voidaan käyttää myös avustetussa ajamisessa, mutta joiden tarkoitus on saada autolle itselleen informaatiota ympäröivästä tilasta jotta se pystyy älykkääseen päätöksentekoon.

Vaikka se ei suoraan ole autonomisen ajamisen toiminto, Janssen ym. (2019) esittelevät formalisoidun Markovin piilomalleihin perustuvan kehyksen sille, miten kuljettajalla ei välttämättä ole oikeaa uskomusta siitä, mitkä toiminnot osittain autonomisessa kulkuneuvossa ovat milloinkin ihmisen vastuulla, koska kulkuneuvon autonomian taso saattaa muuttua hetkestä toiseen riippuen järjestelmän tukemista olosuhteista.

### 4.1 Kuljettajan aikomusten ennustaminen

Tärkeä osa ajamista avustavista prosesseista on kuljettajan aikomusten ennustaminen. Jos auto pystyy jarruttamaan tai kääntämään rattia automaattisesti estääkseen onnettomuuden, sen pitää myös luotettavasti pystyä tunnistamaan milloin kuljettaja on tilanteen tasalla ja milloin ei, jottei synny epäluottamusta kuljettajan ja järjestelmän välille. Aikomusten ennustaminen voidaan muotoilla piilomallien evaluaatio-ongelmaksi, eli millä todennäköisyydellä kyseinen malli on generoinut havaintosarjan (Berndt, Emmert ja Dietmayer 2008). Tämä on aiemmin mainittu ensimmäisenä keskeisenä kysymyksenä piilomalleissa.

Variaatio piilomalleista, jota on hyödynnetty aikomusten ennustamiseen liikenteessä, on autoregressiivinen sisääntulo-ulostulo HMM (autoregressive input-output HMM, AIO-HMM), missä sisääntuloparametrit vaikuttavat piilotettuihin tiloihin, jotka generoivat toisistaan ajas-

sa riippuvia havaintoja. Jainin ym. (2015) mallissa sisääntulo on kulkneuvon ulkoiset sensorit kuten kamerat tai GPS-paikannin, piilotetut tilat ovat kuljettajan aikomukset, ja havainnot ovat auton sisäiset tapahtumat, eli tässä tapauksessa kamerat jotka kuvaavat kuljettajaa. Mallin tarkoituksena on siis se, että ulkoiset havainnot vaikuttavat sisäisiin tapahtumiin, missä tavallisessa piilomallissa kaikki havainnot ovat toisistaan riippumattomia. Akai ym. (2019) päätyivät myös käyttämään samantapaisia malleja aikomusten ennustamiseen, mutta sisäisten kameroiden sijaan kuljettajan katsetta seurataan siihen tarkoitetuilla silmälasilla. Molemmat kokeet tuottavat verrattain suuria onnistumisprosentteja, mikä antaa hyvän kuvan ulkopuolisen ja menneen informaation huomioonottavien AIO-HMM:ien luotettavuudesta kyseisessä tehtävässä.

Kaistanvaihdon tunnistaminen on myös tärkeä osa ajoa avustavia järjestelmiä, jotta järjestelmä osaa tunnistaa milloin kuljettaja on ajoneuvon hallinnassa. Kuge ym. (2000) tunnistivat piilomalleilla kolmea erilaista liikettä: kaistalla pysyminen, kaistanvaihto, ja hätätilanteessa kaistanvaihto. Havaintoarvoina käytettiin pelkästään ratista saatavaa dataa: Kulma, kulmanopeus ja käännösvoima. Jokaiselle eri liikkeelle koulutettiin oma HMM, ja luokittelu tapahtui laskemalla mikä kolmesta mallista soveltui parhaiten havaintosarjaan. Jakamalla jatkuvat datan sisääntulon pieniin pätkiin tutkijat pystyivät soveltamaan mallia jatkuvaan ajonaikaiseen tunnistukseen.

