

Arrive Alive: Detect and Predict Lane Departures from the Steering Wheel Signal

Loppuraportti hankkeelle 113298

Doc. Pia Forsman
Helsingin yliopisto
Fysiikan laitos
Elektroniikan laboratorio

TIIVISTELMÄ

Työ- ja liikenneturvallisuusvirkaileijat ovat kauan tiedostaneet vastatoimien tarvetta väsyneenä ajamiselle, koska se on suuri osatekijä liikenneonnettomuuksissa [1,2]. Suomessa jopa 40 % kyselyihin vastanneista pitkän matkan rekkakuskeista, ja 21 % lyhyen matkan rekkakuskeista, raportoivat vaikeuksia hereillä pysymisessä jopa 20 % matkoistaan. Yli 20 % vastanneista pitkän matkan rekkakuskeista myöntävät nukahtaneensa rattiin ainakin kahdesti [3].

Väsynyt kuljettaja tekee harvoja mutta suuria korjausliikkeitä ratilla [4,5], mikä pahentaa ulosajon riskiä [6,5]. Tähän mennessä nykyiset kaistavahdit havaitsevat vain 30-40 % kaikista kaistalta poikkeamisista koska ne ovat video-pohjaisia ja menettävät usein tietoa [8]. Osoitimme äskettäin että auton siirtofunktio mahdollistaa rattisignaalin muuntamisen kaistasijainnin signaaliksi [9]. Kaistavahti, joka perustuisi tähän menetelmään, olisi luotettavampi ja sen pitäisi havaita kaistalta poikkeamiset suuremmalla herkkyydellä kuin nykyiset video-pohjaiset järjestelmät.

On epävarmaa, mikäli kaistavahti todella ehkäisee onnettomuuksia *havaitsemalla* kaistalta poikkeamia [8,10,11]. Teknologia, joka *ennustaisi* kaistalta poikkeamia, antaisi kuljettajalle aikaa ehkäistä lähestyvää vaaratilannetta. Tähän asti tutkijat ovat käyttäneet yhdistelmän autopohjaisista ja fysiologisista signaaleista ennustaakseen väsymystä viisi minuuttia eteenpäin [12]. Toisaalta, järjestelmä joka perustuu fysiologisiin signaaleihin saattaa olla häiritsevää kuljettajalle ja altis tiedon menetykselle. Kvanttineuroverkot (QNN) käytetään ennustamaan nopeita ja hetkellisiä vaihteluja osakemarkkinoilla (ihmisen toiminta) ja auringonpilkkujen aktiviteettiä (luonnollinen toiminta) [13-15], ja niitä voisi myös käyttää ennustamaan kaistalta poikkeamia rattisignaaleista.

Simulaattoripohjainen koulutus on tärkeää ammattikuljettajien koulutuslaitoksille, koska se mahdollistaa vaaratilanteiden emuloiminen ja analysoinnin, kuten esim. miten toimia kun linja-auto ajaa jäisen tiekohdan yli [16]. Vaikka simulaattorit ovat arvokkaita koulutuksen kannalta, kouluttajien pitää varautua opiskelijoihin jotka kärsivät simulaattoripahoinvoinnista [17]. Se aiheuttaa trauma, jotka rajoittavat koulutuksen tehokkuutta ja lisää keskeyttämisten määrää [18]. Simulaattoripahoinvoinnille alttiiden opiskelijoiden tunnistaminen antaisi kouluttajalle mahdollisuuden keskeyttää harjoituskerran ennen pahoinvoinnin alkamista - tämä parantaisi pahoinvoinnille alttiiden opiskelijoiden simulaattorikoulutuksen laatua ja määrää. Koska sykevälivaihtelu (HRV) on stressitunniste, sitä voitaisiin käyttää ennustamaan simulaattoripahoinvointia.

