Gerhard-Lustig-Preis

Christina Ohm, Regensburg

Bitte nicht stören – Zur Vorhersage des Workloads von Autofahrern unter Verwendung von Smartphone-Sensordaten

DOI 10.1515/iwp-2015-0039

Immer häufiger werden Informationssysteme beim Fahren eingesetzt. Diese dienen dazu dem Fahrer zu assistieren, können jedoch auch eine Quelle kognitiver Belastung darstellen. Aus diesem Grund wurde eine Nutzerstudie durchgeführt, die es ermöglichen soll, Fahrerassistenzsysteme anzupassen, sodass die Fahraufgabe optimal bewältigt werden kann. Zu diesem Zweck wurden Smartphone-Sensordaten, situative Faktoren sowie Nutzereigenschaften erhoben und untersucht. Die Ergebnisse der Nutzerstudie zeigen auf, dass die Fahrsituation, das Geschlecht sowie die Fahrhäufigkeit einen signifikanten Einfluss auf den Workload haben. Werden diese Daten zusätzlich zu den Smartphone-Sensordaten verwendet, um den Workload vorherzusagen, kann dieser unter Verwendung eines Entscheidungsbaumes mit bis zu 86 Prozent Genauigkeit vorhergesagt werden.

Deskriptoren: Workload Vorhersage, Fahrerassistenzsysteme, Klassifikation, Empirische Untersuchung, Sensor

Estimating the Driver's Workload. Using Smartphone Data to Adapt In-Vehicle Information Systems

The use of in-vehicle information systems has increased in the past years. These systems assist the user but can as well cause additional cognitive load. The study presented in this paper was carried out to enable workload estimation in order to adapt information and entertainment systems so that an optimal driver performance and user experience is ensured. For this purpose smartphone sensor data, situational factors and basic user characteristics are taken into account. The study revealed that the driving situation, the gender of the user and the frequency of driving significantly influence the user's workload. Using only this information and smartphone sensor data the current workload of the driver can be estimated with 86% accuracy.

Descriptors: Workload Estimation, In-vehicle information systems, Classification, Empirical Study, Sensor

Prière de ne pas déranger – les prévisions de la charge de travail des automobilistes en utilisant les données des capteurs de smartphones

Les systèmes d'information sont utilisés de plus en plus fréquemment pendant la conduite de voitures. Ceux-ci servent à aider l'automobiliste, mais peuvent aussi être une source de charge cognitive. Pour cette raison, une étude a été menée, qui devrait permettre d'adapter les systèmes d'assistance au conducteur de sorte que la tâche de conduite puisse être gérée de façon optimale. A cette fin, des données des capteurs de smartphones, des facteurs situationnels et des caractéristiques de l'utilisateur ont été recueillies et testés. Les résultats de l'étude montrent que la situation de conduite, le sexe et la fréquence de conduite ont un impact significatif sur la charge de travail. Si ces données sont utilisées en plus des données des capteurs de smartphones afin de prévoir la charge de travail, celle-ci peut être prédite, en utilisant un arbre de décision, avec un taux de précision qui peut monter jusqu'à 86 pour cent.

Descripteurs: prévision de charge de travail, système d'assistance de conduite, classification, étude empirique, capteur

Motivation

Fahrerassistenzsysteme, wie beispielsweise das Navigationssystem, das Radio oder eine Freisprechanlage unterstützen oder unterhalten den Fahrer bei seiner Fahraufgabe. Jedoch können diese Informationssysteme auch ablenkend wirken oder eine kognitive Belastung darstellen. Folglich wäre es von großem Vorteil die momentane kognitive Belastung des Fahrers zu kennen, um gefährliche Situationen zu vermeiden und den Fahrer während

seiner primären Aufgabe – dem eigentlichen Fahren – nicht unnötig zu belasten. Ist der momentane kognitive Zustand nicht optimal, könnte beispielsweise ein eingehender Anruf oder die Sprachausgabe des Navigationssystems für einige Sekunden blockiert werden, sodass die Konzentration des Fahrers nicht von der Fahraufgabe abgelenkt wird. Insgesamt ist eine Interaktion mit einem Informationssystem für den Fahrer während der Fahrt eine große Herausforderung, da er oder sie sich auf die primäre Fahraufgabe konzentrieren muss. Diese beinhaltet alle Aktionen die die Handhabung des Fahrzeugs erfordern, wie beispielsweise das Lenken oder Schalten (siehe Michon, 1986).