On myös mahdollista, että järjestelmä sekoittaa kaistanvaihdon käännöksiin, etenkin mutkikkailta teillä. Tran ym. (2015) käyttivät mallia, jossa auton ohjausdata (ratin käänнос, polkimet) ja tietyt tilaan liittyvät parametrit kuten kiihtyvyys, nopeus ja suunta syötetään moniulotteisena piirrevektorina havainnoiksi kuudelle eri HMM:lle. Ne on kukin koulutettu tunnistamaan yhtä liikettä kuudesta: Seis, "ei-seis", kaistanvaihto vasemmalle, kaistanvaihto oikealle, käänнос vasemmalle ja käänнос oikealle. Jokaisesta lasketaan sitten  $P(O|\lambda)$  kuten teoriaosassa näytettiin, josta selviää mikä liike on mallien mukaan todennäköisin. Malli pysyy havaitsemaan eri liikkeitä ennen niiden päättymistä, mutta etenkin käännöksiin liittyvissä tunnistuksissa menee enemmän aikaa, koska malli aluksi sekoittaa ne kaistanvaihtoihin. Kokeessa käytettiin tietokonesimulaatiota, mutta kulkuneuvon tilan mittaaminen onnistuu nykyautoissa olevilla sensoreilla. Berndt, Emmert ja Dietmayer (2008) totesivat, että GPS-paikantimien ja digitaalisten karttojen voidaan odottaa olevan tulevaisuuden autoissa, mikä

13 vuoden kuluessa on osoittautunut todeksi. Heidän mallissaan ratin kulmaa ei annettu suoraan piilomallille, vaan sen sijaan otettiin erotus siitä ja odotetusta kulmasta tien kaarevuuden perusteella, mikä saadaan karttadatasta.

Puhtaasti erilaisia käänöstilanteita tunnistettiin Mitrovicin (2005) artikkelissa käyttäen yksisuuntaisia piilomalleja. Yksisuuntaisessa piilomallissa tilat ovat jossain järjestyksessä, ja malli ei pysty tekemään tilasiirtymiä ns. väärään suuntaan. Havaintoina käytettiin oikeasta autosta saatuja mittauksia nopeudesta, pitkittäisestä ja sivusuuntaisesta kiihtyvyydestä sekä kiihtyvyykäyrien jyrkkyydestä. Malli saavutti korkean onnistumisprosentin lukuunottamatta sitä, että se usein sekoitti vasemmalle kääntymisen ja vasemmalle kääntymisen liikenneympyrässä. Uuden Seelannin teillä ajetaan vasemmalla puolella, mikä tekee niistä kahdesta käänöksestä käytännössäkin hyvin samantapaiset, joten tutkijat eivät kokeneet sitä suureksi ongelmaksi.

Markovin piilomallit ovat olleet jo pitkään käytössä puheentunnistuksessa, mikä olikin Rabinerin (1989) teoriaosan lähteenä toimineen oppaan keskeinen näkökulma. Puheentunnistuksen ideoita voidaan yrittää soveltaa ajamisen tunnistamisen. Torkkola, Venkatesan ja Liu (2005) lainasivat foneemin ideaa, millä tarkoitetaan pienimpiä äänneitä jotka puheessa kantavat merkitystä (Twaddell 1935), ja koittivat löytää samantapaisia rakenteita eri ajotilanteissa. Kuten kappaleen esimerkeissä on jo nähty, eri ajoliikkeitä tunnistetaan yksisuuntaisilla piilomalleilla vertaamalla niitä eteen-algoritmin avulla. Tutkimuksen tarkoitus oli löytää näistä eri liikkeitä kuvaavista malleista useimmiten esiintyviä tiloja ja osittaisia tilasarjoja, ja klusteroida niitä merkitystä kantaviksi palasiksi, joita artikkeli kutsuu driveemeiksi. Tuloksista voidaan nähdä, että esimerkiksi ohituksen alussa ilmenee samoja driveemejä kuin kaistanvaihdossa vasemmalle ja lopussa samoja kuin kaistanvaihdossa oikealle.

Sathyanarayana, Boyraz ja Hansen (2008) laajensivat tätä analogiaa puheentunnistukseen siten, että driveemeistä koostuvat ajoliikkeet ovat verrattavissa sanoihin, sarja liikkeitä fraaseihin, ja ajoneuvon reitit lauseisiin. Näin saadaan aikaiseksi hierarkkinen kehys jonka avulla yritettiin tunnistaa kokonaisia reittejä eikä vain yksittäisiä ajoliikkeitä. Se voidaan toteuttaa piilomalleilla eri tavoilla aloittamalla hierarkian eri päistä. Kehyksen yläosasta aloitettaessa luodaan yksi suuri piilomalli josta Viterbin algoritmia ja muita menetelmiä käyttäen muodostetaan hienorakeisempi malli. Toisaalta alhaalta lähtiessä muodostetaan malli reitin

jokaiselle vaiheelle, joista voidaan jonkinlaisella syntaksilla koota kokonainen reitti.