Projektilla (2014-2015) oli kolme tavoitetta: 1) ennustaa simulaattoripahoinvointia, 2) havaita ja 3) ennustaa kaistalta poikkeamia rattisignaalista. Tutkimukseen värvättiin 34 opiskelijaa Työtehoseuran Logistiikka ja ajoneuvot-osastolta. He ajoivat Työtehoseuran kahdessa high-fidelity ajosimulaattoreissa 80 km/h nopeudella 55 min joka kolmas tunti 36 tunnin valvomisen ajan, yhteenlaskettuna 31200 km ajoa. Ajokertojen aikana tallensimme simulaattoreiden ratti- ja kaistasijaintisignaaleja 60 Hz:n näytteistystaajuudella. Mittasimme myös osallistujien sydänkäyrää (ECG) 500 Hz:llä. Välittömästi ennen jokaista ajokertaa ja jokaisen ajokerran jälkeen osallistujat tekivät 10-minuutin valppaustestin (Psychomotor Vigilance Test) ja arvioivat pahoinvoinnin, okulomotorisen epämukavuuden ja disorientaation oireet simulaattoripahoinvointikyselyssä (Simulator Sickness Questionnaire, SSQ) samalla kuin sydänkäyrää mitattiin.

Käytimme ensimmäisinä kvantitatiivista sydänkäyrää ennustamaan mitkä osallistujat tulevat kokemaan simulaattoripahoinvointia, ja keskityimme dataan, jota mitattiin kolmen ensimmäisten koekertojen aikana, jolloin he vielä kokivat itsensä levänneiksi (välttääksemme että väsymys vaikuttaisi heidän SSQ-arvoihinsa). $N=15$ osallistujaa saivat korkeamman SSQ-tuloksen ajokertojen jälkeen missä muut $n=19$ eivät. Ennen ajoa (PVT- ja SSQ tehtävien aikana) LF/HF-suhde (joka on HRV-signaalista laskettu tunnusluku [30]) oli pienempi niillä osallistujilla, jotka saivat korkeamman SSQ-arvon ajon jälkeen. Vaikka ero kahden ryhmän välillä ($n=15$ ja $n=19$) ei ollut tilastollisesti

merkittävä, tämä ero osoittaa että LF/HF-suhteesta voisi ennustaa simulaattoripahoinvointia. Perustelu tälle on se, että ketään osallistujista eivät saaneet korkeita SSQ-arvoja ensimmäisten kolmen testikertojen aikana - LF/HF-suhteen havaitsema vaikutus $n=15$ kuljettajassa oli lievä (toisin sanoen, kukaan heistä ei keskeyttänyt ajoa simulaattoripahoinvoinnin takia). Seuraavaksi meidän pitäisi validoida parametri vapaaehtoisilla jotka kokevat simulaattoripahoinvointia. Se, että kukaan osallistujista ei saanut korkeita SSQ-arvoja levänneinä tarkoittaa myös että ammattikuljettajien koulutuslaitokset voisivat käyttää meidän koejärjestelyjämme helpottaakseen opiskelijoidensa totuttautumista simulaattoripohjaiseen koulutukseen. Eritoten, koulutuksen aloittaminen maantieajo-skenaariolla auttaisi opiskelijoita sopeutumaan simuloituun ympäristöön.

Havaitaksemme kaistalta poikkeamia rattisignaalista määritimme ensin simulaattoreiden siirtofunktiot ja käytimme niitä laskemaan kaistasijaintia mitatuista rattisignaaleista. Pearson korrelaatio laskettujen ja mitattujen kaistasijaintisignaalien välillä oli $r=0.48$ ($n=3151$). Tämä vastaa aikaisempia tutkimustuloksia (Työsuojelurahaston projekti #109257). Seuraavaksi kehitimme algoritmin, joka käytti lasketut kaistasijaintisignaalit varoittaakseen kaistalta poikkeamisista kolme sekuntia etuajassa. Herkkyys oli 47 % ja tarkkuus oli 71 %. Korrelaatio laskettujen ja mitattujen kaistasijaintisignaalien välillä oli pienempi kuin meidän aikaisemmassa tutkimuksessa ($r \geq 0.78$ [9]), mutta herkkyys kehittämällemme kaistavahti-algoritmillemme oli suurempi kuin nykyisten video-pohjaisten kaistavahtien saavuttama 40 % herkkyys. Yhteenvedona tämä tarkoittaa sitä, että tuotimme ensimmäiset tieteelliset todisteet sille että kaistalta poikkeamia voidaan havaita rattisignaalista. Seuraavaksi meidän tulisi kokeilla onko ehdotettu menetelmä kenttäkelpoinen.