Die hier dargestellte Studie untersucht, welche Faktoren einen signifikanten Einfluss auf den Workload des Fahrer während der primären Fahraufgabe haben. Des Weiteren werden diese Faktoren sowie gesammelte Smartphone-Sensordaten dazu verwendet, den kognitiven Zustand des Fahrers vorherzusagen. Hierzu werden unterschiedliche Data Mining Techniken herangezogen.

Bevor die Studie und deren Ergebnisse dargestellt werden, wird zunächst das Konzept des Workloads eingeführt. Schließlich werden die Ergebnisse zusammengefasst.

Workload

Grundsätzlich kann Workload definiert werden, als eine Belastung, die auf dem Menschen lastet (de Waard, 1996). Jedoch umfasst diese aufgabenorientierte Definition nicht alle Aspekte des Workload-Konzepts. So werden beispielsweise keine nutzerzentrierten Faktoren, wie die kognitiven Fähigkeiten oder das Vorwissen beachtet. Aus diesem Grund hat nicht nur de Waard selbst, sondern auch andere Kollegen die Definition erweitert. Zusammengefasst lautet diese wie folgt (siehe z. B.: Cain, 2007, deWaard, 1996, Hart & Staveland, 1988): Eine Person muss eine Aufgabe in einer spezifischen Situation meistern. Dies erfordert kognitive informationsverarbeitende Fähigkeiten. Folglich verursacht die Aufgabe eine kognitive Belastung. Workload ist somit die geforderte Fähigkeit die Aufgabe zufriedenstellend zu erfüllen. Während der Situation erlebt die Person eine subjektive Erfahrung, die aus den situativen Umständen (z. B.: Verkehrsaufkommen), seinen Eigenschaften (z. B.: Alter) sowie den Anforderungen der jeweiligen Situation resultieren.

Workload kann zudem in verschiedene Zustände unterteilt werden. Oron-Gilad et al., 2008 unterscheiden hierzu drei mögliche Stadien, die aus dem Verhältnis von

Fahrerfähigkeiten und den situativen Umständen resultieren:

- „Overload“: Die Anforderungen der Aufgabe übersteigen das Können des Fahrers.
- Optimaler Zustand: Die Faktoren befinden sich im Gleichgewicht. Der Fahrer kann seine Aufgabe problemlos meistern.
- „Underload“: Die Fähigkeiten des Fahrers übertreffen die Anforderungen der Situation.

Insbesondere ist anzumerken, dass auch der „Underload“-Zustand zu vermeiden ist. Er kann als Gefühl der Langeweile oder Ablenkung gesehen werden. De Waard, 1996 unternimmt eine detailliertere Klassifikation. Er fügt einen weiteren Zustand des „Overloads“ hinzu. Dieser kann als eine Situation verstanden werden, in der der Fahrer die Kontrolle verliert. Da dieser Zustand unweigerlich zu einem Unfall führt, konnte er in der hier vorgestellten Studie nicht gemessen werden. Zudem teilt de Waard den optimalen Zustand in drei Teile. Er argumentiert, dass es nötig ist, zu wissen, ob der Fahrer sich an der Schwelle zum „Overload“ oder „Underload“ befindet.