Toistaiseksi kappaleessa on ollut esimerkkejä erilaisten ajotoimintojen, kuten kaistanvaihtojen tai käännosten tunnistamisesta piilomallien avulla. Niitä pystytään kuitenkin myös hyödyntämään kaistavaroittimissa, jotka ilmoittavat jos kuljettaja liikkuu tien suhteen sivusuunnassa käyttämättä vilkkua. Sellainen järjestelmä on toteutettavissa ilman monimutkaisia koneoppimisalgoritmeja, mutta Wang ym. (2018) kehittivät personalisoidun varoitusjärjestelmän, jossa piilomalli opetetaan kuljettajan omiin ajotottumuksiin. Tutkimus toteaa, että yleisempi malli saattaa tuottaa paljon enemmän vääriä hälytyksiä, jos kuljettaja esimerkiksi ajaa yleensäkin lähellä reunaviivaa, mikä heikentää luottamusta sen hyödyllisyyteen.

Kuljettajan aikomusten tunnistamisesta ja ennustamisesta Markovin piilomalleilla on kirjoitettu paljon, ja on pysynyt vielä vuoden 2015 jälkeenkin suosittuna aiheena alalla. Etenkin rinnastus puheentunnistukseen antaa vaikutelman että aikomusten ennustaminen on hyvin samantapainen tehtävä kuin mihin piilomalleja on käytetty jo vuosikymmeniä. Hyvin tunnettuna ja selkeästi tuloksia tuottavana metodina ne ovat pysyneet houkuttelevana vaihtoehtona edistyneempien koneoppimismenetelmien ohella.

## 4.2 Kuljettajan tilan arviointi

Kuljettajan aikomusten ennustamisen lisäksi tutkijoita kiinnostaa myös kuljettajan tilan tarkkailu. Liiallinen väsymys ja juopumus aiheuttavat onnettomuuksia, ja kulkuneuvo joka pysyy automaattisesti estämään sellaisen ajamisen on yksi ratkaisu tähän ongelmaan.

Fu, Wang ja Zhao (2016) mittasivat linja-autonkuljettajan väsymystä pitkällä ajomatalla. Mittareina käytettiin niin kontekstuaalisia asioita kuten kuljettajan nukkuminen ennen ajoa ja tehtävän monotonisuus (kaupunkiajo vai suora maantie), kuten myös erilaisia fysiologisia mittareita kuten aivo- ja lihassähkökäyriä ja hengityksen monitorointia. Kuljettajalta myös kysyttiin omaa mielipidettä säännöllisesti.

Edellisessä kappaleessa ennustettiin aikomuksia kuvaamalla kuljettajan kasvoja, ja niin siellä kuten tässäkin ulkoisten sensoreiden käyttö herättää käytännöllisyyskysymyksiä, etenkin jos kuljettajan odotetaan asettavan elektrodeja itseensä monitorointia varten. Vaikka julkis-

sa yhtiön omistamissa kulkuneuvoissa voisi ajatella kuljettajan jatkuvan tarkkailun vähemmän yksityisyyttä loukkaavaksi, se ei kuitenkaan välttämättä herätä luottamusta siihen että niitä käytetään puhtaasti turvallisuuden vuoksi. Amazon on alkanut lisäämään pakettiautoihinsa kameroita, jotka pystyvät tunnistamaan esimerkiksi kuljettajan huokauksia ja liikenne-rikkomuksia, mutta jotkut kuljettajat ja asiantuntijat ovat epäluuloisia teknologiaa kohtaan, etenkin koska tallennusten käyttöä koskevat lait eivät välttämättä ole ajan tasalla (Palmer 2021).

