

Fysiologisk övervakning av förare för fordonets hantering av nödsituationer (DriverER)



Författare: Stefan Candefjord, Pelle Viberg, Da Wang, Jawwad Ahmed, Xuezhi Zeng, Ke Lu, Bengt Arne Sjöqvist, Anna Sjörs Dahlman

Datum: 2024-02-16

Engelsk titel: Driver physiologic monitoring for vehicle Emergency Response (DriverER)

Projekt inom: FFI - Trafiksäkerhet och automatiserade fordon

FFI Fordonsstrategisk
Forskning och
Innovation

VINNOVA

Energimyndigheten

TRAFIKVERKET

FKG

VOLVO

SCANIA

VOLVO



Innehållsförteckning

1 Sammanfattning	3
2 Executive summary in English	3
3 Bakgrund	4
4 Syfte, forskningsfrågor och metod	7
4.1 Delprojekt 1 <i>Detektion av trötthet i verklig körning</i>	7
4.2 Delprojekt 2 <i>Bedöma mental belastning hos yrkesförare i simulator</i>	15
4.3 Delprojekt 3 <i>Detektion av hjärtfrekvens / plötslig sjukdom i labb</i>	17
5 Mål	21
6 Resultat och måluppfyllelse	21
6.1 Delprojekt 1 <i>Detektion av trötthet i verklig körning</i>	21
6.2 Delprojekt 2 <i>Bedöma mental belastning hos yrkesförare i simulator</i>	25
6.3 Delprojekt 3 <i>Detektion av hjärtfrekvens / plötslig sjukdom i labb</i>	28
7 Spridning och publicering.....	32
7.1 Kunskaps- och resultatspridning.....	32
7.2 Publikationer	32
8 Slutsatser och fortsatt forskning	33
9 Deltagande parter och kontaktpersoner	34
10 Referenser	34

Kort om FFI

FFI är ett samarbete mellan staten och fordonsindustrin om att gemensamt finansiera forsknings- och innovationsaktiviteter med fokus på områdena Klimat & Miljö samt Trafiksäkerhet. Satsningen innebär verksamhet för ca 1 miljard kr per år varav de offentliga medlen utgör drygt 400 Mkr.

Läs mer på www.vinnova.se/ffi.



1 Sammanfattning

COPE Driver har genom tre olika delprojekt undersökt och utvecklat möjligheterna att uppskatta förartillstånden sömnhet och mental belastning / stressnivå samt plötslig sjukdom genom att mäta fysiologiska signaler från hjärtaktivitet med icke-invasiva sensorer i form av konsumentklassade pulsband och avancerad radartechnologi. Generellt har försöken visat att det finns potential för de testade teknologierna att bidra till att detektera och kvantifiera dessa förartillstånd, men visar också att det är utmanande att med hög noggrannhet lyckas detektera tillstånden utifrån endast mätningar av hjärtaktivitet, det behövs troligen kompletterande data från andra sensorer. Förutsättningar för att mäta på förare är svåra p.g.a. fordonets vibrationer, förarens rörelser samt tjocka kläder. Effektiv signalbehandling spelar en nyckelroll och här har projektet bidragit med utveckling av nya algoritmer. Projektresultatet pekar mot att det finns behov av vidare forskning och utveckling av icke-invasiva mätmetoder för att detektera förartillstånd, vilket kan bidra till säkrare automatiserad körning genom ett bättre samarbete mellan förare och fordon.

2 Executive summary in English

COPE Driver has through three different sub-projects investigated and developed the possibilities of estimating driver states sleepiness and mental load / stress level as well as sudden disease by measuring physiological signals from cardiac activity with non-invasive sensors in the form of consumer-grade chest straps and advanced radar technology. In general, the experiments have shown that there is potential for the evaluated technologies to help detect and quantify these driver states, but they also show that it is challenging to succeed in detecting the driver states with high accuracy based on measurements of cardiac activity alone, and additional data from other sensors is probably needed. Conditions for measuring drivers are challenging due to vehicle vibrations, the driver's movements and thick clothing. Efficient signal processing plays a key role and here the project has contributed to the development of new algorithms.

In sub-project 1 *"Detection of fatigue in real-world driving"*, we have investigated the ability to estimate sleepiness through a machine learning model. In general, we can conclude that a small size of the dataset limits performance. It has also been observed in the literature that it may be difficult to predict subjective measures of sleepiness such as KSS based solely on physiological data unless additional contextual or metadata also reinforces the amount of information. In addition, physiological parameters can vary between the individual drivers, time of day, and many other factors, making this a challenging problem. It is also noteworthy that the Mediator dataset may exhibit patterns derived from the controlled experiment design that makes it not ideal for training data for a model that predicts sleepiness during naturalistic driving. Driver datasets, on the other hand, are collected under more free forms as a result of fewer constraints on the experimental design, but it also makes the data more complex.

In sub-project 2 *"Assess mental load of professional drivers in simulator"*, we noted that heart rate (HR) seems to be the physiological parameter that best reflects stress level. Analyzing average heart rate variability (HRV) does not appear to be effective in measuring stress, although it cannot be ruled out that it may correlate at higher stress levels than those measured in our study. There were large differences between different individuals' physiological stress responses and these differences between individuals were greater than the differences between driving tasks. It is therefore important for further studies on stress responses in drivers to take into account individual differences and use analysis methods that take this into account. Stress rates were moderate during the tests and there were no ratings above 7 on the 9-point scale.



This may be due to the fact that the simulator scenes were not experienced as stressful as real-life emergencies while driving. The use of simulators allowed for a high level of control over the scenarios between the participants. However, it is difficult to achieve the same feeling of perceived stress as in real emergencies when driving in a simulator. Driving ability, measured as the number of incidents involving vehicle damage and heavy braking, differed between the driving tasks. This was likely due not only to the stress level of the tasks, but also to the different traffic environments and events included in the scenarios. It is therefore difficult to draw conclusions as to whether stressed drivers have poorer driving skills than non-stressed drivers here.

In sub-project 3 *“Detection of heart rate / sudden disease in the lab”*, we have shown that it is necessary to model the vibrations found in the passenger compartment of a car in order to detect the driver's heart rate with satisfactory quality. A first step is to use the radar sensor to measure the vibrations that occur. This has been carried out and it turns out that the RADSENZ sensor (Raytellintelligence AB) can measure these vibrations accurately. Further research is required to introduce this in a car cabin and verify that the vibrations can be filtered out so that the measurement signal from the object (the driver) can be identified. It is possible to measure heart rates in a wide frequency range and the intervals between heartbeats with radar technology, which suggests that there is good potential to detect arrhythmia. We have developed methods that can provide high accuracy under stationary conditions. However, there are still several challenges with signal processing before radar can be implemented in a vehicle. Among other things, it is necessary to develop the method further so that it becomes more robust and can measure over a longer period. More and longer measurements need to be carried out in the future on more healthy people, but also on patients with arrhythmia in a clinical study.

The results of the project indicate that there is a need for further research and development of non-invasive measurement methods to detect driver states, which can contribute to safer automated driving through better cooperation between driver and vehicle.

3 Bakgrund

Detta projekt har sitt fokus på att utveckla och förbättra metoder för övervakning av förartillstånd, där tre huvudsakliga drivkrafter är sömnhet, mental belastning (stress) och plötslig sjukdom. Forskningsläget skiljer sig åt mellan dessa områden, där sömnhet hos förare är mer studerat än andra förartillstånd.

Sömnhet eller trötthet hos föraren är en bidragande orsak till 10–30 % av dödsolyckorna [1], [2]. Därför har system för övervakning av förarens sömnhet potential att rädda många liv. Sömnhetsdetekteringssystemen som finns tillgängliga är vanligtvis baserade på körprestanda, såsom styrning och hastighet; ansiktsanalys, inklusive ögonrörelser som blinkning och blickriktning, huvudställning; fysiologiska mätningar, såsom elektroencefalografi (EEG), elektrokardiografi (EKG) och elektromyografi (EMG). De flesta av de nuvarande kommersiellt tillgängliga systemen för sömnhetsdetektering är baserade på körprestanda och ansiktsanalys [3]. Men vid helt eller delvis automatiserad körning, där fordonet kontrollerar parametrar som hastighet och positionen på vägen, och föraren kan vara vänd bort från vägen, kanske sömnhetsdetektering baserad på kameror och körprestanda inte fungerar tillfredsställande. Eftersom styrningen och hastigheten då delvis styrs av fordonet autonomt vid partiell automatisering, kommer de fordonsbaserade körprestandamått inte att vara tillgängliga för bedömning av förarstatus. Då kan detektering av förartillstånd baserat på fysiologiska parametrar vara lämpligare. Vi argumenterar för att fysiologiska data potentiellt kan förbättra precisionen för metoder för detektion av sömnhet [4], [5], och dessutom kan sådana



mätningar vara tillgängliga som reserv om t.ex. kamerasystemet av någon anledning inte är tillgängligt, till exempel att föraren antingen avsiktligt av integritetsskäl eller oavsiktligt blockerar kameran, eller på grund av att föraren under körning med högre automatisering ägnar sig åt en icke-körrelaterad uppgift som kan påverka bilden och försvåra tydning av tecken på sömnhet. Ytterligare en fördel med fysiologiska mätningar är att de signalerna börjar förändras i det tidigaste stadiet av sömnhet [6], vilket kan leda till en tidig upptäckt som är avgörande för att undvika olyckor.

Flera studier har undersökt förhållandet mellan förarens sömnhet och hjärtfrekvens (heart rate, HR) och att bygga system för detektion av sömnhets baserat på hjärtfrekvensvariabilitet (heart rate variability, HRV) metrik [7], [8], [9]. Tidigare har vi studerat HRV-sömnhetsmönster, se Buendia et al [9], och trots deras komplexitet återspeglades skillnaderna mellan sömna och icke-sömna förare tydligt i HRV-indexen. I en annan studie demonstrerade vi en personlig sömnhetsdetekteringsalgoritm med hjälp av HRV och tidsinformation, som uppnådde god noggrannhet i verkliga vägtester för både manuell och delvis automatiserad körning (L2 automatisering) [4]. Tidigare experiment har dock utförts med begränsade och kontrollerade körscenarier inom ett kort tidsintervall. Verkliga naturalistiska data krävs för att utvärdera inflytandet av flera andra faktorer som påverkar kroppens pulsreglering och kan påverka tillförlitligheten hos algoritmer över tid.