Ennustaaksemme kaistalta poistumisia rattisignaalista koulutimme ensin yhden QNN:n, kahdella piilotetulla kerroksella, ennustamaan rattisignaalia eteenpäin yhdellä aikapisteellä. Koska alinäytteistimme rattisignaalia 10 Hz:iin QNN ennusti 0,1 s eteenpäin. Seuraavaksi käytimme ennustettua signaalia kaistasijainnin laskemiseen siirtofunktiolla - korrelaatio lasketun ja mitatun kaistasijaintisignaalin välillä oli $r=0.73$ ($n=1$). Yhteenlaskettuna näytimme ensimmäiset tieteelliset todisteet sille, että QNN:illä voidaan ennustaa kaistasijaintisignaalia. Seuraava tehtävämme on kasvattaa ennustushorisonttia.

Yhteenvedo:

1) Tuotimme ensimmäiset tieteelliset todisteet sille että suhteellisen matala LF/HF suhde edeltää pieni kasvu SSQ-pisteissä. Tämä tulos perustuu koehenkilöryhmään missä selväpiirteistä simulaattoripahoinvointia ei esiintynyt. Ennen kuin voimme tehdä johtopäätöksiä meidän tulisi validoida tuloksen vapaaehtoisilla jotka selvästi potevat simulaattoripahoinvointia.

2) Kehitimme myös algoritmin joka havaitsee kaistalta poikkeamia rattisignaalista suuremmalla herkkyydellä kuin nykyiset video-pohjaiset kaistavahdit (47 % vs. 40%). Seuraava tehtävämme on lisätä menetelmän herkkyyttä. Koska menetelmä kehitettiin laboratorio-olosuhteissa, meidän tulisi validoida sen kenttäkelpoisuutta. Tällöin olemme varustaneet tieliikennettä ensimmäisellä luotettavalla autopohjaisella kaistavahdilla.

3) Lopuksi osoitimme, että QNN pystyy ennustamaan rattisignaalia 0,1 s eteenpäin 0,7 % virheellä (eli isolla tarkkuudella), ja että ennustettu signaali voidaan käyttää laskemaan kaistasijaintia. Jos pystymme kasvattamaan ennustushorisonttia, meillä on tarvittavat osatekijät ennustavalle kaistavahdille.

SUMMARY

Work- and traffic safety officials have long acknowledged the need for countermeasures against drowsy driving, because it is a main contributor to road crashes [1,2]. In Finland, even 40% of polled long-haul truck drivers and 21% of polled short-haul truck drivers report difficulties staying awake during 20% of their journeys. More than 20% of the polled long-haul drivers admit to nodding off at the wheel at least twice [3].

A drowsy driver makes less frequent but large corrective steering wheel movements [4,5], which increases the risk for running off the road [6,7]. So far, current in-car lane departure warning (LDW) systems only recognize 30-40% of all imminent lane departures, because they are video-based and often lose data [8]. We recently showed that the car's transfer function provides a way to transform the steering wheel signal into a lane position signal [9]. An LDW system that relies on this approach would be more robust and should detect lane departures with higher sensitivity than the current video-based systems do.

Whether a LDW system truly prevents accidents by *detecting* lane departures is unknown [8,10,11]. A technology that *predicts* lane departures would give the driver time to safely counteract an upcoming event. So far researchers have used a combination of car-based and physiological signals continuously recorded while driving to predict drowsiness five minutes in advance [12]. However, a system that relies on physiological metrics may be obtrusive and is also prone to data loss. Quantum Neural Networks (QNN) are used to predict e.g. transient fluctuations in the stock market (human action) and sunspot activity (natural action) [13-15], and may also be used to predict lane departures from the steering wheel signal.

For institutions that train professional drivers, simulator-based training is important because it allows emulating and analyzing dangerous situations, like e.g. what to do when the bus hits an icy spot [16]. While simulators are valuable in driver training, instructors must be prepared for students who suffer from simulator sickness [17]. It leaves a stigma which limits the effectiveness of training and increases the student dropout rate [18]. Catching a student prone to simulator sickness would enable the instructor to end the training session before the student experiences simulator sickness – for susceptible students this reflects positively on training quality and quantity. While heart rate variability (HRV) is a marker of stress, it could be used to predict simulator sickness.