Harkous ym. (2018) mukaan juopuneisuus näkyy hitaina suunnanvaihtoina ja epänormaalina kaasus- ja jarrupolkimen käyttönä. He käyttivät piilomallissa vain kulkuneuvon oman CAN-väylän läpi kulkevaa dataa, eli tarvitsematta ulkoisia sensoreita. Yhteensä 13 eri sensorien tuottamaa parametria käytettiin havaintoina, ja mallissa oli kolme tilaa: Alkutila, normaali ja juopunut. Havainnoista saatava aikasarja on viiden sekunnin liukuva ikkuna, jonka he pystyvät laskemaan millisekunnissa. Malli pystyy parhaiten tunnistamaan normaalin kuljettajan korkeussuuntaisesta kiihtyvyydestä, ja juopuneen kulmanopeudesta. Keskimäärin paras mittari on kuitenkin pitkittäinen kiihtyvyys. Tutkijat uskovat tulosten parantuvat jos eri sensoreiden lukemia yhdistetään tai otetaan huomioon esim. sijainti kartalla.

### 4.3 Autonomiset toiminnot

Yksi aikaisimmista esimerkistä tilanteenvalvontaan liikenteessä HMM:iä käyttäen on Meyer-Deliuksen, Plagemannin ja Burgardin (2009) työ muiden kulkuneuvojen käytöksen ennustamiseen moottoritiellä. Malli seuraa ympärillä olevia kulkuneuvoja ja luokittelee niiden käytöstä sen mukaan, seuraako se referenssikulkuneuvoa, ohittaako se, vai tekeekö se keskeytetyn ohituksen. Oikean maailman koe käytti autoa, johon oli asennettu lasereilla toimivat etäisyysmittarit mitä kaupallisissa kulkuneuvoissa ei ollut. Firl ja Tran (2011) kehittivät samantapaisen järjestelmän, mutta sen tarkoituksena on tunnistaa mittaavan auton käytöstä. Koejärjestelyissä käytettiin myös kaupallista kameraa ja tutkaa, mitkä ovat nykypäivänä käytännöllisesti mahdollisia avustetuissa kulkuneuvoissa.

Saadakseen hyväksyntää ja luottamusta matkustajilta, autonomisen kulkuneuvon täytyy pystyä käyttäytymään jokseenkin ihmismäisesti. Kaistanvaihto on yksi toiminto jossa tekoä-

lyn täytyy toimia luontevasti. Jin ym. (2020) jakaa ihmisten tekevät kaistanvaihdot kahteen luokkaan: pakollisiin kaistanvaihtoihin, esimerkiksi jos risteykseen tullessa täytyy olla jollain kaistalla saadakseen kääntyä, ja harkinnanvaraisiin kaistanvaihtoihin, esim. maantiellä toisen auton ohittaminen. Oikealla moottoritiellä kerätystä datasta otettiin tarkasteltavaksi kaistaa vaihtavan kulkuneuvon nopeus, sekä sen edessä ja takana niin alkuperäisellä kuin maalikaistallakin olevien autojen suhteelliset etäisyydet ja nopeudet. Nämä parametrit johdettiin Gaussin seosmallin läpi, mikä on keino löytää normaalisti jakautuneita alipopulatioita joukosta, ja HMM käsitteli niitä. Malli pystyi tekemään ihmismäisiä kaistanvaihtopäätöksiä suurella tarkkuudella. Se on kuitenkin koulutettu suhteellisen pienellä mallidatalla joka käsittelee vain muutaman sadan metrin pituista suoraa moottoritietä, mikä rajoittaa sen käytettävyyttä.

Joissain tapauksissa piilomalleilla voidaan parantaa muiden mallien tekemiä päätöksiä. Gomez ym. (2014) tunnistivat liikennevalojen tilaa prosessoimalla kulkuneuvon ottamia valokuvia. Kuvankäsittelyalgoritmeilla voidaan kuvasta löytää liikennevalo ja siltä alueelta mistä se on tunnistettu voidaan laskea liikennevalon senhetkinen väri. Perinteiset kuvankäsittelymetodit ovat kuitenkin herkkiä valaistuksen muutokselle ja esim. liikennevalon osittain peitetyille esteille. Artikkelissa liikennevalon tilan tunnistuksen jälkeen se annettiin vielä piilomallille, jossa Viterbin algoritmia hyödyntämällä saatiin parannettua tulosten oikeellisuutta etenkin eri säätiloissa. Nienhüser, Drescher ja Zöllner (2010) käyttivät HMM:iä samalla tavalla, missä erilaisille Saksasta löytyville liikennevaloille muodostettiin omat piilomallinsa, ja havaintoina käytettiin tukivektorikoneen tuottamia veikkauksia liikennevalon tilasta. Näistä esimerkeistä voidaan havaita, että piilomallit ovat hyvin soveltuvia tilanteisiin, jossa yritetään mallintaa jotain mikä vaihtaa ajan kuluessa tilaa, ja mihin liittyy paljon epävarmuutta mitä vähemmän oppivat metodit eivät välttämättä pysty käsittelemään.