Stabila förarprestationer är grundläggande för att förhindra fordonsolyckor, och stress kan påverka förarens prestation negativt och avsevärt öka risken för en kollision [10]. Australiens nationella haverirapporter visar att stress är en av de tio främsta orsakerna till allvarliga olyckor [11]. Hög mental belastning på grund av stress eller krävande körsituationer kan leda till otillräcklig informationsbehandling och ofullständig uppfattningsförmåga, vilket i sin tur kan leda till försämrade förarprestationer [12]. Att utveckla ett förarstödsystem som exakt och automatiskt kan upptäcka olika förarens mentala tillstånd kan därför spela en viktig roll för trafiksäkerheten genom att förutsäga och förebygga farliga trafiksituationer och proaktivt stödja förare i stressiga lägen. Fysiologiska signaler som EKG och fotopletysmografi (PPG) och andningsfrekvens har tidigare använts för att klassificera förarens stressnivåer [13], [14], [15]. Flera studier visade ett starkt samband mellan EKG, elektrodermal aktivitet och andningssignaler och stressnivåer hos föraren. Fysiologiska variabler har också använts för att skilja måttlig mental belastning från låg mental belastning vid körning på väg på motorvägar och i städer [12]. Många av de sensorer som tidigare använts är dock för invasiva för att användas i verkliga trafiksituationer, och det finns ett behov av att utveckla mer praktiska metoder som lämpar sig för verkliga situationer [5]. En utmaning med att studera hög mental belastning vid bilkörning är dessutom att den normalt bara förekommer i enstaka korta händelser kopplade till ett komplext trafikscenario. Simulatorkörning å andra sidan kan göra det möjligt att standardisera scenarier och skapa en hög arbetsbelastning under hela körningen.

Det finns få studier om plötslig sjukdomsupptäckt hos förare. Den mesta forskningen inom detta område är retrospektiva studier av kraschrapporter. Det finns ett signifikant samband mellan plötslig sjukdom och olycksrelaterad dödlighet och skada hos äldre förare [16], [17]. Plötslig sjukdom/distraktion konstaterades ha varit den omedelbara riskfaktorn för ca 10 % av alla motorfordonsolyckor med dödlig utgång i Finland under åren 2003–2004 [17]. Hjärt- och kärlsjukdomar var vanligast. Det är mycket svårt att genomföra forskningsstudier om plötslig sjukdom vid verklig körning. Ett första steg mot övervakning och upptäckt av plötslig hjärt-kärlsjukdom under körning i realtid är att identifiera och utveckla diskreta sensorer som kan upptäcka vissa kardiovaskulära händelser i kontrollerade miljöer. I detta projekt fokuserar vi på hög puls och arytmier som efterliknas av simulering, men konceptet kan vidareutvecklas för att täcka andra kardiovaskulära händelser.



För att tillgodose behovet av automatisk övervakning av vitaldata såsom hjärtfrekvens och andningsfrekvens har ingenjörer utvecklat och undersökt olika nya koncept under de senaste åren och bland alla föreslagna tekniker har mikrovågs/radarbaserad övervakning stor potential på grund av flera fördelar. För det första är det den mest bekväma och diskreta metoden eftersom sensorn inte behöver någon kontakt med kroppen. För det andra begränsas dess funktion inte av siktlinjen eller ljusförhållandena, vilket krävs för kamerabaserade och laserbaserade lösningar. Mikrovågor kan tränga igenom kläder och är därför lämpliga för olika övervakningssituationer. Slutligen kan mikrovågssensorer enkelt integreras i olika miljöer, t.ex. förarhytten, ambulanser och hem för att möjliggöra kontinuerlig övervakning av vitaldata. En fördel med mikrovågsradarsensorer jämfört med kamerabaserade lösningar är att användarna kan vara mer positiva ur integritetssynpunkt. Konceptet har redan visat sig fungera under gynnsamma förhållanden, men inte under förutsättningarna som finns i rörliga fordon och med förarens rörelser när t.ex. ratten vrids. Vår hypotes är att framgångsrik upptäckt under utmanande omständigheter kan kräva sofistikerad signalanalys och möjligen mer än en radarsensor. Genom att detektera slag-för-slag-intervall med tillräcklig precision kan HRV bedömas, vilket kan göra det möjligt att upptäcka hjärtsjukdomar, t.ex. arytmier.

Målet med konceptet Connected Occupant Physiological Evaluation (COPE) som initierats av Chalmers tekniska högskola i samarbete med Autoliv Research är att utveckla och utforska forsknings-, samhälls- och affärsmöjligheter inom fordon och hälsa med hjälp av en plattform för uppkopplade fordon (Figur 1). Plattformen kommer att användas för att öka trafiksäkerheten, förbättra intelligenta transportsystem och möjliggöra hälsoapplikationer i fordon och uppkopplade hälsoapplikationer. COPE kommer att möjliggöra förarövervakning och kapacitetsuppskattning i realtid genom diskret mätning och analys av förarens fysiologiska signaler som hjärtfrekvens (HR), hjärtfrekvensvariabilitet (HRV) och andningsfrekvens, samt data relaterade till förarens prestationer. Tillämpningar kan hittas i scenarier som förväntas i helt eller delvis automatiserade fordon, samt möjligheten att upptäcka hälsoproblem som kan påverka körförmågan, och i situationer efter en olycka för att förbättra vård och räddning. De automatiserade fordonen kommer att vara bättre rustade för att hantera sådana situationer om förarens tillstånd kan detekteras korrekt.



Figur 1: COPE-plattformen kombinerar data från olika sensorer som mäter förarens fysiologiska parametrar. Genom att använda datafusion och maskininlärning kan våra möjligheter att detektera förarens tillstånd förbättras och slutsatser om lämplighet att köra kan dras.

Utvecklingen av COPE-konceptet startade 2019 som ett samarbete mellan Chalmers och Autoliv Research, som tillsammans är väl lämpade att driva både fordons- och hälsodomäner. Idén till COPE bygger på arbete som utförts vid institutionen för elektroteknik på Chalmers i samarbete med Autoliv och VTI för att bedöma förarens sömnhetsnivå via artificiell intelligens (AI), genom maskininlärning av HRV-signaler. Målet är att gå mot detektering av vitala data i realtid och bedömning av förartillstånd, och att bredda omfattningen av övervakning av förartillstånd till att även omfatta stress och plötsliga sjukdomstillstånd. En av de största utmaningarna kommer att vara att få robusta vitala signaler, t.ex. hjärtfrekvens, från diskreta mätningar via flera sensorer i bilen som ratt och säte, med varierande signalstyrka beroende på förarens position och klädsel.

4 Syfte, forskningsfrågor och metod

Det övergripande syftet med projektet är att visa proof-of-concept för att detektera förartillstånd utifrån mätningar av fysiologiska data, och mer specifikt adresserades följande: 1) Detektering av sömnhetsnivå / trötthet i verklig körning; 2) Bedöma mental belastning hos yrkesförare i simulator; 3) Detektering av hjärtfrekvens / plötslig sjukdom i labb. Projektet delades därför in i tre delprojekt som följer, där flera projektdeltagare deltog i flera delprojekt för att utbyta erfarenheter och lärdomar och diskutera projektets mål.

4.1 Delprojekt 1 Detektering av trötthet i verklig körning

I COPE Driver-projektet har vi genomfört en studie där fordonsinstrumentering och datainsamling gjordes specifikt med fokus på fysiologiska data och sömnhetsdata och relaterad instrumentering. Som en del av studien har vi gjort en omfattande analys av fysiologiska data och sömnhetsdata som samlats in från bilförare i en naturalistisk miljö. Baserat på analysen av insamlade data har vi utvecklat en maskininlärning (ML)-baserad algoritm för att förutsäga förarens sömnhetsnivå eller trötthet enligt Karolinska Sleepiness Scale (KSS) med hjälp av HRV-index [9]. KSS mäter en subjektiv sömnhetsnivå per individ vid en viss tid på dygnet som är lyhörd för miljöfaktorer samt dygnsrytm.



Det har gjorts många forskningsinsatser som rapporterats i litteraturen för att förutsäga förarens sömnhet baserat på de fysiologiska mätningarna [5]. En nyhet med denna studie är dock att analysen baseras på data som samlats in under verkliga körförhållanden på verkliga vägar istället för i en körsimulator. Dessutom har en naturalistisk datainsamling använts där det inte fanns några begränsningar för körsessionens längd, tid på dygnet, bildrift (manuell/automatisk) bland andra möjliga kontrollparametrar för att få data så nära som möjligt hur människor kör i verkligheten i en dynamisk miljö. Vi har bedömt potentialen att upptäcka sömnhet baserat på ML med hjälp av flera utvärderingsstrategier relaterade till flera datakällor som vi hade tillgång till. Detta för att förstå effekten av datamängdens storlek och generaliseringsmöjligheter hos de utvecklade modellerna.

Datainsamling och instrumentering

Som tidigare nämnts utformades studien som en naturalistisk körstudie, som först godkänns av Etikprövningsmyndigheten (dnr 2022-05313-01). Deltagarna körde en instrumenterad bil som en del av sin dagliga rutin, och instrumentet i bilen samlade in data som laddades upp till en säker molninfrastruktur. Den insamlade datan användes för att träna och förbättra sömnhetsmodeller med hjälp av maskininlärningsmetoder.

Instrumenteringen består av två delar: huvudenheten som är en låda med ett pekskärmgränssnitt monterat på instrumentbrädan i bilen, och ett Polar H10 pulsband (konsumentklassat).

Huvudenheten (Figur 2) består av tre distinkta delar: 1) En Raspberry Pi 4, som är en liten enkortsdator; 2) En pekskärm som används för att interagera med användarna. Huvudenheten ber deltagarna att mata in sin upplevda sömnhet var femte minut med hjälp av Karolinska sömnhetsskalan (KSS) med hjälp av pekskärmen (frågan ligger kvar ett tag ifall trafiksituationen gör det olämpligt att svara direkt). 3) Ett skräddarsytt kretskort med olika gränssnitt som stöder anslutning till olika sensorer. I det här projektet använder vi den för att omvandla spänningen från bilen till en lämplig nivå för Raspberry Pi för att driva huvudenheten och hantera dataanslutningen till bilen via diagnostikporten (OBD2-porten). Förutom att läsa data från diagnosporten samlar huvudenheten även in andra data. Den har en inbyggd IMU som registrerar accelerations- och rotationsdata.

Huvudenheten ansluter kringutrustning trådlöst. En mobiltelefon används för att ansluta huvudenheten för att dela internetåtkomsten så att enheten både kan kalibrera tiden och ladda upp den insamlade datan till molnlagringen automatiskt. En annan enhet krävs för att samla in hjärtslagsdata, det vill säga Polar H10-bandet.



Figur 2: Exempel på montering av huvudenheten i bilen.

Polar H10

Polar H10 är ett konsument pulsband. Det kan antingen användas via de standardiserade Bluetooth-pulsprofilerna, där den tillhandahåller grundläggande förbehandlade data, eller valfritt genom att använda anpassade protokoll för att läsa rådata från enheten. Sådana data kan t.ex. vara rå EKG-data eller accelerationsdata från den inbyggda accelerometern.

I datainsamlingsfasen använde vi standard Bluetooth-profil för att läsa av dessa data av huvudenheten, det vill säga pulsbandet mäter EKG och utför beräkningen för att härleda hjärtfrekvens och RR-intervall.

