

# Oma kocht heute nicht? Effektive Warnhinweise im Kontext von Elderly Care

Thomas Paul Kreamsner, Christian Pfeiffer, Forschung Burgenland GmbH

## 1. Hintergrund

In den letzten Jahren ist eine zunehmende Alterung der Gesellschaft zu beobachten, ein Trend, der sich weltweit abzeichnet und voraussichtlich weiter anhalten wird (UN DESA, 2022). Ältere Menschen, insbesondere diejenigen, die alleine leben, sind vermehrt Risiken ausgesetzt. Viele Senioren ziehen es vor, zuhause zu bleiben, statt ins Pflegeheim zu gehen (Narasinghe et al., 2020). Diese Situation stellt Angehörige oft vor Herausforderungen, da sie das Wohlergehen ihrer älteren Verwandten im Auge behalten. Gleichzeitig wünschen sich auch die älteren Personen, dass ihre Betreuungspersonen informiert werden, wenn etwas passiert (Pandey & Litoriya, 2019). Hier kommen technologische Lösungen ins Spiel, die in der Literatur als „Elderly Care“ zusammengefasst werden. Insbesondere fällt die „Human Activity Recognition“ (HAR) in diesen Bereich, die auf die Überwachung des täglichen Verhaltens und des gesundheitlichen Wohlbefindens abzielt. HAR kann Abweichungen im Verhalten erkennen, die auf potenzielle Gefahren – wie Stürze – hindeuten könnten. Ein Beispiel für eine Datengrundlage für HAR sind Smart Meter Daten, die in 10-Sekunden-Intervallen den Stromverbrauch in Haushalten messen können. Durch die Überwachung dieser Daten kann festgestellt werden, ob eine betreuungsbedürftige Person bereits Aktivitäten wie Kochen ausgeführt hat, und somit kann zwischen normalem und abnormalem Verbrauchsverhalten unterschieden werden (Tun et al., 2021; Chalmers et al., 2019). Ein praktisches Beispiel für eine solche Anwendung ist die Beenera App (Beenera, 2023), die bei Erkennung einer Gefahrensituation die Betreuungspersonen über Push-Benachrichtigungen oder Warnmeldungen informiert.

Die Gestaltung effektiver Warnnachrichten ist in der Literatur im Kontext der Elderly Care noch wenig erforscht. Dennoch lassen sich Erkenntnisse aus verwandten Bereichen heranziehen. Bzostek & Wogalter (1999) fanden heraus, dass Warnnachrichten auf Produktverpackungen am besten in roter Schrift mit Icons gestaltet werden sollten, um die Sichtbarkeit und Auffindbarkeit zu maximieren. Im Lebensmittelbereich wird mit Ampelfarben gearbeitet, um anzudeuten, was Konsument\*innen zu gesünderen Entscheidungen anregt (Zhang et al., 2020).

Ziel dieser Arbeit ist es herauszufinden, inwieweit Warnungen in Ampelfarben auch für den Anwendungsfall der Betreuung Älterer geeignet sind, um Betreuungspersonen über mögliche Gefahren zu informieren.

## 2. Forschungsfrage

Der Fokus dieser Arbeit liegt darauf, Betreuungspersonen effektiv zu benachrichtigen, wenn bei betreuungsbedürftigen Personen längere Inaktivitätsphasen festgestellt werden. Dennoch soll es nicht passieren, dass die Personen ohne tatsächliche Gefahrensituation gewarnt werden, um die Effektivität der Warnmeldungen nicht zu mindern (Lees, Lee, 2007).

Dementsprechend wurde folgende Forschungsfrage formuliert:

**Wie sollten Ampel-Warnsysteme von Elderly Care Anwendungen zur effektiven Benachrichtigung von Betreuungspersonen gestaltet werden?**

## 3. Methodik

Von einer Studierendengruppe der FH Burgenland wurde dazu ein Experiment mit 50 Personen durchgeführt. Zuerst mussten die Proband\*innen eine pflegebedürftige Person in ihrem näheren Umfeld definieren. Im Anschluss wurde ihnen ein Prototyp einer möglichen Elderly Care Funktion gezeigt. Insgesamt wurden elf verschiedene Szenarien vorbereitet, in denen die Farbgestaltung basierend auf dem Ampelsystem variierte (grün, gelb und rot). In jedem Szenario wurden mit einem Balkendiagramm unterschiedliche Zeiträume an Inaktivität der zu betreuenden Person in einer stündlichen Auflösung dargestellt. Dazu gab es Hinweise in grün, gelb oder rot, ob die Inaktivität schon länger zurücklag und somit ein Grund zur Sorge besteht, oder ob die Inaktivität erst kürzlich zurücklag und somit kein Handlungsbedarf besteht. Mit diesen Informationen mussten die Proband\*innen nacheinander in fünf zufällig zugeteilten Szenarien entscheiden, wie dringlich sie das Szenario einstufen würden und ob sie nach der pflegebedürftigen Person sehen oder sie anrufen würden, um sich zu vergewissern, dass es ihr gut geht.