Paikantunnistus kameroiden avulla on jokseenkin samanlainen ongelma. Samasta paikasta otettu eteenpäin katsova kuva voi olla hyvin erilainen riippuen säästä, vuodenajasta tai ihmisten aiheuttamista tekijöistä kuten rakennustyö. Doan ym. (2019) esittelevät metodin paikannukseen jatkuvasti kasvavaa tietokantaa vastaan. Piilomallien käyttö mahdollistaa prosessointiajan pysymisen kohtalaisena tietokannan koosta riippumatta. Tietokanta itse kuitenkin on kulkuneuvossa itsessään, ja muistin riittävyys saattaa olla ongelma pidemmän päälle.

Piilomalleilla on myös pystytty personalisoimaan autonomista ajoneuvoa. Lefevre, Carvalho ja Borrelli (2015) mallissaan syöttivät koulutusdatana auton kiihtyvyyttä toista autoa seurattaessa. Sen perusteella kulkuneuvo pystyy jäljittelemään ihmisajajan omaa käytöstä samantapaisissa tilanteissa, tietyt turvarajat huomioonottaen. Järjestelmä myös arvioi luottamusta dataan, ja jos se kohtaa tilanteen, jossa koulutusdatan puutteellisuuden takia syntyisi hyvin epätodennäköisiä kiihdytyskomentoja, se pystyy poikkeamaan mallin vaatimuksista ja tukeutumaan muihin kulkuneuvon ominaisuuksiin.



## 5 Yhteenveto

Kirjallisuuskatsauksessa tarkasteltiin Markovin piilomallien käyttöä ajoneuvoissa. Ensin käytiin hieman läpi autonomisen ajamisen historiaa ja niihin käytettäviä sensoreita sekä järjestelmien hierarkkista rakennetta. Sitten käytiin läpi Markovin piilomallien perusrakenne ja lyhyesti niiden käyttö. Lopuksi yhdistettiin nämä kaksi asiaa ja annettiin esimerkkejä piilomallien sovelluksista tutkittavalla alalla. Niiden havaittiin olevan suosittuja etenkin kuljettajan aikomuksia ennustettaessa, ja vähemmässä määrin mielentilaa tarkkaillaessa tai puhtaasti autonomisen ajamisen prosesseissa. Autonominen ajaminen on kuitenkin suhteellisen tuore ala, joten mitä luultavimmin jää nähtäväksi kuinka yleiseksi metodiksi piilomallit osoittautuvat kun ihminen otetaan pois kuvioista.

Katsaus ei missään nimessä ole täysin kattava. Ajoneuvojen välistä kommunikaatiota hyödyntävät järjestelmät jäivät huomiotta, jos niissä esiintyy piilomallien käyttöä. Se myös keskittyi täysin piilomalleihin, joten niiden suosio verrattuna muihin alalla käytettäviin koneoppimismenetelmiin jää hämäräksi.