Specifikation av uppgifter

Uppgifterna samlades in i realtid av huvudenheten. Datatyp, källor och frekvenser som används för datainsamling beskrivs i Tabell 1.

Tabell 1: Specifikation och källor för insamlade data.

Data Name	Source	Frequency
Vehicle Speed	OBD2 Port	3 Hz
Pedal Percentage	OBD2 Port	3 Hz
KSS	Touchscreen	Every 5 minutes
Heartrate & RR-interval	Polar H10 Strap	1 Hz
Acceleration	IMU	4.5 Hz
Rotation	IMU	4.5 Hz

Test procedur

Datainsamlingen inleddes med ett pilottest när instrumenten var klara. I pilottestet körde några projektmedlemmar instrumenterade bilar för att testa systemkapaciteten, och uppgraderade sedan hårdvara och mjukvara i enlighet med de problem som hittades. Därefter inleddes en formell datainsamlingsfas där deltagarna efter att ha givit informerat samtycke uppmanades att köra sina egna privata bilar. Om några deltagare hade svårt att använda sin privata bil eller om deras bil inte var tekniskt tillgänglig för datainsamling med hjälp av huvudenheten, erbjöds de att använda en testbil från Autoliv Research. Alla inblandade bilar var instrumenterade på följande



sätt: 1) Fixerade huvudenheten till ventilationsutloppet; 2) Kopplade in strömuttaget i bilens 12-V uttag (förr cigarettändare); 3) Anslöt huvudenhetens datakabel till bilens OBD-port.

Deltagarna gavs först utförlig information om studien och gav informerat samtycke. Sedan ombads de att använda sin mobiltelefon för att ställa in sitt anonyma användar-ID via Bluetooth-parning. De fick också instruktioner om hur datainsamlingen ska genomföras och hur de ska mata in värden enligt KSS-skalan på huvudenheten efter var 5:e minut av resan. Deltagarna körde vanligtvis de instrumenterade bilarna till kontoret och hemkomsten som sin dagliga rutin. Deltagarna kunde även köra på andra turer. En resa bör vara längre än 20 minuter för att samla mer tillförlitliga data med tillräcklig volym för analys. Förra ombads att bära Polar H10 pulsband före bilfärden startar och ta med den ihopparade mobiltelefonen i den instrumenterade bilen. Huvudenheten startar när föraren startar tändningen. Polar H10 ansluts automatiskt via Bluetooth till huvudenheten. Displayen visade förarens namn och antal registrerade körningar vid varje körnings början. Om allt var i sin ordning blev släcktes skärmen snart efter start förutom när huvudenheten begärde att föraren skulle mata in KSS-bedömning var 5:e minut, detta för att störa föraren så lite som möjligt.

Huvudenheten samlade in data från bilen och pulsbandet, och detta sparades i loggfiler. När en resa avslutas och tändningen stängs av, stängs huvudenheten av automatiskt. Loggfilerna stannade kvar i huvudenhetens interna lagring tills de laddades upp till molnlagringen nästa gång huvudenheten slogs på.

Beskrivning av dataset

Här beskriver vi den datamängd som samlades in som en del av datainsamlingsarbetet inom detta projekt. Alla personuppgifter pseudonymiserades och ersattes med unika deltagaridentifikatorer. Det var totalt 18 deltagare (forskningspersoner) då denna rapport skrivs (datainsamlingen är pågående) och 16 återstod efter datafiltrering och förbehandling, detaljer om dataanalysen kommer att beskrivas senare. Det totala antalet resor uppgick till 224 och 138 blev kvar efter förbehandling av data. På samma sätt fanns det efter förbehandling 795 episoder med 5 minuters varaktighet i datasetet. Datasetet inkluderade fysiologiska signaler inklusive RR-intervall och hjärtfrekvensdata. När det gäller märkning av data samlade vi in KSS-värden som rapporterades ungefär var 5:e minut av förarna baserat på deras upplevelse under de senaste 5 minuterna. Det är också värt att nämna att för en liten del av de totala resorna samlades även några ytterligare signaler från fordonet in, nämligen fordonshastighet, bromspedalstillstånd samt IMU-signaler (3D-accelerometer och gyroskop) som registrerades från en smartphone monterad på instrumentbrädan i bilen. På grund av tekniska svårigheter i instrumenteringen i vissa bilar var det dock inte möjligt att samla in dessa signaler under de flesta resorna.

Från Tabell 2 kan vi se att de flesta resorna innehåller antingen 3, 4, 5 eller 6 episoder (5-min avsnitt av resan), vilket innebär att många resor var cirka 15 till 30 minuter långa. Tabell 3 visar att vissa försökspersoner bidrog med många fler resor medan andra hade mycket få resor rapporterade i datasetet. Så fördelningen av resorna baserat på resans längd och resor per deltagare var ganska varierad.



Tabell 2: Reslängder (antal 5-min episoder) och deras frekvens i datamängden.

Trip Length (Episodes)	Trip Frequency
1	8
2	9
3	12
4	33
5	23
6	13
7	7
8	9
9	3
10	3
11	6
12	2
13	5
14	1
15	3
16	1

Tabell 3: Antal resor per deltagare.

Participant ID	Trip Count
0	5
1	1
2	4
3	4
4	19
5	9
6	21
7	16
8	8
9	2
10	17
11	7
12	13
13	1
14	9
15	2


Externa datakällor

I denna studie har vi för vissa utvärderingsmetoder som beskrivs senare i resultatavsnittet också använt data som samlats in som en del av Mediator-projektet. Den experimentella designen och datainsamlingen genomfördes gemensamt av Autoliv, Statens väg- och transportforskningsinstitut (VTI) och Smart Eye AB. Studien har finansierats av ett anslag inom ramen för EU-projektet MEDIATOR. Experimentet involverade individer som körde genom en tvåfilig motorväg med varierande grad av automatisering och tid på dygnet. Forskarna administrerade en 2x2-kombination av automatisering och tillstånd: med nivå 2-assistans aktiverad/inaktiverad och med körförhållanden dagtid (efter normal sömn) / nattetid (efter sömnbrist). Följaktligen deltog varje deltagare i fyra separata körningar, två på dagen och två på natten. Deltagarna instruerades att få minst 7 timmars sömn, gå och lägga sig senast vid midnatt och vakna senast klockan 9 på morgonen under tre dagar i följd före experimentdagarna. Under

datainsamlingen fick deltagarna ta på sig olika sensorer för att mäta fysiologiska data. Under körpasset rapporterade deltagarna sin nivå av sömnhet var 5:e minut enligt KSS-mätskalan. Mer information om projektet, experimentell design, instrumentering och datainsamling finns i [18].


Förbehandling av data och feature extraction

Som tidigare nämnts används pulsband för att samla in EKG rådata om RR-intervall från bilförare under deras körpass. Data samlas ursprungligen in i JSON-format på enheterna och konverteras sedan senare till mer ML-användarvänligt CSV-format som en del av förbehandlingsfasen. RR-intervall (R-toppar) beräknas från R-vågsdata som fångas från EKG signaler, och det hänvisar till tidsintervallet från en R-våg till nästa. Normal-Normal intervall beräknas genom filtrering av onormala R-toppar som kan förvränga de statistiska måtten. Detta inkluderar att ta bort både extremvärdena samt att ta bort de ektopiska slagen. Detta hjälper till att rensa data (Figur 3). För att ta bort extremvärden fastställdes ett acceptabelt intervall av RR-intervall från 300 ms till 1300 ms. När det gäller borttagning av ektopiska slag använde vi Malik-regeln [19]. Borttagna punkter interpolerades sedan med hjälp av linjär interpolation. Det fanns några resor som antingen saknade fysiologiska data eller KSS-data på grund av vissa datainsamlingsproblem. De uteslöts från analysen samt den träningsdata som senare användes för prediktiv modellering.



Figur 3: Höga extremvärden och ektopiska slag observerades i vissa episoder.

Vi fann också att i vissa fall på grund av högt brus rapporterades inte hjärtfrekvensen korrekt av sensorn, som visas i Figur 4 baserat på de processade RR-intervallen. Observera att x-axeln visar tripp/resnumret och y-axeln visar medelpulsen i slag per minut (BPM).



Figur 4: Medelpuls rapporterad av sensorn för varje resa jämfört med beräknad baserat RR-intervallen.

HRV-parametrar extraheras från Normal-Normal slagintervall (baserat på RR-intervall mätt i millisekunder). När aktuell KSS rapporteras tar vi hänsyn till de senaste 5 minuterna som förflutit (sedan den senaste rapporterade KSS) och använder det tidsfönstret för extrahering av features. På så sätt genereras en funktionsvektor för varje 5-minutersfönster och matchas med KSS för det tidsfönstret. För närvarande har vi implementerat ett fast tidsfönster (ingen fönsterglidning) för extrahering av funktioner. Den för närvarande implementerade data pipeline för extrahering av features extraherar längs tre nyckeldimensioner, nämligen: Temporal (minimum, maximum av hjärtfrekvens, medelvärde och standardavvikelse etc.), Spektral (total effekt och varians i olika

frekvensband) och Domänspecifik (fysiologirelaterad i detta fall). Totalt finns det 31 features som extraheras från signalen. Som tidigare nämnts omfattar annan förbearbetning, som en del av data pipelinen, datanormalisering, hantering av avsaknade värden, borttagning av avvikande värden osv. för att förbättra kvaliteten på de data som ska matas in i ML-modellträningssalgoritmen.

Problemformulering och datadrivet förhållningssätt

Här har vi valt att använda ett datadrivet tillvägagångssätt baserat på ML för att lösa problemet med att prediktera sömnhet hos förare baserat på fysiologiska data. Vi har formulerat problemet som ett binärt klassificeringsproblem. Det innebär att förarens tillstånd betraktas som antingen "sömnig" eller "inte sömnig". Kriterier i detta fall är att föraren endast klassificeras som "sömnig" om villkoret $KSS \geq 7$ är uppfyllt, annars klassificeras den som "icke-sömnig".

En ML-baserad modell utvecklas baserat på gradientförstärkta beslutsträd i en Python-miljö med hjälp av det välkända XGBoost Python-biblioteket [20], [21]. Parametrar för XGBoost-modellträningen justerades manuellt och konfigurerades inkluderande antalet estimatorer, växande trädjup, inlärningshastighet och vikter. För funktionsnormalisering användes standardskalning i Python. Det är en skalningsteknik där värdena är centrerade kring medelvärdet med en enhetsstandardavvikelse. Skalningsparametrar beräknades endast med hjälp av träningsdata och användes för transformering på både tränings- och testdata. Detta gjordes för att undvika dataläckage.