Um eine Vorhersage des Workloads zu ermöglichen, muss dieser zunächst gemessen werden. Hierzu existiert eine Vielzahl von verfügbaren Methoden, von der Nutzung von Fragebögen bis hin zum Einsatz von Biosensoren (siehe für eine Übersicht: de Waard, 1996). In der im Folgenden vorgestellten Studie wurde eine adaptierte Variante des Rating Scale Mental Effort (RSME) (siehe Zijstra & Van Doorn, 1985) verwendet. Diese Messmethode sieht vor, dass Testpersonen angeben, wie hoch der Aufwand war, die Aufgabe zu erfüllen. Hierzu sind einer Skala einige Ausdrücke wie „sehr viel Aufwand“ zugeordnet, die die Ausprägung verdeutlichen sollen.

Darüber hinaus wurde ein multidimensionales Messinstrument herangezogen: Der NASA Task Load Index (NASA-TLX), der als die am weitesten verbreitete Selbstauskunftsmethode zur Messung des Workloads gilt (siehe Cain, 2007). Dieser enthält Fragen, die die Ausprägung diverser Anforderung misst, darunter beispielsweise die mentale Belastung oder der aktuelle Frustrationslevel (siehe Hart & Staveland, 1988).

Studie

Aufbauend auf einer Literaturrecherche (siehe z. B.: Schweitzer & Green, 2007; Oron-Gilad et al., 2008) wurden der situative Faktor „Straßentyp“, sowie die Nutzeigenschaften „Geschlecht“ und „Fahrfähigkeit“ als po-

tenzielle unabhängige Variablen identifiziert, die einen signifikanten Einfluss auf den Workload des Fahrers ausüben können. Demnach wurden die folgenden Hypothesen aufgestellt und im Rahmen einer Nutzerstudie geprüft:

- H_1 : Der Workload unterscheidet sich für die Fahr-situationen „Autobahn“, „Landstraße“ und „Stadtverkehr“.
- H_2 : Frauen und Männer erleben unterschiedlichen Workload beim Fahren.
- H_3 : Der Workload unterscheidet sich für Personen mit unterschiedlicher Fahrhäufigkeit.

Zusätzlich zu diesen Daten wurden Smartphone-Sensor-daten erhoben, um eine Vorhersage des Workloads zu ermöglichen. Nachfolgend sind der Aufbau sowie die Ergebnisse der Studie beschrieben.

Testpersonen und Testroute

An der Studie nahmen acht weibliche und zwölf männliche Testpersonen teil. Ihr durchschnittliches Alter betrug 24,9 Jahre ($SD = 2,1$). Im Schnitt hatten sie eine Fahr-erfahrung von 6,9 Jahren ($SD = 2,4$). Daraus folgt, dass

die gesamte Testgruppe aus sehr jungen, jedoch nicht völlig unerfahrenen Personen bestand. Die Testroute beinhaltete drei Teile („Autobahn“, „Landstraße“ und „Stadtverkehr“), die aus Hypothese H_1 folgen. Jeder Routenabschnitt konnte in etwa 15 Minuten absolviert werden und war fünf bis zwölf Kilometer lang.

Messinstrumente

Nach jedem Streckenabschnitt wurde der Workload-Level der Testperson mit einer Smartphone-basierten Repräsentation des NASA-TLX gemessen (siehe Abbildung 1, mittig und rechts). Zusätzlich wurde eine vereinfachte Version des RSME auf dem Smartphone implementiert (siehe Abbildung 1, links). Dieser sollte ermöglichen, dass die Testpersonen ihren aktuellen Workload-Level auch während des Fahrens angeben konnten. Hierzu wurde das Smartphone an der Frontscheibe angebracht. Die Teilnehmer wurden dazu angehalten ihren Workload-Level bei jeder Veränderung mit Hilfe der Applikation anzugeben. Um das Design des angepassten RSME so einfach wie möglich zu gestalten, wurde im Vorfeld eine Usability-Studie durchgeführt, bei der zehn Testpersonen vier unterschiedliche potenzielle Oberflächen bewerten mussten.

