

Ablauffähige Modellierung des Einflusses von Ereignishäufigkeiten auf die Aufmerksamkeitsverteilung von Autofahrern

Bertram Wortelen und Andreas Lüdtko

Schlüsselwörter: Digitale Menschmodelle, Fahrermodelle, Aufmerksamkeit, SEEV-Modell.

Zusammenfassung

Moderne Fahrerassistenzsysteme sollen den Fahrer entlasten, bergen aber gleichzeitig das Potential die Aufmerksamkeit negativ zu beeinflussen. Um solche Einflüsse zu messen, müssen heute aufwendige Simulatorstudien mit menschlichen Testfahrern durchgeführt werden. Diese Arbeit stellt einen Ansatz zur Entwicklung von kognitiven Fahrermodellen vor, mit dem die Auswirkung von Assistenzsystemen auf die Aufmerksamkeit virtuell simuliert werden kann. Anschließend wird die geplante Evaluierung des Ansatzes durch Realfahrt- und Simulatorstudien vorgestellt. Diese Arbeit ist ein Schritt hin zu Fahrermodellen, die valide Vorhersagen zum menschlichen Fahrverhalten machen können, um die Entwicklung neuer Assistenzsysteme zu unterstützen.

Modern driving assistance systems aim to reduce the driver's workload but at the same time they can have a negative influence on the driver's attention. To measure such influences today, expensive studies in driving simulators with human subjects have to be conducted. This work presents an approach for the development of cognitive driver models that can virtually simulate the effect of assistance systems on driver's attention. Afterwards the intended evaluation of this approach with real driving and simulator studies is presented. This work is one step towards driver models that can realistically predict human driving behavior, to support the development of new driving assistance systems.

Einleitung

Im Automobilbereich werden vermehrt teilautonome Assistenzsysteme zur Unterstützung des Fahrers eingesetzt (Freymann, 2004), wie z.B. Advanced Cruise Control (ACC) und Lane Departure Avoidance. Teilautonome Systeme überwachen die Umgebung und können im Bedarfsfall autonom intervenieren. Sie verändern die Aufgabe des Fahrers, indem sie die Rolle des Fahrers vom alleinigen Akteur hin zum Überwacher verschieben. Dabei besteht die Gefahr, dass der Fahrer die Überwachungsaufgabe vernachlässigt, wenn er davon ausgeht, dass dies in ausreichender Weise vom Fahrzeug übernommen wird. Man spricht hier von out-of-the-loop-Effekten. Werden nun die Systemgrenzen erreicht und der Fahrer ist durch die verminderte Aufmerksamkeit nur schlecht über die Verkehrssituation informiert, so kann das zu verzögerten Reaktionszeiten und ggf. zu Unfällen führen. Um das System frühzeitig auf potenzielle Schwachstellen im HMI (Human Machine Interface) Design zu überprüfen, werden Werkzeuge zur Erkennung solcher Probleme benötigt. Ausführbare Fahrermodelle, die menschliches Verhalten realistisch simulieren, bieten hier die Möglichkeit, Prototypen eines Fahrzeugsystems ohne menschliche Testfahrer zu evaluieren.

In dem EU-Projekt ISi-PADAS wird ein auf der kognitiven Architektur CASCaS aufbauendes Modell entwickelt, welches das Aufmerksamkeitsverhalten an die jeweilige Fahrsituation und die beteiligten Assistenzsysteme anpasst. Die Anpassung basiert auf der Anzahl und Frequenz von Umgebungsereignissen, die der Fahrer wahrnimmt. Als Anwendungsbeispiel dient ein ACC-System, das den Abstand zum Vordermann selbstständig regulieren kann. Dadurch verringert es auch die Anzahl der Ereignisse, auf die der Fahrer reagieren muss. Folge hiervon kann eine Aufmerksamkeitsveränderung sein, mit potentiell negativen Konsequenzen für die

Fahrsicherheit. Indem das Fahrermodell die Aufmerksamkeitsadaption simuliert, soll es out-of-the-loop-Effekte vorhersagen können.

Stand der Forschung

Im Folgenden wird der Stand der Forschung zu relevanten psychologischen Themen präsentiert. Anschließend wird ein Überblick über existierende kognitive Fahrermodelle gegeben.