Den tränade algoritmen kan förutsäga drivrutinstillståndet baserat på en 5-minutersepisod av beräkning av HRV-parametrar för föraren. Observera att metadata som time-on-task (tid som förflutit sedan föraren har startat den aktuella körsessionen), förar-ID eller bil-ID inte användes för att träna ML-modellen. Huvudorsaken är att vår avsikt är att förutsäga förarens sömnhet enbart utifrån förarens fysiologiska tillstånd. Dessutom kan användning av sådan metadata tvinga ML-modellen att lära sig oönskade mönster som relaterar till särdragen hos det insamlade datasetet som samlats in under en viss miljö och vissa förutsättningar, vilket skulle kunna göra generaliserbarheten (hur bra modellen presterar på ny data) sämre.

Tabell 4: Antal sömnhetsepisoder per KSS-värde.

KSS Label	Frequency
1	12
2	105
3	118
4	151
5	228
6	130
7	47
8	3
9	1

Vi observerade en stor variation i fördelningen av antalet episoder associerade med varje sömnhetstillstånd per förare. Detta resulterar i kraftigt obalanserade data (förhållandet mellan "sömniga" episoder och "icke-sömniga" episoder är endast 0,064 i datauppsättningen) för att träna algoritmen vid klassificering. Samma obalans kan också observeras när frekvensen av sömnhetsepisoder som är associerade med vart och ett av KSS-värdena studeras, som visas i Tabell 4. I synnerhet är antalet episoder med KSS-nivån 8 och 9 nästan obefintligt representerade i data. Detta medför ytterligare utmaningar för utvecklingen av sömnhetsprediktion. Av den anledningen har inlärningsalgoritmen konfigurerats för att tränas med hjälp av högre klassvikt som tilldelats data som är associerade med klassen "inte sömnig". Syftet är att bestraffa felklassificeringen av "minoritetsklassen" ("sömnig") mer jämfört med

majoritetsklassen ("icke-sömnig"). Regularisering görs också genom att ange parametern för att begränsa det maximala djupet för genererade träd för att undvika överanpassning av träningsdata.

Som tidigare nämnts, efter filtrering för datakvalitetsproblem, fanns det data från 16 förare (deltagare) som inkluderades för utveckling och validering av den fysiologibaserade ML-modellen för förutsägelse av sömnhet. För att bättre förstå modellens prestanda tar vi inte hänsyn till prestandan hos de förare som inte upplevde några sömnhetsepisoder alls under denna studie (inga KSS ≥ 7). Data från dessa förare ingick dock fortfarande i träningsdatasetet.

Observera att i denna studie samlas inte rå EKG-data in från deltagande förare och beaktas därför inte heller i analys- och modellutvecklingsfasen. Detta gjordes delvis av praktiska skäl för att begränsa den datamängd som genererades samt för att minska batteriförbrukningen på datainsamlingsenheter vid insamling och lagring av data under längre körpass. Detta är också i linje med de verkliga situationerna där sensorenheterna i de flesta praktiska scenarier endast matar ut IBI-data (Inter-beat Intervals, RR) i stället för rå EKG-data, även om det finns möjlighet att minska batteriförbrukningen och övervinna begränsningar för datagenomströmning. Detta innebär att den utvecklade algoritmen lätt kan distribueras även på en enhet med begränsade resurser utan överdriven beräkningskapacitet, minnesresurser eller batterikapacitet. En potentiell nackdel är dock att det finns en oundviklig informationsförlust vid omvandling av detaljerade EKG-signaldata till IBI-data, så ML-modellens prestanda kan potentiellt vara högre med full EKG data_

Performance Evaluation and Metrics

För att utvärdera prestandan hos utvecklade ML-baserade algoritmer använde vi lämpliga prestandautvärderingskriterier för klassificering. Eftersom data var kraftigt obalanserade som tidigare nämnts och för att göra en rättvis jämförelse, förlitar vi oss på F1-prestandautvärderingen av algoritmen på testdata (harmoniskt medelvärde för precision och recall) (Figur 5). Observera att F1-poängen endast maximeras om både precision och träffsäkerhet är maximerade (på grund av det harmoniska medelvärdet). När det gäller beteckningar hänvisar TP till "True Positives", FP till "False Positives", FN till "False Negatives" och TN till "True Negatives".

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$\text{ACC} = \frac{TP + TN}{P + N}$$

Figur 5: Prestandamått för klassificering.

Här representerar värdet 1,0 för F1 det bästa värdet och 0 är det sämsta värdet. Vidare definieras Makro F1-score som medelvärdet av klassvis/etikettvis F1-poäng både för positiv och negativ klass i detta fall. Viktad F1-poäng som beräknas utifrån klassrepresentationen i datan redovisas också. Detta ger oss en bättre bild av klassificeringsprestanda på obalanserade data. I Figur 5 hänvisar ACC till modellens totala noggrannhetsprestanda på testdata.

Förutom F1-poängen rapporterar vi också Cohens kappa-mått, som mäter inter-annotators överensstämmelse på ett klassificeringsproblem. Det är ett tal mellan -1 och 1. Det maximala värdet betyder fullständig överenskommelse medan noll eller lägre värde betyder slumpmässig överenskommelse. Här används Kappa för att mäta överensstämmelsen mellan de utvecklade



modellförutsägelserna jämfört med en "perfekt" modell som alltid förutsäger det korrekta KSS-värdet (dvs. grundsanningen, ground truth).

Observera att utöver de normala HRV-funktionerna som beskrivits tidigare konstruerade vi även en "baslinjekorrigerad" funktionsuppsättning per förare på grund av variationen i HRV-parametrarna som observerats per förare. Detta konstruerades genom att subtrahera de genomsnittliga värdena för olika features per deltagare som motsvarar $KSS \leq 5$ fall. En ML-modell som utvecklats baserat på inläring från denna baslinjekorrigerade funktionsuppsättning resulterade dock inte i några meningsfulla prestandaförbättringar, och därför rapporterades inte heller resultaten här. En mer omfattande undersökning för att hitta den lämpligaste strategin för individualisering av funktioner krävs i framtida studier.

För utvärderingen beslutade vi att använda oss av Cross Validation (CV) eller mer exakt Leave One Out CV (LOOCV). Det är en utvärderingsmetod där tränings- och testdata uppsättningar konstrueras dynamiskt i varje iteration av CV. På så sätt kan man maximera användningen av mindre datauppsättningar med färre exempel för både träning och testning. Dessutom gör LOOCV-varianten det möjligt för oss att utvärdera modellens generaliseringsprestanda på ett adekvat sätt. Kanske viktigast av allt är att LOOCV förhindrar informationsläckage där dataproverna som tillhör samma resa och/eller förare kan ha liknande egenskaper och endast bör ingå i antingen träningsdata eller testdata, men inte båda.

Prestatanda utvärderades med hjälp av tre olika strategier som beskrivs nedan. Den största skillnaden mellan dem är hur datauppsättningar (interna och externa datauppsättningar till projektet) används för att träna modellen och validera prestandan.

Metod 1: DrivER-datauppsättningen (intern) används för både träning och testning av modellen med hjälp av korsvalidering (LOOCV). I det här fallet uppskattar vi generaliseringsprestanda på samma datauppsättning (men för osedda förare/forskningspersoner).

Metod 2: Mediator-dataset (externt) som samlas in i Mediator-projektet används för att träna modellen och DrivER-dataset används för prestandautvärdering. Så i det här fallet uppskattar vi modellens generaliseringsprestanda i ett svårare scenario med en helt osedd datauppsättning som samlats in under olika antaganden och experimentdesign.

Metod 3: DrivER-datauppsättningen (intern) används för både träning och testning med korsvalidering (LOOCV). I det här fallet uppskattar vi generaliseringsprestanda på samma datauppsättning (men för osynliga förare/forskningspersoner) som metod 1. En viktig skillnad från metod 1 är dock att i varje CV-fold matas data från Mediator-datauppsättningen in i träningsdatapoolen för en mer robust träning av modellen.

4.2 Delprojekt 2 *Bedöma mental belastning hos yrkesförare i simulator*

Syfte och forskningsfrågor

I denna delstudie användes simulatortester designade för att framkalla olika nivåer av upplevd stress med målet att öka kunskapen om hur förarens mentala tillstånd (stress och mental belastning) påverkar körningen och hur fysiologisk stress kan övervakas under körning. Simulatorkörning möjliggör standardiserade scenarier mellan deltagare och att designa en hög arbetsbelastning under hela körningen. Syftet med studien var att undersöka hur akut stress påverkar körförmågan och att undersöka om det är möjligt att detektera höga stressnivåer med objektiva fysiologiska mätningar, samt validera en skala för att subjektivt uppskatta stress som liknar KSS för sömnighet. Sambandet mellan mental belastning, upplevd stress och körprestation



undersöktes för att få insikt i vilka mentala tillstånd som är viktiga att övervaka av trafiksäkerhetsskäl.

De specifika forskningsfrågorna var:

- Hur påverkar akut stress körförmågan?
- Kan fysiologisk övervakning användas för att upptäcka akut stress och hög arbetsbelastning under körning i en simulator?
- Kan stabila och robusta mätningar av vitaldata, såsom hjärtfrekvens och andningsfrekvens, utföras under körning med enklare sensorer som inte stör deltagarna?
- Validera en ny skala för att subjektivt uppskatta stress som kallas VTI Acute Stress Scale (VSS)

Metod

Ambulanssimulatortester genomfördes med scenarion utformade för att framkalla olika stressnivåer hos ambulans- och räddningstjänstpersonal. Fysiologiska mätningar (hjärtfrekvens, HR), subjektiva upplevelser och kördata från simulatören samlades in. Deltagarnas subjektiva bedömningar av körningarna och rapportering enligt VSS jämfördes med objektiva fysiologiska mätningar av stress och med kördata från simulatören. Resultaten jämfördes mellan körningar.

Deltagare

Deltagarna rekryterades bland ambulanspersonal och räddningstjänsten i västra Sverige.

Ambulanssjukvårdare, ambulanssjuksköterskor och brandmän tillfrågades att delta.

Exklusionskriterier var sjukdomar som kunde påverka hjärtfrekvensmätningarna, inklusive hjärt-kärlsjukdom, diabetes och neurologiska sjukdomar. Datainsamlingen ägde rum vid två olika ambulansstationer under fem olika tillfällen under 2022. Studien genomfördes i enlighet med Helsingforsdeklarationen, och informerat samtycke erhöles från alla deltagare. Studieprotokollet godkändes av Etikprövningsmyndigheten (ref 2021-04352).

Testprocedur

Deltagarna fyllde i en bakgrundsenkät med frågor om deras arbete, körerfarenhet, allmän hälsa, stress och sömn. Varje deltagare utförde tre simulatoruppgifter: uppgift A var en rutinkörning med låg stressnivå, uppgift B var en relativt brådsakande uttryckning med medelhög stress, uppgift C var en prio 1-uttryckning med förväntat hög stress. Uppgifterna randomiserades mellan deltagarna. Efter varje köruppgift fyllde de i en enkät med frågor om arbetsbelastning (NASA-TLX), stress (VSS, 9-gradig skala) och sömnhet (KSS, 9-gradig skala).