Abbildung 1: Screenshot der Android-Applikation, die zur Messung des Workloads herangezogen wurde: RSME (links) und NASA-TLX (mittig und rechts).

Tabelle 1: Vorhersagegenauigkeit des Workloads in Prozent für unterschiedliche Klassifikationsalgorithmen und Unterteilungen.

	Entscheidungsbaum (C4.5)	Sequential Minimal Optimization (SMO)	AdaBoost	Naive Bayes	Neuronales Netz
3 Zustände	85,70	63,30	62,30	63,92	70,51
5 Zustände	72,92	46,27	46,13	46,13	54,81

Des Weiteren wurden dem aktuellen Workload-Level, der durch den RSME erhoben wurde, die zu diesem Zeitpunkt gemessenen Smartphone-Sensordaten zugeordnet. Hierfür wurden die aktuelle Geschwindigkeit sowie die Quer- und Längsbeschleunigung verwendet. Eine Vorstudie ergab hoch signifikante Korrelationen mit den äquivalenten Fahrzeugsensordaten. Zudem korreliert die Querbeschleunigung hoch signifikant mit dem Lenkwinkel. Somit kann durch diese Daten sowohl „Gas-geben“ als auch eine Lenkbewegung abgebildet werden.

Während der Testfahrten wurden keine zusätzlichen Informationssysteme verwendet, weil die aktuelle Belastung der primären Fahraufgabe gemessen werden sollte.

Ergebnisse

Die zuvor aufgestellten Hypothesen wurden mit den Ergebnissen des NASA-TLX geprüft. Zunächst wurde jedoch für alle Datensätze die Normalverteilungsannahme mit Hilfe des Kolmogorov-Smirnov-Tests ($p < 0,05$) und einer Analyse der Histogramme bestätigt.

Die Nullhypothese zu H_1 konnte aufgrund der Ergebnisse einer ANOVA mit Messwiederholung verworfen werden ($p = 0,009$). Ein Post-Hoc-Test nach Bonferroni zeigte auf, dass der Workload für die Fahrsituation „Autobahn“ ($p = 0,039$) und „Stadt“ ($p = 0,013$) höher ist als während dem Fahren auf der Landstraße.

Weiterhin konnten auch die Nullhypothese zu H_2 und H_3 verworfen werden ($p = 0,024$ und $p = 0,037$). Hierzu wurde ein t-Test herangezogen. Es zeigt sich, dass Frauen höheren Workload beim Fahren empfinden als Männer. Des Weiteren erleben Personen, die selten fahren, mehr Workload als jene, die angeben regelmäßig im Straßenverkehr involviert zu sein.

Ausgehend von der Beobachtung, dass diese drei Variablen einen signifikanten Einfluss auf den Workload beim Fahren haben, wurden diese zusätzlich zu den Smartphone-Sensordaten für die Vorhersage des Workloads herangezogen. Die Werte des RSME wurden hierfür in drei Zustände nach Oron-Gilad et al., 2008 und weitere fünf nach de Waard, 1996 unterteilt. Zur Vorhersage wurden fünf unterschiedliche Klassifikationsalgorithmen herangezogen. Die Ergebnisse sind Tabelle 1 zu entnehmen.

Die Studie zeigte auf, dass der aktuelle Workload-Level unter Verwendung eines Entscheidungsbaumes mit einer Genauigkeit von ca. 86 Prozent vorhergesagt werden kann, sofern nur drei Zustände unterschieden werden. Hierbei wird eine sehr gute diagnostische Genauigkeit erzielt (ROC-Wert $> 0,9$). Für eine genauere Einteilung in fünf Zustände sinkt die Genauigkeit auf ca. 73 Prozent (ROC-Wert = 0.749).