Für die Studie wurde eine Kombination aus Eye-Tracking, Gesichtsausdrucksanalyse und Galvanic Skin Response angewendet. Den Proband\*innen wurde ein Fragebogen mit dem Prototypen und den zugehörigen Szenarien auf einem Laptop gezeigt. Während der Untersuchung wurden die Gesichter der Proband\*innen mithilfe einer Webcam gefilmt. Gleichzeitig erfasste ein Eye-Tracker, wohin deren Blicke fielen und wie lange (Bojko, 2013). Hierfür werden die Fixationen (Anzahl der Blickpunkte mit mehr als 300 ms in einem bestimmten Bereich) und Revisits (Häufigkeit, mit der man einen bestimmten Bereich erneut fixiert) als Indikatoren herangezogen. Anschließend wurden die erfassten Daten mit der Software iMotions und dessen Algorithmus Affectiva Affdex ausgewertet. Der Algorithmus unterteilt die Videos der Proband\*innen in 30 Einzelbilder pro Sekunde und berechnet für jedes Bild die Wahrscheinlichkeit für bestimmte Gesichtsausdrücke (positiv, negativ, neutral und zusätzlich sieben Basisemotionen). Wenn ein bestimmter Schwellenwert überschritten wird, zählt das jeweilige Bild als die jeweilige Emotion. Diese Informationen sind wichtig um zu verstehen, ob die Warnmeldungen verständlich waren oder zu Verwirrung führten (iMotions, 2017 a). Mit Hilfe der Galvanic Skin Response (GSR) wurden außerdem Veränderungen der Hautleitfähigkeit gemessen (in

GSR-Peaks), die ebenfalls auf Emotionen hinweisen können. Veränderungen in der elektrischen Leitfähigkeit der Haut weisen darauf hin, dass die präsentierten Inhalte emotionale Reaktionen hervorrufen (iMotions, 2017 b).

#### 4. Ergebnisse

Die Ergebnisse sind unterschiedlich je Szenario, sowohl bei der Analyse der Blickbewegungen, als auch bei der Gesichtsausdrucksanalyse.

Die Blickbewegungsdaten zeigen, dass Proband\*innen die Warnsignale in roter Farbe einfach interpretieren konnten. Grüne und gelbe Farben führten zu mehr Entscheidungsschwierigkeiten, da die Proband\*innen nicht wussten, ob eine Gefahrensituation besteht oder nicht. Die Blickbewegungen zeigen, dass diese Szenarien länger angesehen wurden ( $MW_{\text{grün}} = 37 \text{ Sek.}$ ) im Vergleich zu gelben ( $MW_{\text{gelb}} = 23 \text{ Sek.}$ ) und roten ( $MW_{\text{rot}} = 21 \text{ Sek.}$ ) Ampelfarben. Die Anzahl der Revisits zur Warnmeldung war viel kürzer bei roten Warnmeldungen ( $MW_{\text{rot}} = 2,41$ ) im Vergleich zu den anderen Ampelfarben ( $MW_{\text{gelb}} = 2,52$ ,  $MW_{\text{grün}} = 3,07$ ). Diese Kennzahl deutet darauf hin, dass die Daten einfacher verstanden wurden und deshalb weniger oft in diesen Bereich zurückgekehrt werden musste (Molina et al., 2018). Bei roten Ampelfarben benötigten die Proband\*innen die wenigsten Fixationen im Bildausschnitt des Balkendiagramms ( $MW_{\text{rot}} = 15,93$ ), im Vergleich zu gelben ( $MW_{\text{gelb}} = 17,14$ ) und grünen ( $MW_{\text{grün}} = 23,44$ ) Ampelfarben.

Die Emotionsdaten liefern zusätzliche Nuancen zu den Eye-Tracking-Ergebnissen (siehe **Tabelle 1**). Szenarien mit grüner ( $MW_{\text{grün}} = 12,18 \%$ ) und gelber Ampelfarbe ( $MW_{\text{gelb}} = 11,15 \%$ ) führten zu mehr negativen Emotionen, da die Proband\*innen die Situation der zu betreuenden Person nicht eindeutig einschätzen konnten. Die roten Szenarien lösten weniger negative Emotionen aus ( $MW_{\text{rot}} = 9,90 \%$ ).

Farbe	Negativ	Verwirrung <sup>1</sup>	Überraschung <sup>1</sup>	Freude <sup>1</sup>	Ekel <sup>1</sup>	Traurigkeit <sup>1</sup>	Verachtung <sup>1</sup>	Ärger <sup>1</sup>	Angst <sup>1</sup>	Peaks / min <sup>2</sup>
Grün	12,18	6,08	1,03	5,66	1,22	8,21	3,74	3,09	2,05	4,18
Gelb	11,18	7,17	1,34	3,10	0,31	11,99	2,93	4,14	2,82	3,52
Rot	9,90	6,10	1,00	5,58	1,34	8,38	2,36	2,03	1,93	3,62