Datainsamling och bearbetning

Simulatorhårdvaran bestod av en dator, tre skärmar, pedaler och en ratt. Simulatorscenarierna var utformade för att likna verklig ambulanskörning. Inget av scenarierna involverade att ha en patient i fordonet. Förarna var fria att välja om de ville slå på blåljus och sirener. De instruerades att köra som de skulle ha gjort vid en verklig uttryckning.

Hjärtfrekvensen mättes med Polar H10 pulsband. Från simulatorerna registrerades kördata (hastighet, acceleration, bromsning, hastighetsbegränsning, händelse/event). Antalet kraftiga inbromsningar (deceleration $<-4,5g$) och antalet skador på fordonet användes som mått på körförmåga.

Hjärtfrekvensvariabilitet (HRV) analyserades som ett 5-minuters glidande medelvärde med 1 minuts steglängd. För analys av respons på specifika händelser användes hjärtfrekvens från H10 med en samplingsfrekvens på 1 Hz. Avvikande RR-intervall rensades med metoden beskriven av Clifford et al [22]. Tidsdomän- och frekvensdomänparametrar beräknades med hjälp av PhysioNet cardiovascular signal toolbox [23], [24]. Lomb periodogram användes för frekvensdomänanalys. HRV-parametrar inkluderade medelvärdet för normala till normala (NN) intervall, standardavvikelse av NN-intervall (SDNN), roten ur medelvärdet av på varandra följande skillnader (RMSSD) och antalet par på varandra följande NN-intervall som skiljer sig med mer än 50 ms (pNN50), mycket låg frekvens (VLF), låg frekvens (LF), hög frekvens (HF),



förhållandet mellan LF och HF (LF/HF) samt total power. En beskrivning av parametrarna finns i [25].

Statistisk analys

Resultaten presenteras generellt som medelvärden med standardavvikelser (SD). Skillnader i HRV-parametrar och skattningar mellan de tre köruppgifterna analyserades med variansanalys (ANOVA). Separata regressionsmodeller skapades med varje utfallsmått som beroende variabel. Köruppgift (A, B, C) inkluderades som en inomindividfaktor och forskningsperson inkluderades som en slumpmässig faktor. Om köruppgiftseffekten var signifikant, gjordes parvisa jämförelser mellan köruppgifter med Tukey post hoc-test. Signifikansnivån sattes till 0,05. Statistiska analyser utfördes i IBM SPSS Statistics version 29 (IBM Corp., Armonk, NY, USA).

4.3 Delprojekt 3 *Detektion av hjärtfrekvens / plötslig sjukdom i labb*

Delprojekt 3 genomfördes genom några olika experiment baserat på sensorer och försöksupställningar utvecklade av Raytelligence AB och Chalmers primärt, samt ett test som genomfördes tillsammans med Autoliv i testfordon. Vi beskriver här först försöken med Raytelligence metodik (inklusive mätningar i Autolivs testfordon) och därefter försöken på Chalmers.

Syfte och bakgrund Raytelligence experiment

Som ett delprojekt i COPE DrivER har vi studerat möjligheterna att använd radarsensorer för att under färd detektera vitalparametrar hos föraren. Fokus har varit på hjärtfrekvens vilket är användbart för att upptäcka plötslig sjukdom då onormalt hög hjärtfrekvens (t.ex. > 140 BPM) kan vara tecken på plötslig sjukdom. Vi har använt en specialutvecklad sensor från Raytelligence AB. Sensorn baseras på RADSENZ-plattformen. Raytelligence har sedan i projektet utvecklat nya funktioner som är nödvändiga för att kunna detektera vitalparametrar i den mycket besvärliga miljön som råder i en bil under färd.

Den bärande principen för att detektera andning och puls hos en person med radar är att ur fasinformationen från den reflekterade radarsignalen urskilja de mycket små rörelser som förarens torso gör till följd av både andning och hjärtslag. Detta är en mycket utmanande uppgift.

Metod Raytelligence experiment

I en preliminär studie utförd hos Autoliv kördes Autolivs experimentbil bestyckad med en RADSENZ-sensor placerad på insidan av vindrutan riktad mot förarens bröstorg. Bilen kördes i två sessioner på vanlig väg och signaler från sensorn registrerades. Figur 6 visar försöksbilen vid tillfället för provet.



Figur 6: Autolivs försöksbil vid testet med radardetektering av hjärtfrekvens.

I Figur 7 visas sensorns placering och signalen som registrerades.




Figur 7: Placering av radarsensor vid mätning av förarens hjärtfrekvens.



Figur 8: Registrerad radarsignal under körning.

I Figur 8 visas den signal som radarn ger. I det blå fältet visas en rangeprofil från radarn där intensiteten är färgkodad. Varje linje är en rangeprofil. X-axeln representerar tiden. Med tanke på de mycket små displacement som skall mätas visade de preliminära experimenten att vibrationerna från bilen är för stora för att med tillräcklig noggrannhet detektera hjärtfrekvens. Det finns studier som visar både hjärtfrekvens och andning hos personer som sitter på en stol framför radarn. Det har inte visats att detta är möjligt i en körande bil.

Därför genomfördes ett omfattande arbete att modifiera RADSENZ-plattformen som möjliggjorde mätning av de vibrationer som förekommer i en bil under färd. Om dessa kan mätas kan också



Figur 9: Försökupställning för vibrationsmätning.

filter konstrueras för att eliminera dessa i signalen. Av praktiska skäl utfördes dessa mätningar i Raytelligence labb i Halmstad. Olika vibrationskällor användes vid experimenten. All signalbehandling genomfördes i sensorn och visades på en hemsida som låg på sensorn. Detta är unikt så vitt vi vet. I Figur 9 visas en försökupställning för att mäta vibrationer. I detta fall används en bormaskin som vibrationskällan. I bilden visas även ett hinder framför radarsensorn.

Syfte och bakgrund Chalmers experiment

Syftet var att undersöka potentialen för att detektera tecken på plötslig sjukdom i form av arytmi med radarteknik genom att mäta hjärtfrekvens och intervallen mellan hjärtslag.


Forskningsfrågor inkluderar:

- Var bör radarsensorn placeras?
Radarpositionen är avgörande för hur noggrant hjärtslagssignalen kan detekteras och det bedömdes därför nödvändigt att undersöka olika positioner av radarn för att kunna dra slutsatser kring vilken position som är mest lämplig.
- Hur säkert kan hjärtfrekvensen mätas med radarteknik i ett brett hjärtfrekvensområde?
De flesta av de publicerade studierna betraktade endast ett normalt hjärtfrekvensområde, d.v.s. 60~100 BPM. För att detektera en arytmi, vilken kan kännetecknas av en mycket högre hjärtfrekvens, behöver vi kunna mäta onormalt hög hjärtfrekvens med hög noggrannhet.
- Påverkar kläder mätningsnoggrannhet?
Principen av radarteknik är att skicka ut en elektromagnetisk signal som träffar ett föremål och reflekteras tillbaka och sen mottas. Tjockleken och materialet på kläderna påverkar styrkan av den reflekterade signalen, vilket i sin tur kan ha en effekt på mätningsnoggrannhet.
- Kan vi åstadkomma mätningar av intervallen mellan hjärtats slag med hög precision (RR-intervall)?
Arytmi kännetecknas av oregelbundna, för långsamma eller för snabba hjärtslag. Om intervallen mellan hjärtats slag kan mätas med hög precision, kan man upptäcka förekomsten av olika typer av arytmier.

Metod Chalmers experiment

För att besvara de ovanstående forskningsfrågorna, har vi designat och genomfört två olika studier. Den första studien fokuserade på hur radartekniken kan tillämpas för att uppskatta hjärtfrekvensen hos patienter med arytmi och den andra studien fokuserade på hur radarteknik kan användas för att urskilja hjärtslag hos patienter med arytmi. Båda studierna utfördes i en labbmiljö på Chalmers.

Radarsensorn var AWR1642BOOST tillverkad av Texas Instruments. AWR1642BOOST är en FMCW-radar som arbetar vid 77 GHz och stödjer en bandbredd på 4 GHz. En inspelningsenhet DCA1000EVM tillverkad av Texas Instruments används också i projektet för att fånga rå data från sensorn för vidare signalbehandling. I Figur 10 (vänster) syns FMCW-radarn AWR1642BOOST och inspelningsenheten DCA1000EVM. Som referens till FMCW-radarn användes en EKG-sensor, en trådlös 8-kanals biosignalspluxmodul (Figur 10, höger), för att ge grundsanningen för hjärtslag.



Figur 10: Radarsensor (vänster) och EKG sensor (höger).



I den första studien undersöktes tre olika sensorpositioner, där det även har tagits hänsyn till att uppställningen ska kunna appliceras i en bil. Tre försökspersoner med normal puls och hög puls skapad genom fysisk ansträngning mättes under stationära och rörliga förhållanden. Dessutom har två olika jackor prövats under mätningar, en tunnare och en tjockare jacka.

I den andra studien placerades radarsensorn framför och bakom försökspersonen i olika mätningsserier och totalt har sex försökspersoner uppmätts under stationära och rörliga förhållanden. Avancerade metoder har tagits fram för signalbehandling.

5 Mål

Syftet med projektet var att utveckla följande relaterade koncept för detektering av förartillstånd:

1) Studera sömnhetsdetektion i verklig körning; 2) Bedömning av stressnivå och mental belastning hos yrkesförare (ambulanspersonal) med hjälp av diskreta sensorer separat eller i kombination (sensorfusion). 3) Detektion av vitaldata och plötslig sjukdom på grund av hjärtrelaterade komplikationer såsom arytmier. De specifika forskningsfrågorna var:

1. Är det möjligt att upptäcka sömnhets hos föraren med hjälp av diskreta sensorer vid vardagskörning?
2. Kan fysiologisk övervakning användas för att upptäcka hög mental belastning och stress under körning?
3. Kan vi etablera stabila och robusta mätningar av vitaldata, såsom HR/HRV och andningsfrekvens i körscenarier?
4. Vilka sensorer är lämpliga för diskret fysiologisk övervakning och detektering av sömnhets, stress/hög arbetsbelastning och plötslig sjukdom?
5. Kan sensorfusion förbättra övervakningen av förartillstånd?

Målen har under projektets gång egentligen inte förändrats, men projektet lyckades inte angripa forskningsfråga 4 och 5 så som ambitionen var, då de tre delprojekten var mycket utmanande i sig utan att addera den ytterligare komplexitet som det innebär att addera fler sensorer.