## Lähteet

- Akai, Naoki, Takatsugu Hirayama, Luis Yoichi Morales, Yasuhiro Akagi, Hailong Liu ja Hiroshi Murase. 2019. “Driving behavior modeling based on hidden markov models with driver’s eye-gaze measurement and ego-vehicle localization”. Teoksessa *2019 IEEE Intelligent Vehicles Symposium (IV)*, 949–956. IEEE.
- Badue, Claudine, Rânik Guidolini, Raphael Vivacqua Carneiro, Pedro Azevedo, Vinicius Brito Cardoso, Avelino Forechi, Luan Jesus, Rodrigo Berriel, Thiago Meireles Paixao, Filipe Mutz ym. 2020. “Self-driving cars: A survey”. *Expert Systems with Applications*, 113816.
- Baum, Leonard E, ja Ted Petrie. 1966. “Statistical inference for probabilistic functions of finite state Markov chains”. *The annals of mathematical statistics* 37 (6): 1554–1563.
- Bengler, Klaus, Klaus Dietmayer, Berthold Farber, Markus Maurer, Christoph Stiller ja Hermann Winner. 2014. “Three decades of driver assistance systems: Review and future perspectives”. *IEEE Intelligent transportation systems magazine* 6 (4): 6–22.
- Berndt, Holger, Jorg Emmert ja Klaus Dietmayer. 2008. “Continuous driver intention recognition with hidden markov models”. Teoksessa *2008 11th International IEEE Conference on Intelligent Transportation Systems*, 1189–1194. IEEE.
- Broggi, Alberto, Alex Zelinsky, Ümit Özgüner ja Christian Laugier. 2016. “Intelligent vehicles”. Teoksessa *Springer Handbook of Robotics*, 1627–1656. Springer.
- Doan, Anh-Dzung, Yasir Latif, Tat-Jun Chin, Yu Liu, Thanh-Toan Do ja Ian Reid. 2019. “Scalable place recognition under appearance change for autonomous driving”. Teoksessa *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 9319–9328.
- Firl, Jonas, ja Quan Tran. 2011. “Probabilistic Maneuver Prediction in Traffic Scenarios.” Teoksessa *ECMR*, 89–94.
- Fu, Rongrong, Hong Wang ja Wenbo Zhao. 2016. “Dynamic driver fatigue detection using hidden Markov model in real driving condition”. *Expert Systems with Applications* 63:397–411.

- Galvani, Marco. 2019. “History and future of driver assistance”. *IEEE Instrumentation & Measurement Magazine* 22 (1): 11–16.
- Gasser, Tom M, ja Daniel Westhoff. 2012. “BASt-study: Definitions of automation and legal issues in Germany”. Teoksessa *Proceedings of the 2012 road vehicle automation workshop*. Automation Workshop.
- Gomez, Andres E, Francisco AR Alencar, Paulo V Prado, Fernando S Osorio ja Denis F Wolf. 2014. “Traffic lights detection and state estimation using hidden markov models”. Teoksessa *2014 IEEE Intelligent Vehicles Symposium Proceedings*, 750–755. IEEE.
- Harkous, Hasanin, Carine Bardawil, Hassan Artail ja Naseem Daher. 2018. “Application of hidden Markov model on car sensors for detecting drunk drivers”. Teoksessa *2018 IEEE International Multidisciplinary Conference on Engineering Technology (IMCET)*, 1–6. IEEE.
- International, SAE. 2018. “J3016-2018, taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles”. *SAE International*, *sae.org*, [https://doi.org/10.4271/J3016\\_201806](https://doi.org/10.4271/J3016_201806).
- Jain, Ashesh, Hema S Koppula, Bharad Raghavan, Shane Soh ja Ashutosh Saxena. 2015. “Car that knows before you do: Anticipating maneuvers via learning temporal driving models”. Teoksessa *Proceedings of the IEEE International Conference on Computer Vision*, 3182–3190.
- Janssen, Christian P, Linda Ng Boyle, Andrew L Kun, Wendy Ju ja Lewis L Chuang. 2019. “A hidden markov framework to capture human–machine interaction in automated vehicles”. *International Journal of Human–Computer Interaction* 35 (11): 947–955.
- Jin, Hao, Chunguang Duan, Yang Liu ja Pingping Lu. 2020. “Gauss mixture hidden Markov model to characterise and model discretionary lane-change behaviours for autonomous vehicles”. *IET Intelligent Transport Systems* 14 (5): 401–411.
- Kodaka, Kenji, Makoto Otabe, Yoshihiro Urai ja Hiroyuki Koike. 2003. “Rear-end collision velocity reduction system”. *SAE transactions*, 502–510.