Im Bereich der psychologischen Forschung zur Aufmerksamkeit und zur Wahrnehmung von Häufigkeiten und Frequenzen gibt es verschiedene Studien, die relevant für diese Arbeit sind. Eine gute Übersicht darüber, wie Frequenzen wahrgenommen und verarbeitet werden, findet sich z. B. bei Sedlmeier und Betsch (2002). Wickens und McCarley (2008) untersuchten, wie Menschen ihre Aufmerksamkeit verteilen. Sie präsentieren das SEEV-Modell, das vier Haupt-Einflussfaktoren (Saliency, Effort, Expectancy, Value) identifiziert. Die vorliegende Arbeit beschränkt sich auf den Einfluss von Erwartung (Expectancy). Das SEEV-Modell besagt, dass der Fahrer bei hoher Erwartung neuer Informationen in einem bestimmten Bereich (Area of Interest - AOI) seine Aufmerksamkeit mit hoher Wahrscheinlichkeit dorthin lenkt. Dabei kann eine Erwartungshaltung durch Umgebungshinweise (z.B. Signaltöne), oder aus der Frequenz bisheriger Ereignisse erzeugt werden. Treten Ereignisse häufig auf, so erhöht sich die Erwartung. Horrey et al. (2006) nutzten das SEEV-Modell erfolgreich in Fahrstudien, um die Aufmerksamkeitsverteilung von Autofahrern vorherzusagen. Diese Studien waren auf die laterale Kontrollaufgabe (Spurhalten) des Fahrers fokussiert, während die vorliegende Arbeit die longitudinale Kontrollaufgabe (Abstands- und Geschwindigkeitskontrolle) untersucht.

Im Bereich der kognitiven Fahrermodellierung existieren verschiedene Arbeiten zu ausführbaren Fahrermodellen. So hat beispielsweise Salvucci (2006) mithilfe der kognitiven Architektur ACT-R ein Fahrermodell erstellt, dessen Fokus auf der lateralen Fahrzeugkontrolle liegt. Mit der in dieser Arbeit verwendeten kognitiven Architektur CASCaS (s.u.) wurde bereits von Weber & Lüdtke (2009) ein Fahrermodell zur Untersuchung von Einfädelszenarien auf der Autobahn erstellt. Des Weiteren gibt es verschiedene Modelle, die auf speziell für die Fahrermodellierung entwickelten Frameworks aufsetzen, wie das COSMODRIVE Modell von Bellet und Tattegrain-Veste (1999), das das Situationsbewusstsein von Fahrern untersucht.

Die Innovation der vorliegenden Arbeit ist, basierend auf dem Aufmerksamkeitsmodell von Wickens und McCarley (2008), einen Mechanismus in die existierende kognitive Architektur CASCaS zu integrieren, der den Einfluss der Ereignisdichte auf die Aufmerksamkeit simuliert.

Die kognitive Architektur CASCaS

Die kognitive Architektur CASCaS (Cognitive Architecture for Safety Critical Task Simulation) wird am Institut OFFIS zur Simulation menschlichen Verhaltens bei der Durchführung sicherheitskritischer Aufgaben entwickelt (s. Abbildung 1a). Sie soll HMI-Entwickler bei Design-Entscheidungen unterstützen. Die Architektur implementiert Mechanismen zur kognitiv plausiblen Verarbeitung taskspezifischen Wissens. Dieses taskspezifische Wissen gliedert sich in Langzeit- und Kurzzeitwissen und wird in der Memory-Komponente abgelegt. Alle Informationen, die über die Perzept-Komponente wahrgenommen werden, gelangen automatisch in die Memory-Komponente und stehen dort dem Modell als Kurzzeitwissen zur Verfügung. Das Langzeitwissen besteht aus einer Menge aus Tripeln $\langle g, c, a \rangle$, so genannten GSM-Regeln (Goal State Means). Die linke Seite einer Regel (WENN) nennt ein Ziel g , das durch Anwenden der Regel erreicht werden soll und formuliert Bedingungen c an das Kurzzeitwissen der Memory-Komponente. Wenn die Bedingungen wahr sind, kann die Regel gefeuert werden und alle Aktionen a auf der rechten Seite der Regel (DANN) werden ausgeführt. Das können z.B. Manipulationen von Umgebungsvariablen, Augenbewegungen, Änderungen von Gedächtnisvariablen oder Ableitung von Subzielen sein (s. Abbildung 1b).