6 Resultat och måluppfyllelse

6.1 Delprojekt 1 *Detektion av trötthet i verklig körning*

I COPE DrivER-projektet har vi genomfört en studie där fordonsinstrumentering och datainsamling gjordes specifikt med fokus på fysiologiska data och sömnhetsdata samt relaterad instrumentering i fordonet. Som en del av studien har vi gjort en omfattande analys av fysiologiska data och sömnhetsdata som samlats in från bilförare i en naturalistisk miljö (verklig körning). Baserat på analysen av insamlade data har vi utvecklat en ML-baserad algoritm för att prediktera förarens upplevda sömnhets / trötthet enligt KSS. En nyhet med denna studie är att analysen baseras på data som samlats in under verkliga körförhållanden på verkliga vägar istället för i en köringsimulator. Dessutom har datainsamlingen inga begränsningar för köringsessionens längd, tid på dygnet, bildrift (manuell/automatisk), bland andra möjliga kontrollparametrar, för att få data så nära som möjligt hur människor kör i verkligheten i en dynamisk miljö. Vi har bedömt potentialen att upptäcka sömnhets baserat på ML med hjälp av flera utvärderingsstrategier relaterade till flera datakällor som vi hade tillgång till. Detta för att förstå effekten av datamängdens storlek och bedömd generalisering till nya osedda data hos de utvecklade modellerna.

Resultat

När det gäller prestandautvärderingen, med början i utvärderingsmetod 1, redovisas detaljerade resultat i Tabell 5. Här visar varje rad prestandamått för en specifik test fold. Observera att 2:a och 3:e kolumnen hänvisar till makrot respektive det viktade genomsnittet av F1-poängen. Som vi kan observera, vilket dock beror på den stora obalansen i datasetet (få episoder innehåller höga KSS-värden som motsvarar vad vi definierat som sömning dvs $KSS \geq 7$), ser resultaten bra ut för de flesta test folds och uppnår prestanda på mer än 90 procent. En liknande bild målas upp av den viktade genomsnittliga poängen. En mer realistisk resultataspikt visas dock av makrogenomsnittet som faller under 50 procent på alla sätt. Kappa-statistik visar också att tränad klassificerare inte är bättre än en slumpmässig klassificerare eftersom värdena ligger kring 0.

Accuracy	Macro Avg.	Weighted Avg.	Kappa Stats	Test Fold
0.926	0.481	0.950	-0.021	1
0.954	0.488	0.944	-0.019	2
0.812	0.448	0.728	0.000	3
0.970	0.492	0.955	0.000	4
0.746	0.485	0.665	0.062	5
0.928	0.481	0.893	0.000	6
0.444	0.308	0.274	0.000	7

Tabell 5: Tabellen visar prestandamått per test fold för klassificering av testdata med metod 1.

Resultaten av utvärderingen av prestanda med utvärderingsmetod 2 visas i Tabell 6. Vi kan observera att även om prestanda på majoritetsklassen "Not-Sleepy" är ganska bra, kämpar modellen med förutsägelseprestanda på minoritetsklassen (Sleepy). Testkappa-poäng på 0,13 uppnåddes dock, vilket tyder på en viss grad av överensstämmelse mellan en hypotetisk "perfekt klassificerare" och den klassificerare vi har tränat här.

	Precision	Recall	F1-Score	Accuracy	Kappa Stats	Support/Count
Not-Sleepy	0.95	0.84	0.89	-	-	744
Sleepy	0.14	0.39	0.21	-	-	51
Accuracy	-	-	-	0.81	-	795
Kappa Stats	-	-	-	-	0.130	795
Macro Avg.	-	-	0.55	-	-	795
Weight. Avg.	-	-	0.85	-	-	795

Tabell 6: Tabellen visar prestandamått per test fold för klassificering av testdata med metod 2.


Utvärdering av prestanda med hjälp av utvärderingsmetod 3 redovisas i Tabell 7. Som vi kan observera förbättras makrogenomsnittet (av F1-poäng) och kappa-statistik avsevärt jämfört med vad som observerades tidigare för utvärderingsmetod 1. Detta visar tydligt fördelarna med att använda mer träningsdata när ML-modellen utvecklas.

Accuracy	Macro Avg.	Weighted Avg.	Kappa Stats	Test Fold
0.951	0.487	0.963	-0.019	1
0.841	0.556	0.888	0.153	2
0.583	0.531	0.629	0.144	3
0.910	0.601	0.931	0.215	4
0.746	0.595	0.716	0.208	5
0.913	0.477	0.885	-0.025	6
0.556	0.500	0.481	0.182	7

Tabell 7: Tabellen visar prestandamått per test fold för klassificering av testdata med metod 3.

När det gäller modellens förklarbarhet är vi också intresserade av den relativa betydelsen av olika HRV-parametrar som extraherats från fysiologiska data och spelar en viktig roll för


modellens prediktionsförmåga. I det här fallet har vi använt SHAP-värden (SHapley Additive exPlanations) för tillförlitliga resultat för att fånga den relativa betydelsen och fördelningen av olika HRV-parametrar. SHAP-värden är ett elegant sätt att samla in ett mått på en variabels bidrag till förutsägelsen av modellens utdata. Vi har använt SHAP Python-paketet för att beräkna SHAP-värdena. Figur 11 visar fördelningen av de effekter som varje funktion har på modellens utdata i ett detaljerat Beeswarm-diagram. Observera att modellen som utvecklats i metod 2 har använts för att generera resultaten som rapporteras här.



Figur 11: Fördelning av SHAP-värden för prediktionsmodellens ingående variabler.

Det här diagrammet ger en översikt över viktiga variabler för modellen genom att visualisera SHAP-värdena. Diagrammet sorteras efter summan av SHAP-värdets storlek över alla prover. Som vi kan observera beräknas de frekvensbaserade variablerna vara viktiga av modellen (total effekt, vlf, etc.). Med tanke på dessa två viktigaste variabler som exempel kan vi dra slutsatsen att lägre värden för dessa funktioner minskar SHAP-värdet, vilket i sin tur resulterar i minskad sannolikhet för bra förutsägelse av sömnhet. Ett förenklat diagram som sammanfattar variabelns betydelse baserat på detta diagram visas i Figur 12. Detta är ett enkelt SHAP-

stapeldiagram som beräknar det genomsnittliga absoluta värdet för varje funktion över alla instanser (rader) av datasetet för att fånga den övergripande betydelsen av olika funktioner.



Figur 12: Variabelns betydelse baserat på genomsnittligt absolut SHAP-värde.

Det viktigaste att ta med sig från resultaten av utvecklingen av sömnighetsprediktionsmodellen är att metod 1 inte visar tillfredsställande prestanda. Det var väntat på grund av den lilla storleken på DrivER-datasetet i nuläget (studien är pågående). Å andra sidan visar metod 2 förbättrad prestanda jämfört med metod 1. Detta inträffar även om hela utvärderingsdatasetet (d.v.s. DrivER datasetet) inte kan ses av den tränade modellen. Som tidigare nämnts i metod 2 kommer utbildningsdatasetet från de historiska data som samlats in i Mediator-projektet. En förklaring till detta är att träning på större datamängder (t.ex. Mediator) gör det möjligt att utveckla en mer robust modell. Den totala prestandan är dock fortfarande inte på en förväntad nivå, vilket kan bero på bias i träningsdata och det sätt på vilket data i Mediator-projektet hade samlats in under mer kontrollerade experimentella miljöer för att besvara olika forskningsfrågor. Metod 3 kan tyckas likna metod 1 men förbättrar den i prestanda där modellen visar bättre prestanda för många forskningspersoner. Detta kan förklaras av det faktum att i varje CV-fold matas ytterligare träningsdata (från Mediator-datasetet) in, vilket gör att den tränade modellen i varje fold kan ha ett större träningsdataset att lära sig av.

Framtida arbete


Datainsamlingsinstrumentationen utvecklas vidare för att fungera fullt ut i de flesta fordon. Autolivs datainsamlingsarbete kommer att fortsätta för att berika datasetet till en tillfredsställande nivå för en planerad kommande vetenskaplig publikation. En lovande riktning för framtida forskning är att potentiellt förbättra algoritmens prestanda med hjälp av dataförstärkning och syntetiska datagenereringstekniker. Bättre tekniker för funktionsanpassning eller modellanpassning kan också förbättra förutsägelseprestanda genom att ta hänsyn till den individuella skillnaden i fysiologisk respons. I samband med förbehandling av data kan fler dataexempel extraheras från resedata med hjälp av glidande tidsfönster för att maximera genererade data per resa och på så sätt öka den totala datamängdsstorleken i viss utsträckning. Det är också värt att utforska djupinlärningsbaserade metoder där modellen är förtränad på stora HRV-data på ett oövervakat sätt före den slutliga övervakade träningen eller finjusteringen. Slutligen kan sensorfusionsbaserade metoder utforskas där HRV-data kombineras med andningsdata från förare för att berika data och ge ML-modellen mer gynnsamma förutsättningar.

6.2 Delprojekt 2 *Bedöma mental belastning hos yrkesförare i simulator*

Fyrtionio personer (33 män och 16 kvinnor) deltog i studien. Medelåldern var 43 år (spänn 25 till 64 år). De hade i genomsnitt arbetat 10 år som uttryckningspersonal, med en variation från mindre än ett år till 39 år.

Subjektiva skattningar


Upplevd stress (VSS) och samtliga delskalor av NASA-TLX var signifikant högre för uppgift C jämfört med uppgift A och B (Figur 1). Uppgift B hade signifikant högre poäng än uppgift A när det gäller upplevd stress, mentala, fysiska och temporala krav, ansträngning och frustration (Figur 1). Det fanns ingen signifikant skillnad i sömnhet mellan uppgifterna (Figur 1). De genomsnittliga VSS-skattningarna var A=3,17 (SD 1,58, intervall 1–7), B=3,77 (SD 1,59, intervall 1-6) och C=4,65 (SD 1,77, intervall 1–7).



Figur 13: Subjektiva skattningar från de tre köruppgifterna.

HRV


Medelvärden för NN-intervall var signifikant kortare i uppgift C jämfört med uppgift A och B (Figur 14). Medelvärdet för VLF HRV var signifikant högre i uppgift C jämfört med uppgift A och B (Figur 14). Det var inga andra signifikanta skillnader i HRV-parametrar mellan köruppgifterna.



Figur 14: HRV från de tre köruppgifterna.

Respons på specifika event

I uppgift C fanns en specifik händelse - en bil som plötsligt backade ut framför ambulansen. Hjärtfrekvensförändringar kring eventet i scenario C undersöktes. En ökning av hjärtfrekvensen




Figur 15: Hjärtfrekvens före och efter eventet i köruppgift C (vid tidpunkt 0) från två olika forskningspersoner.

efter händelsen kunde ses hos vissa deltagare (Figur 15, exempel till vänster) men vi kunde inte se en sådan ökning hos alla förare (Figur 15, exempel till höger). På grupp nivå var den genomsnittliga hjärtfrekvensen 20 sekunder före händelsen 82,5 slag per minut (SD 0,6) och den var 82,0 slag per minut (SD 0,8) efter händelsen, med en genomsnittlig förändring på -0,5 slag per minut (SD 1,0).