- Kuge, Nobuyuki, Tomohiro Yamamura, Osamu Shimoyama ja Andrew Liu. 2000. "A driver behavior recognition method based on a driver model framework". *SAE transactions*, 469–476.
- Kyriakidis, Miltos, Riender Happee ja Joost CF de Winter. 2015. "Public opinion on automated driving: Results of an international questionnaire among 5000 respondents". *Transportation research part F: traffic psychology and behaviour* 32:127–140.
- Lefevre, Stéphanie, Ashwin Carvalho ja Francesco Borrelli. 2015. "A learning-based framework for velocity control in autonomous driving". *IEEE Transactions on Automation Science and Engineering* 13 (1): 32–42.
- Lie, Anders, Claes Tingvall, Maria Krafft ja Anders Kullgren. 2006. "The effectiveness of electronic stability control (ESC) in reducing real life crashes and injuries". *Traffic injury prevention* 7 (1): 38–43.
- Meyer-Delius, Daniel, Christian Plagemann ja Wolfram Burgard. 2009. "Probabilistic situation recognition for vehicular traffic scenarios". Teoksessa *2009 IEEE International Conference on Robotics and Automation*, 459–464. IEEE.
- Mitrovic, Dejan. 2005. "Reliable method for driving events recognition". *IEEE transactions on intelligent transportation systems* 6 (2): 198–205.
- Mor, Bhavya, Sunita Garhwal ja Ajay Kumar. 2020. "A systematic review of hidden markov models and their applications". *Archives of Computational Methods in Engineering*, 1–20.
- NHTSA. 2013. "Preliminary statement of policy concerning automated vehicles". *National Highway Traffic Safety Administration and others* (Washington, DC), viitattu 30. huhtikuuta 2021. [www.nhtsa.gov/staticfiles/rulemaking/pdf/Automated\\_Vehicles\\_Policy.pdf](http://www.nhtsa.gov/staticfiles/rulemaking/pdf/Automated_Vehicles_Policy.pdf).
- Nienhüser, Dennis, Markus Drescher ja J Marius Zöllner. 2010. "Visual state estimation of traffic lights using hidden Markov models". Teoksessa *13th International IEEE Conference on Intelligent Transportation Systems*, 1705–1710. IEEE.
- Paden, Brian, Michal Čáp, Sze Zheng Yong, Dmitry Yershov ja Emilio Frazzoli. 2016. "A survey of motion planning and control techniques for self-driving urban vehicles". *IEEE Transactions on intelligent vehicles* 1 (1): 33–55.

Palmer, Annie. 2021. "Amazon is using AI-equipped cameras in delivery vans and some drivers are concerned about privacy". *CNBC* (3. helmikuuta 2021). Viitattu 26. maaliskuuta 2021. <https://www.cnn.com/2021/02/03/amazon-using-ai-equipped-cameras-in-delivery-vans.html>.

Rabiner, Lawrence R. 1989. "A tutorial on hidden Markov models and selected applications in speech recognition". *Proceedings of the IEEE* 77 (2): 257–286.

Sathyanarayana, Amardeep, Pinar Boyraz ja John HL Hansen. 2008. "Driver behavior analysis and route recognition by hidden Markov models". Teoksessa *2008 IEEE International Conference on Vehicular Electronics and Safety*, 276–281. IEEE.

Torkkola, Kari, Srihari Venkatesan ja Huan Liu. 2005. "Sensor Sequence Modeling for Driving." Teoksessa *FLAIRS Conference*, 721–727.

Tran, Duy, Weihua Sheng, Li Liu ja Meiqin Liu. 2015. "A Hidden Markov Model based driver intention prediction system". Teoksessa *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, 115–120. IEEE.

Twaddell, W Freeman. 1935. "On defining the phoneme". *Language* 11 (1): 5–62.

Wang, Wenshuo, Ding Zhao, Wei Han ja Junqiang Xi. 2018. "A learning-based approach for lane departure warning systems with a personalized driver model". *IEEE Transactions on Vehicular Technology* 67 (10): 9145–9157.

Viterbi, Andrew. 1967. "Error bounds for convolutional codes and an asymptotically optimum decoding algorithm". *IEEE transactions on Information Theory* 13 (2): 260–269.

Yurtsever, Ekim, Jacob Lambert, Alexander Carballo ja Kazuya Takeda. 2020. "A survey of autonomous driving: Common practices and emerging technologies". *IEEE Access* 8:58443–58469.