<sup>1</sup> Mittelwerte in %, <sup>2</sup> Anzahl

**Tabelle 1** – Emotionsdaten für Warnmeldungen in den jeweiligen Ampelfarben, Werte in %.

Szenarien in gelber Ampelfarbe wurden von den Proband\*innen im Vergleich zu den anderen Szenarien als verwirrender empfunden ( $MW_{\text{gelb}} = 7,17 \%$ ). Darüber hinaus wurden auch höhere Mittelwerte für Traurigkeit ( $MW = 11,99 \%$ ) und Ärger ( $MW = 4,14 \%$ ) beobachtet. Die grüne Warnmeldung wurde ebenfalls als verwirrend empfunden, was sich in einem mittleren Wert für Verwirrung (6,08 %) widerspiegelt. Darüber hinaus wurden höhere Werte für Freude ( $MW = 5,66 \%$ ) und Ekel ( $MW = 3,74 \%$ ) festgestellt.

Im Gegensatz dazu wurde die rote Warnmeldung von den Probanden als unmittelbare Gefahr wahrgenommen, was sich in höheren Werten für Ärger (MW = 2,36 %) und Überraschung (MW = 3,62 %) widerspiegelt. Darüber hinaus wurden auch höhere Werte für Freude (MW = 5,58 %) und Ekel (MW = 2,03 %) beobachtet.

## 5. Zusammenfassung und Ausblick

Abschließend kann gesagt werden, dass die Elderly Care-Funktion gut ankommt. Lediglich die gelben und grünen Warnnachrichten sind von Nutzer\*innen schwer zu deuten. Ein Optimierungsvorschlag wäre daher, Warnmitteilungen nur zu senden, wenn diese in den roten Bereich fallen, da hier auch ganz eindeutig klar ist, dass Handlungsbedarf herrscht und es sich im schlimmsten Falle um eine bedrohliche Situation handeln könnte. Warnnachrichten in grün oder gelb könnten beispielsweise durch einen zusätzlichen Infobutton näher erklärt werden, um diese Verwirrung zu vermeiden.

## 6. Literaturverzeichnis

Beenera (2023). Im Alter sicher und selbstbestimmt. Abgerufen am 7.4.2023 von <https://beenera.de/elderly-care-inaktivitaetserkennung/>

Bojko, A. (2013). Eye tracking the user experience: A practical guide to research. Rosenfeld Media.

Bzostek, J. A., & Wogalter, M. S. (1999). Measuring visual search time for a product warning label as a function of icon, color, column and vertical placement. In Proceedings of the Human Factors and Ergonomics Society Annual Meeting (Vol. 43, No. 16, pp. 888-892). Sage CA: Los Angeles, CA: Sage Publications.

iMotions (2017 a). Facial expression analysis – the complete pocket guide, iMotions, 2017. Abgerufen am 10.1.2024 von <https://imotions.com/blog/learning/best-practice/facial-expression-analysis/>

iMotions (2017 b). Galvanic Skin Response – the complete pocket guide, iMotions, 2017. Abgerufen am 10.1.2024 von [Galvanic Skin Response \(GSR\): The Complete Pocket Guide - iMotions](#)

Lees, M. N., & Lee, J. D. (2007). The influence of distraction and driving context on driver response to imperfect collision warning systems. Ergonomics, 50(8), 1264-1286.

Molina, A. I., Navarro, Ó., Ortega, M., & Lacruz, M. (2018). Evaluating multimedia learning materials in primary education using eye tracking. Computer Standards & Interfaces, 59, 45-60..

Narasinghe, N., Kathriarachchi, R. P. S., & Maduranga, M. W. P. (2020). IoT based Health Monitoring and Activity Detection for Elderly Care.

Pandey, P., & Litoriya, R. (2019). Elderly care through unusual behavior detection: a disaster management approach using IoT and intelligence. IBM Journal of Research and Development, 64(1/2), 15-1.

Statistik Austria. (2022). Altersstruktur in Österreich im Jahr 2021 und Prognose für 2030 bis 2100 [Graph]. In Statista. Zugriff am 27. März 2023, von <https://de.statista.com/statistik/daten/studie/688475/umfrage/prognose-zur-altersstruktur-in-oesterreich/>

Statistik Austria. (2023). Altersstruktur in Österreich von 2013 bis 2023 [Graph]. In Statista. Zugriff am 27. März 2023, von

<https://de.statista.com/statistik/daten/studie/217431/umfrage/altersstruktur-in-oesterreich/>

UN DESA. (2022). Altersmedian der Weltbevölkerung von 1990 bis 2021 und Prognosen bis 2100 (in Jahren; nach verschiedenen Szenarien) [Graph]. In Statista. Zugriff am 05. April 2023, von <https://de.statista.com/statistik/daten/studie/159834/umfrage/altersmedian-der-weltbevoelkerung/?locale=de>

Zhang, X., Liu, Y., Gu, Y., Wang, S., & Chen, H. (2020). Red for “stop”: “traffic-light” nutrition labels decrease unhealthy food choices by increasing activity and connectivity in the frontal lobe. *Nutrients*, 12(1), 128.