Körförmåga

Det fanns signifikanta skillnader mellan köruppgifterna för antalet kraftiga inbromsningar ($F=30,7$, $p<0,001$, $\eta^2=0,411$) och fordonsskador ($F=12,6$, $p<0,001$, $\eta^2=0,218$), som visas i Figur 16. Antalet händelser med fordonsskador var signifikant högre i det stressigaste scenariot (uppgift C) jämfört med uppgift A och B ($p<0,001$). Alla parvisa jämförelser mellan uppgifter var signifikanta (alla $p<0,001$) vid analys av antalet kraftiga inbromsningar.



Figur 16: Körförmåga mätt som genomsnittligt antal incidenter per uppgift.

Jämförelse av körförmåga mellan stressade och icke-stressade förare med Mann-Whitney U-test visade signifikant fler fordonsskador ($U=2609$, $p<0,001$) och kraftiga inbromsningar ($U=2375$, $p=0,009$) hos stressade individer. När uppgift A, B och C analyserades separat, sågs inga signifikanta skillnader i uppgift A, stressade individer hade signifikant färre kraftiga

inbromsningar i uppgift B ($U=98$, $p=0,018$), och stressade förare hade signifikant fler händelser med fordonsskador i uppgift C ($U=376$, $p=0,011$).

Utöver ovanstående resultat så har också ny kunskap om hur hjärtfrekvensvariabilitet påverkas av faktorer som tid på dagen och hur länge körningen har pågått har utarbetats och presenterats på DDI2022 – Conference on Driver Distraction and Inattention (<https://ddi2022.org/>). På samma konferens presenterade vi en studie där vi jämför noggrannheten för Polar H10 heart rate sensor med ett referenssystem (EKG).

6.3 Delprojekt 3 Detektion av hjärtfrekvens / plötslig sjukdom i labb


Resultat Raytelligence experiment

Experimenten med Autolivs experimentbil i Vårgårda gav vid handen att direkt mätning av hjärtfrekvens med hjälp av radar i bilen inte är möjlig utan att kunna mäta och modellera de vibrationer som bilen inducerar.


Av den anledning lades tyngdpunkten av arbetet i delprojektet på att med en 60 GHz radar sensor baserad på RADSENZ mäta vibrationer upp till 2000 Hz. Resultatet av studien visar att detta kan göras och är ett nödvändigt steg på vägen mot att kunna mäta vitalparametrar i en bil under färd.

Efter Raytelligence vidareutveckling av sensorn som möjliggör mätning av vibrationer med mycket små displacement upp till frekvensen 2000 Hz. Det visade sig dessutom möjligt att göra dessa mätningar genom väggar. Detta öppnar för stor flexibilitet vad gäller placering av sensorn i bilen (t.ex. bakom instrumentbrädan).

Vi kan konstatera att sensorn mycket väl kan detektera dessa vibrationer som kan återfinnas i kupén av en bil. I Figur 17 visas frekvensspekret hos vibrationerna, och i Figur 18 demonstreras att frekvensspektrumet också kan mätas väl genom en vägg. Av sekretessskäl kan inte signalbehandlingen närmare visas.



Figur 17: Mätning av vibrationer med radarsensorn RADSENZ



Figur 18: Mätning av vibrationerna med en vägg mellan det vibrerande objektet och sensorn.

Resultat Chalmers experiment


Resultat från den första studien (mätningen av hjärtfrekvens)

Tabell 8 visar medelvärde och median av noggrannheten för 12 mätningar där radarsensorn var positionerad bakom försöksperson. Medelvärdet av samtliga beräknade medelvärden av noggrannheten är 91,0 %, och medelvärdet av samtliga beräknade medianer av noggrannheten är 94,0 %. Noggrannheten för samtliga mätningar utom en är högre än 89 %, och det är inte någon större skillnad i noggrannheten mellan mätningarna med normal puls och de med hög puls.

Tabell 8: Noggrannheten för mätningar där radarsensor var bakom försöksperson.

Mätning	Medelvärde(%)	Median (%)
A7-A9	94,18	96,29
B7-B9	88,56	91,34
C7-C9	93,30	95,83
D7-D9	88,36	89,98
E7-E9	91,42	93,94
F7-F9	94,78	96,67
Medelvärde:	91,77	94,01


I Figur 19 visas hjärtfrekvenserna från radarn och från EKG för två mätningar med hög noggrannhet. Det visades att hjärtfrekvensen som fås från radarn och hjärtfrekvensen som erhålls från EKG följer varandra väl.



Figur 19: Hjärtfrekvenser erhålls från radarn och från EKG, med god överensstämmelse.


Resultat från den andra studien (mätningen av intervall mellan hjärtats slag)

Tabell 1 visade medelvärde och median av noggrannheten för sex olika försökspersoner. Radarsensorn var positionerad bakom försöksperson och tre mätningar utfördes på varje person. Det totala medelvärdet av noggrannheten uppgår till 91,77% och medelvärdet av medianen uppgår till 94,01%.



Figur 20: Detekterade toppar (vänster) och interbeatintervall (IBI) mellan radar och EKG (höger).

De två mätningar med högst medelvärde för den aktuella mätserien presenteras i Figur 20 och 21. Bild till vänster visar detekterade toppar jämfört med EKG R-vågor och bild till höger presenterar jämförelsen av interbeatintervall (IBI) mellan radar och EKG. Resultaten visade också att det är möjligt att detektera hjärtfrekvens när försökspersonerna har jacka på sig men att jackans material kan spela roll.



Figur 21: Ytterligare exempel på detekterade toppar (vänster) och interbeatintervall (IBI) mellan radar och EKG (höger).

7 Spridning och publicering

7.1 Kunskaps- och resultatspridning

Hur har/planeras projektresultatet att användas och spridas?	Markera med X	Kommentar
Öka kunskapen inom området	X	
Föras vidare till andra avancerade tekniska utvecklingsprojekt	X	
Föras vidare till produktutvecklingsprojekt	X	
Introduceras på marknaden		
Användas i utredningar/regelverk/tillståndsärenden/ politiska beslut		

Projekt COPE Driver och kunskapsbyggandet och nätverket projektet har byggt har lett till vidare projekt och ytterligare projekt har definierats för vilka nu finansiering söks. Exempel på pågående projekt är Syncope som är ett samarbete mellan Chalmers och VTI och fortsätter att undersöka möjligheterna att detektera plötslig sjukdom utifrån mätningar av EKG / puls. Autoliv fortsätter datainsamling för detektion av sömnhet och en kommande vetenskaplig publikation planeras. Utvecklingen av plattformen för datainsamling som gjordes i COPE Driver kan också utnyttjas i andra studier. Vidare arbetar parterna bakom TEAPaN mot en fortsättning i TEAPaN 2 som ska leda närmare skarp implementering av nya tjänster för att förebygga och hantera trafikolyckor (se film om TEAPaN projektet här: <https://vimeo.com/797279963>).

7.2 Publikationer

Nedan listas publikationer som har publicerats eller är inskickade för granskning. Utöver dessa planeras fler vetenskapliga publikationer att genomföras av parterna framöver då det bedöms att flertalet resultat av projektet har ett vetenskapligt nyhetsvärde.

- K. Lu, J. Karlsson, A. Sjörs Dahlman, B. A. Sjöqvist, and S. Candefjord, "Detecting Driver Sleepiness Using Consumer Wearable Devices in Manual and Partial Automated Real-Road Driving," *IEEE Trans. Intell. Transport. Syst.*, pp. 1–10, 2021, doi: [10.1109/TITS.2021.3127944](https://doi.org/10.1109/TITS.2021.3127944)
- K. Lu, A. Sjörs Dahlman, J. Karlsson, and S. Candefjord, "Detecting driver fatigue using heart rate variability: A systematic review," *Accident Analysis & Prevention*, vol. 178, p. 106830, Dec. 2022, doi: [10.1016/j.aap.2022.106830](https://doi.org/10.1016/j.aap.2022.106830)
- A. Sjörs Dahlman, K. Lu, J. Karlsson, B.-A. Sjöqvist, and S. Candefjord, "Field evaluation of using Polar H10 sensor to measure heart rate variability for driver state monitoring," in *19th International Conference Road Safety on Five Continents (RS5C). Grapevine, Texas, USA. Held October 10–12, 2022*, Statens väg-och transportforskningsinstitut, 2022, pp. 74–76. Available: <https://www.diva-portal.org/smash/record.jsf?pid=diva2:1709216>. [Accessed: Feb. 15, 2024]
- Xuezhi Zeng, Ke Lu, Stefan Candefjord, Andreas Fhager, Bengt-Arne Sjöqvist, "Towards continuous in-home health monitoring using radar", Medicinteknikdagarna 2022, Luleå, Sverige
- K. Lu, A. Sjörs Dahlman, J. Karlsson, B.-A. Sjöqvist, and S. Candefjord, "Heart rate variability as an indicator for driver fatigue, different effects of time of day and time-on-task," in The 8th international conference on driver distraction and inattention. Lindholmen Conference Centre &



online October 19–20, 2022, Safer, 2022, pp. 98–100. Available: <https://www.diva-portal.org/smash/record.jsf?pid=diva2:1725774> [Accessed: Feb. 16, 2024]

- A. Sjörs Dahlman, K. Karlsson, S. Candefjord, and A. Anund, "Validation of a one-item acute stress scale for driving tasks," submitted to AHFE 2024, 15th International Conference on Applied Human Factors and Ergonomics (AHFE 2024) and the Affiliated Conferences 2024, 2024.

8 Slutsatser och fortsatt forskning

I tre olika delprojekt har projekt COPE DrivER undersökt och utvecklat möjligheterna att uppskatta förartillstånden sömnhet och stressnivå hos förare genom att mäta fysiologiska signaler från hjärtaktivitet. Generellt har försöken visat att det finns potential för de testade teknologierna att bidra till att uppskatta dessa förartillstånd, men visar också att det är utmanande att med hög noggrannhet lyckas detektera tillstånden utifrån endast mätningar av hjärtaktivitet, det behövs troligen kompletterande data från andra sensorer. Förutsättningar för att mäta på förare är svåra p.g.a. vibrationer, förarens rörelser samt tjocka kläder.

I delprojekt 1 har vi undersökt förmågan att genom en maskininlärningsmodell uppskatta sömnhet. I allmänhet kan vi dra slutsatsen att en liten storlek på datasetet begränsar prestandan. Det har också observerats i litteraturen att det kan vara svårt att förutsäga subjektiva mått på sömnhet som KSS enbart baserat på fysiologiska data om inte ytterligare kontextuell eller metadata också förstärker informationsmängden. Dessutom kan fysiologiska parametrar variera mycket mellan de enskilda förarna, tid på dygnet och många andra faktorer, vilket gör detta till ett utmanande problem. Det är också noterbart att Mediator-datasetet kan uppvisa mönster som härstammar från den kontrollerade experimentdesignen och gör den inte ideal för som träningsdata för en modell som predikterar sömnhet under naturalistisk körning. DrivER-dataset å andra sidan samlas in under mer fria former till följd av färre begränsningar för den experimentella designen, men det gör också data mer komplex.