Orientiert an Anderson (2000) wird die Verarbeitung von Wissen in drei Ebenen unterteilt – die kognitive, assoziative und autonome Ebene. Aufgaben, die in dieser Arbeit betrachtet werden, ordnen wir der assoziativen Ebene zu. Die Verarbeitung auf dieser Ebene erfolgt über die oben beschriebenen Regeln. Regeln sind ein Mittel des Modells, um ein bestimmtes Ziel zu erreichen. Die Auswahl der Ziele erfolgt im Ziel-Modul. Die Fähigkeit zum Multitasking erhält das Modell, indem es durch Unterbrechung des aktuellen Ziels dynamisch zwischen verschiedenen Zielen wechselt. Die assoziative Ebene sammelt alle Regeln, die zum aktuell ausgewählten Ziel gehören und deren Bedingungen erfüllt sind. Aus dieser Menge wird eine ausgewählt und gefeuert (ausgelöst), indem ihre Aktionen ausgeführt werden. Ist ein Wert, der für die Evaluierung der Regel notwendig ist, in der Memory-Komponente nicht verfügbar, so wird die Perzept-Komponente aufgefordert den Blick auf diesen Wert in der Umgebung zu richten, um ihn so wahrzunehmen.

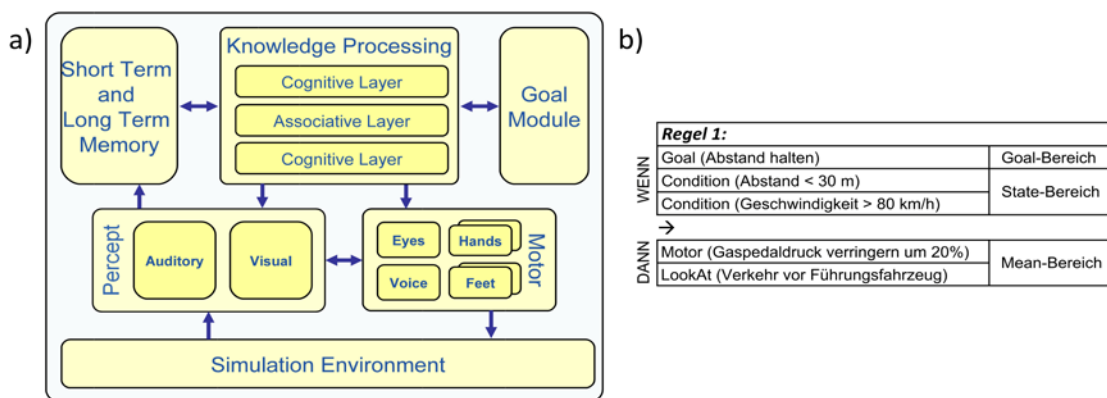


Abbildung 1: a) Die Komponenten von CASCaS. b) Beispiel einer Regel in CASCaS.

Integration eines Mechanismus zur Aufmerksamkeitsadaption in CASCaS

Der Begriff Frequenz wird im Kontext dieser Arbeit für die Häufigkeit eines wiederkehrenden diskreten Ereignisses verwendet, wie z.B. das Aufblinken des Bremslichtes des Vorderfahrzeugs. Die objektive Frequenz dieses Ereignisses hängt davon ab, wie häufig der Vordermann während der Fahrt die Bremse betätigt. Aufgrund von Ablenkung kann es sein, dass der Fahrer nicht jedes Ereignis bemerkt. Für ihn ist daher nicht die tatsächliche Frequenz relevant, sondern die subjektiv wahrgenommene.

Nach Wickens SEEV-Modell (Wickens & McCarley, 2008) ist die Frequenz einer der Faktoren, der die visuelle Aufmerksamkeitsverteilung von Menschen beeinflusst. Senders (1964) zeigte, dass die visuelle Aufmerksamkeit proportional von der Informationsfrequenz abhängt. Zacks und Hasher (2002) argumentieren, dass das Ablegen von Frequenzinformationen im Gedächtnis automatisch und unbeabsichtigt erfolgt. Es benötigt vor allem keinen kognitiven Aufwand und hat somit keinen Einfluss auf die Verarbeitungszeit. Beim Abruf dieser Information hängt der Aufwand jedoch stark von der Art und Weise des Abrufs ab. Brown (2002) stellt eine Taxonomie für verschiedene Strategien bei der Einschätzung von Frequenzen vor. Der Gebrauch von Frequenzinformation bei der Adaption der Aufmerksamkeit geschieht implizit. Hier spielt vor allem der Eindruck von Ereignishäufigkeiten eine Rolle. Brown zufolge entspricht dies am ehesten einer nicht-aufzählenden und nicht-numerischen Strategie. Diese Frequenzinformation steht Menschen unmittelbar zur Verfügung. Daher wird der zeitliche Aspekt des Abrufs von Frequenzinformationen in der Modellierung nicht berücksichtigt.