In the project (2014-2015) we had three aims: 1) to predict simulator sickness and to 2) detect and 3) predict lane departures from the steering wheel signal. We enrolled 34 students at Työteho-seura's branch of logistics and vehicles. They drove in Työteho-seura's two high-fidelity driving simulators at 80 km/h for 55 minutes every third hour during 36 hours of sustained wakefulness – collectively covering 31200 km of driving. During the driving sessions we logged the simulators' steering wheel and lane position signals at 60 Hz. We also recorded the participants' electrocardiogram (ECG) at 500 Hz. Immediately before and after each driving session the participants took a 10-minute Psychomotor Vigilance Test (PVT) and rated their symptoms of nausea, oculomotor discomfort, and disorientation on the Simulator Sickness Questionnaire (SSQ) while we recorded their ECG.

We are the first to use quantitative ECG to predict which participants will experience simulator sickness, and we focused on the data that was recorded during the first three test sessions when they still felt rested (to avoid that sleepiness confounded their SSQ-ratings). N=15 participants scored higher on the SSQ after the drives, whereas the other n=19 participants did not. During the pre-drive PVT and SSQ tests, the ratio of the low- and high frequency components in the HRV signal (LF/HF ratio) [30] was lower in the participants who scored higher on the SSQ after the drive. While the difference between the two groups (n=15 and n=19) was not statistically significant, it indicates that the LF/HF ratio may be a potent predictor of simulator sickness. The rationale is that overall, none of the participants scored high on the SSQ during the first three test sessions – the effect that the LF/HF

ratio detected in the $n=15$ drivers was mild (i.e. none of them stopped driving because of simulator sickness). Next, we should validate the parameter with volunteers who express simulator sickness and develop a user-friendly interface for the instructor. The fact that none of the participants scored high on the SSQ when they were rested also means that institutions that train professional drivers could use our set-up to ease their students into simulator-based training. Specifically, starting the training in a highway scenario would help the student adopt to the simulated environment.

To detect lane departures from the steering wheel signal, we first determined the simulators' transfer functions and used them to derive the lane position signals from the recorded steering wheel signals. The Pearson correlation between the derived and recorded lane position signals was $r=0.48$ ($n=3151$). This is in line with our previous findings (Finnish Work Environment Fund project #109257). Next, we developed an algorithm that used the derived lane position signal to warn of lane departures three seconds in advance. The sensitivity was 47% and the specificity was 71%. The correlation between the derived and recorded lane position signals was lower than in our previous research ($r \geq 0.78$ [9]), but the sensitivity of the LDW algorithm that we developed was higher than the 40% sensitivity that the current video-based LDW systems achieve. Taken together this means that we showed the first scientific proof that lane departures can be detected from the steering wheel signal. Next, we should test whether the proposed system is field-capable.

To predict lane departures from the steering wheel signal, we first trained a QNN with two hidden layers to predict the steering wheel signal one data point ahead. Because we down sampled the steering wheel signal to 10 Hz the QNN predicted 0.1 s ahead. Next, we used the predicted signal to derive the lane position signal with the transfer function approach – the correlation between derived and measured lane position signals was $r=0.73$ ($n=1$). Taken together we showed the first scientific proof that QNNs can predict the lane position signal. Our next task is to increase the prediction horizon.

In conclusion:

- 1) We provided the first scientific proof that a lower LF/HF ratio precedes a small increase in SSQ scores. This finding was based on a group of people with no pronounced simulator sickness, so before any firm conclusions can be drawn, we need to replicate the results with volunteers who clearly express simulator sickness.
- 2) We also developed an algorithm that detects lane departures from the steering wheel signal with higher sensitivity than the current video-based systems do. Our next task is to increase the sensitivity even more. Because the method was developed from data recorded in a laboratory-environment we also need to test whether it works in the field. If it does, we have provided road transportation with the first LDW system that is based on a robust in-car signal.
- 3) Finally, we showed that QNNs can predict the steering wheel angle 0.1 s ahead with 0.7% error (i.e., high accuracy) and that the predicted signal can be used to derive the lane position signal. If we can increase the prediction horizon we have the necessary elements for a predictive in-car LDW system.