Fazit

Es gibt eine Vielzahl von Faktoren, die den Workload beim Fahren beeinflussen können. Die aktuelle Fahrsituation kann sich sekundlich ändern und jeder Nutzer weist sehr spezifische Eigenschaften auf.

Jedoch konnte in der hier vorgestellten Studie gezeigt werden, dass es möglich ist den Workload beim Fahren mit einer relativ hohen Genauigkeit vorherzusagen. Unter Berücksichtigung des Geschlechts und der Fahrhäufigkeit der Nutzer sowie der aktuellen Fahrsituation können mit Hilfe eines Entscheidungsbaums bis zu 86 Prozent richtige Vorhersagen getroffen werden. Vergleicht man diesen Wert mit ähnlichen Studien wie beispielsweise der von Zhang et al., 2008, die anhand von Biosensoren eine Genauigkeit von 65 Prozent erzielen, ist ersichtlich, dass die Verwendung von Smartphone-Sensoren vielversprechend ist. Zudem muss hierzu kein teures Equipment im Fahrzeug installiert werden. Werden zusätzlich noch einige Nutzereigenschaften vor der Fahrt erhoben und beispielsweise anhand der Daten des Navigationssystems der aktuelle Routenabschnitt näher bestimmt, ist eine gute Vorhersage der Belastung während der primären Fahraufgabe möglich. Diese Daten können in einem nächsten Schritt dazu verwendet werden, die Ausgabe von Fahrerinformationssystemen während der Fahrt anzupassen, um ein verbessertes Fahrerlebnis zu ermöglichen.

Literatur

Cain, B. (2007). *A Review of the Mental Workload Literature*. Canada, Toronto: Defence Research and Development.

- de Waard, D. (1996). *The Measurement of Drivers' Mental Workload*. Haren, The Netherlands: The Traffic Research Centre, University of Groningen.
- Hart, S., Staveland, L. (1988). *Development of NASA-TLX (Task Load Index): Results of Empirical and Theoretical Research*. In: Hancock, P., Meshkati, N. (Hrsg.). *Human mental workload*. pp. 139–183. Amsterdam: North Holland Publishers.
- Michon, J. (1985). *A critical view of driver behavior models: what do we know, what should we do?* In: Evans, L., Schwing, R. (Hrsg.). *Human behavior and traffic safety*. pp. 485–524. New York: Plenum Press.
- Ohm, Chr. (2013). *Workload und Emotionen beim Fahren – Untersuchung und Vorhersage des Benutzerzustandes in Systemen für proaktive Empfehlungen an den Autofahrer*. Masterarbeit. Universität Regensburg. Lehrstuhl für Informationswissenschaft.
- Oron-Gilad, T., Rone, A., Shinar, D. (2007). *Alertness maintaining tasks (AMTs) while driving*. *Accident Analysis and Prevention*, volume 40, pp. 851–860.
- Schweitzer, J., Green P. E. (2007). *Task acceptability and workload of driving city streets, rural roads, and expressways: Ratings from video clips*. Michigan: University of Michigan.
- Zhang, Y., Owechko, Y., Zhang, J. (2008). *Learning-Based Driver Workload Estimation*. In: Prokhorov, D. (Hrsg.). *Computational Intelligence in Automotive Applications*. SCI132. pp. 1–24. Berlin, Heidelberg: Springer.
- Zijstra, C., Van Doorn, R. (1985). *The construction of a scale to measure perceived effort*. Delft: University of Technology.

M. A. Christina Ohm

Lehrstuhl für Informationswissenschaft
Universität Regensburg
Universitätsstraße 31
93053 Regensburg
christina.ohm@ur.de

Christina Ohm hat an der Universität Regensburg Informationswissenschaft studiert und ihren Masterabschluss 2012 erworben. Seit 2012 ist sie am Lehrstuhl für Informationswissenschaft als wissenschaftliche Mitarbeiterin im Projekt NADINE tätig und forscht zu Fußgängernavigationssystemen.