I delprojekt 2 noterade vi att HR (mean NN) verkar vara den fysiologiska parameter som bäst avspeglar stressnivå. Att analysera genomsnittlig HRV verkar inte vara effektivt för att mäta stress, även om det inte kan uteslutas att det kan korrelera vid högre stressnivåer än de som uppmättes i vår studie.

Det var stora skillnader mellan olika individers fysiologiska stressresponser och dessa skillnader mellan individer var större än skillnaderna mellan köruppgifter. Det är därför viktigt för fortsatta studier på stressresponser hos förare att ta hänsyn till individuella skillnader och använda analysmetoder som tar detta i beaktande. Stresskattningarna var måttliga under testerna och det fanns inga skattningar över 7 på den 9-gradiga skalan. Detta kan bero på att simulatorscenerna inte upplevdes lika stressande som verkliga nödsituationer under körning. Användningen av simulatorer möjliggjorde hög kontroll över scenarierna mellan deltagarna. Det är dock svårt att uppnå samma känsla av upplevd stress som i verkliga nödsituationer när man kör i en simulator.

Körförmåga mätt som antalet incidenter med fordonsskador och kraftiga inbromsningar skiljde sig åt mellan köruppgifterna. Det berodde troligtvis inte bara på uppgifternas stressnivå, utan också på de olika trafikmiljöerna och händelser som ingick i scenarierna. Det är därför svårt att dra slutsatser om stressade förare har sämre körförmåga än icke-stressade förare här.

I delprojekt 3 har vi visat att det är nödvändigt att modellera de vibrationer som återfinns i kupén på en bil för att med tillfredställande kvalitet detektera hjärtfrekvens på föraren. Ett första steg är att med radarsensorn mäta de vibrationer som förekommer. Detta har genomförts och det visar sig att sensorn RADSENZ kan med stor noggrannhet mäta dessa vibrationer.



Fortsatt forskning krävs för att införa detta i en bilkupé och verifiera att vibrationerna kan filtreras bort så mätsignalen från objektet (föraren) kan identifieras.

Det går att mäta hjärtfrekvenser i ett brett frekvensintervall och intervallen mellan hjärtats slag med radarteknik, vilket tyder på att det finns god potential att detektera arytmi. Vi har utvecklat metoderna som kan ge hög noggrannhet under stationära förhållanden. Dock återstår det flera utmaningar med signalbehandlingen innan radarn kan implementeras i ett fordon. Bland annat är det nödvändigt att utveckla metoden vidare så att det blir mer robust och kan mäta under en längre period. Fler och längre mätningar behöver genomföras i framtiden på fler friska personer men även på patienter med arytmi i en klinisk studie för att få bättre och mer trovärdiga resultat.

9 Deltagande parter och kontaktpersoner

Part / Koordinator: Chalmers

Kontaktperson: Stefan Candefjord, Docent, stefan.candefjord@chalmers.se

Part: Raytelligence AB,

Kontaktperson: Pelle Viberg, VD, pelle.viberg@raytelligence.com

Part: Autoliv Development AB

Kontaktperson: Da Wang, Research Engineer, da.wang@autoliv.com

Part: VTI

Kontaktperson: Anna Sjörs Dahlman, Senior forskare, anna.dahlman@vti.se

Part: Västra Götalandsregionen

Kontaktperson: Jonas Åsberg, jonas.asberg@vgregion.se

10 Referenser

- [1] D. Hallvig, A. Anund, C. Fors, G. Kecklund, and T. Åkerstedt, "Real driving at night – Predicting lane departures from physiological and subjective sleepiness," *Biological Psychology*, vol. 101, pp. 18–23, Sep. 2014, doi: 10.1016/j.biopsycho.2014.07.001
- [2] D. Zwahlen, C. Jackowski, and M. Pfäffli, "Sleepiness, driving, and motor vehicle accidents: A questionnaire-based survey," *Journal of Forensic and Legal Medicine*, vol. 44, pp. 183–187, Nov. 2016, doi: 10.1016/j.jflm.2016.10.014
- [3] A. Chowdhury, R. Shankaran, M. Kavakli, and Md. M. Haque, "Sensor Applications and Physiological Features in Drivers' Drowsiness Detection: A Review," *IEEE Sensors J.*, vol. 18, no. 8, pp. 3055–3067, Apr. 2018, doi: 10.1109/JSEN.2018.2807245
- [4] K. Lu, J. Karlsson, A. Sjörs Dahlman, B. A. Sjöqvist, and S. Candefjord, "Detecting Driver Sleepiness Using Consumer Wearable Devices in Manual and Partial Automated Real-Road Driving," *IEEE Trans. Intell. Transport. Syst.*, pp. 1–10, 2021, doi: 10.1109/TITS.2021.3127944
- [5] K. Lu, A. Sjörs Dahlman, J. Karlsson, and S. Candefjord, "Detecting driver fatigue using heart rate variability: A systematic review," *Accident Analysis & Prevention*, vol. 178, p. 106830, Dec. 2022, doi: 10.1016/j.aap.2022.106830
- [6] A. Sahayadhas, K. Sundaraj, and M. Murugappan, "Detecting Driver Drowsiness Based on Sensors: A Review," *Sensors*, vol. 12, no. 12, pp. 16937–16953, Dec. 2012.
- [7] M. Patel, S. K. L. Lal, D. Kavanagh, and P. Rossiter, "Applying neural network analysis on heart rate variability data to assess driver fatigue," *Expert Systems with Applications*, vol. 38, no. 6, pp. 7235–7242, Jun. 2011.

- [8] A. Persson, H. Jonasson, I. Fredriksson, U. Wiklund, and C. Ahlstrom, "Heart Rate Variability for Classification of Alert Versus Sleep Deprived Drivers in Real Road Driving Conditions," *IEEE Transactions on Intelligent Transportation Systems*, pp. 1–10, 2020, doi: 10.1109/TITS.2020.2981941
- [9] R. Buendia, F. Forcolin, J. Karlsson, B. Arne Sjöqvist, A. Anund, and S. Candefjord, "Deriving heart rate variability indices from cardiac monitoring—An indicator of driver sleepiness," *Traffic Injury Prevention*, vol. 20, no. 3, pp. 249–254, Mar. 2019, doi: 10.1080/15389588.2018.1548766
- [10] M. N. Rastgoo, B. Nakisa, A. Rakotonirainy, V. Chandran, and D. Tjondronegoro, "A Critical Review of Proactive Detection of Driver Stress Levels Based on Multimodal Measurements," *ACM Comput. Surv.*, vol. 51, no. 5, pp. 1–35, Sep. 2019, doi: 10.1145/3186585
- [11] V. Beanland, M. Fitzharris, K. L. Young, and M. G. Lenné, "Driver inattention and driver distraction in serious casualty crashes: Data from the Australian National Crash In-depth Study," *Accident Analysis & Prevention*, vol. 54, pp. 99–107, May 2013, doi: 10.1016/j.aap.2012.12.043
- [12] H. Wiberg, E. Nilsson, P. Lindén, B. Svanberg, and L. Poom, "Physiological responses related to moderate mental load during car driving in field conditions," *Biological psychology*, vol. 108, pp. 115–125, 2015.
- [13] J. A. Healey and R. W. Picard, "Detecting stress during real-world driving tasks using physiological sensors," *IEEE Transactions on intelligent transportation systems*, vol. 6, no. 2, pp. 156–166, 2005.
- [14] C. D. Katsis, N. Katertsidis, G. Ganiatsas, and D. I. Fotiadis, "Toward emotion recognition in car-racing drivers: A biosignal processing approach," *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, vol. 38, no. 3, pp. 502–512, 2008.
- [15] G. Rigas, Y. Goletsis, P. Bougia, and D. I. Fotiadis, "Towards driver's state recognition on real driving conditions," *International Journal of Vehicular Technology*, vol. 2011, 2011, Available: <https://downloads.hindawi.com/archive/2011/617210.pdf>. [Accessed: Jan. 31, 2024]
- [16] L. T. Lam and M. K. Lam, "The association between sudden illness and motor vehicle crash mortality and injury among older drivers in NSW, Australia," *Accident Analysis & Prevention*, vol. 37, no. 3, pp. 563–567, 2005.
- [17] T. M. T. Tervo, W. Neira, A. Kivioja, P. Sulander, K. Parkkari, and J. M. Holopainen, "Observational Failures/Distracton and Disease Attack/Incapacity as Cause(s) of Fatal Road Crashes in Finland," *Traffic Injury Prevention*, vol. 9, no. 3, pp. 211–216, May 2008, doi: 10.1080/15389580802040303
- [18] C. Ahlström, R. Zembyls, H. Jansson, C. Forsberg, J. Karlsson, and A. Anund, "Effects of partially automated driving on the development of driver sleepiness," *Accident Analysis & Prevention*, vol. 153, p. 106058, Apr. 2021, doi: 10.1016/j.aap.2021.106058
- [19] M. Malik, "Geometrical methods for heart rate variability assessment," *Heart rate variability*, 1995, Available: <https://cir.nii.ac.jp/crid/1571135650522663936>. [Accessed: Jan. 31, 2024]
- [20] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785. Available: <http://arxiv.org/abs/1603.02754>. [Accessed: Feb. 05, 2024]
- [21] T. Chen and C. Guestrin, "dmlc/xgboost." Distributed (Deep) Machine Learning Community, Feb. 07, 2024. Available: <https://github.com/dmlc/xgboost>. [Accessed: Feb. 07, 2024]
- [22] G. D. Clifford, P. E. McSharry, and L. Tarassenko, "Characterizing artefact in the normal human 24-hour RR time series to aid identification and artificial replication of circadian variations in human beat to beat heart rate using a simple threshold," in *Computers in cardiology*, IEEE, 2002, pp. 129–132. Available: <https://ieeexplore.ieee.org/abstract/document/1166724/>. [Accessed: Feb. 16, 2024]
- [23] A. L. Goldberger *et al.*, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals," *Circulation*, vol. 101, no. 23, Jun. 2000, doi: 10.1161/01.CIR.101.23.e215. Available: <https://www.ahajournals.org/doi/10.1161/01.CIR.101.23.e215>. [Accessed: Feb. 16, 2024]
- [24] A. N. Vest *et al.*, "An open source benchmarked toolbox for cardiovascular waveform and interval analysis," *Physiol. Meas.*, vol. 39, no. 10, p. 105004, Oct. 2018, doi: 10.1088/1361-6579/aae021
- [25] F. Shaffer and J. P. Ginsberg, "An Overview of Heart Rate Variability Metrics and Norms," *Front. Public Health*, vol. 5, p. 258, Sep. 2017, doi: 10.3389/fpubh.2017.00258