Die genannten Aspekte wurden unabhängig von einer konkret zu modellierenden Aufgabe in CASCaS operationalisiert. Kern der Operationalisierung sind zwei Definitionen (s. unten): Definition eines subjektiven Ereignisses und Definition der subjektiven Ereignisfrequenz. Auf dieser Basis wird der Einfluss der Ereignisfrequenz auf die Aufmerksamkeit modelliert.

In der Studie von Horrey et.al. (2006) wurde die Frequenz von Windturbulenzen als *objektiv* messbare Information variiert und zur Vorhersage der Aufmerksamkeitsverteilung genutzt. Für objektiv messbare Frequenzen lassen sich Ereignisse durch plötzlich auftretende Eigenschaften c in der Umgebung definieren (z.B.: $c = \text{Bremslicht des Vorderfahrzeugs leuchtet auf}$). Sei E die Menge der möglichen Umgebungszustände, dann sind alle objektiv messbaren Ereignisse E_n die Menge aller Umgebungszustände, die c erfüllen: $E_o = \{e \in E \mid e \text{ erfüllt } c\}$. Jedoch ist nicht jedes objektiv messbare Ereignis für den Fahrer relevant oder wird von ihm wahrgenommen. Reagiert der Fahrer allerdings auf eine Umgebungssituation, so hat er sie offensichtlich wahrgenommen und sie hat aufgrund der Reaktion eine Relevanz für ihn. Wir definieren die Menge subjektiver Ereignisse E_c dadurch, dass der Fahrer bestimmte Reaktionen a auf Umgebungsereignisse e_n zeigt: $E_s = \{e_o \in E_o \mid e_o \text{ provoziert } a\}$. Das schränkt die Ereignismenge weiter ein: $E \supseteq E_n \supseteq E_c$. In CASCaS bieten sich die Regeln zur Definition eines Ereignisses an, da sie den Zusammenhang zwischen Umgebungszustand c und Fahrerreaktion a beschreiben.

Wickens (2008) definiert die Ereignisfrequenz jeweils für ein AOI, um die visuelle Aufmerksamkeitszuwendung zu den beteiligten AOIs vorherzusagen. Da in CASCaS sowohl die visuelle Aufmerksamkeit als auch das Feuern einer Regel stark vom ausgewählten Ziel abhängt, sollen hier Ereignisse jeweils für ein Ziel und nicht für ein AOI definiert werden:

Definition 1: subjektives Ereignis

Das Feuern einer Regel $\langle g, c, a \rangle$ ist ein subjektives Ereignis e für das Ziel g . Der Zeitpunkt des Feuerns ist zugleich der Zeitpunkt zu dem das Ereignis auftritt

Der Zeitpunkt jedes Ereignisses wird zusammen mit dem Ziel in der Gedächtniskomponente von CASCaS abgelegt. Nun lässt sich die subjektive Ereignisfrequenz ermitteln, indem man die Anzahl der Ereignisse durch die Zeitspanne seit Beginn der Ereignisaufzeichnung t_{\dots} teilt. Da ein Ereignis durch das Feuern einer Regel definiert ist, und Regeln nur gefeuert werden können, wenn das zugehörige Ziel ausgewählt ist, beginnt die Ereignisaufzeichnung, wenn das zugehörige Ziel im Ziel-Modul aktiviert wird. Die Ereignisfrequenz Ef_c eines Zieles g zum Zeitpunkt t ist wie folgt definiert:

Definition 2: subjektive Ereignisfrequenz

$$Ef_s(g, t) = \frac{n_{events}(g)}{t - t_{start}(g)}, \text{ mit } \begin{array}{l} n_{events}(g) = \text{Anzahl der Ereignisse für } g \\ t_{start}(g) = \text{Zeitpunkt der Aktivierung von } g \end{array}$$

Nach Wickens wirkt sich die Informationsfrequenz auf die visuelle Aufmerksamkeit aus. In CASCaS ist die visuelle Aufmerksamkeit stark an die kognitive Aufmerksamkeit gekoppelt. Wie oben bereits beschrieben, wird die Perzept-Komponente aufgefordert die visuelle Aufmerksamkeit auf Bereiche zu richten, die Informationen für das aktuell ausgewählte Ziel liefern. Um die visuelle Aufmerksamkeit an die Ereignisfrequenzen anzupassen, muss daher zuerst die Zielauswahl an die Frequenz angepasst werden. Bisher hängt die Wahrscheinlichkeit P , dass ein auswählbares Ziel g_i ausgewählt wird, hauptsächlich von den Zielprioritäten ab:

$$P(g_i) = \frac{V(g_i)}{\sum_{i=1}^{n_{goals}} V(g_j)}, \text{ mit } \begin{array}{l} n_{goals} = \text{Anzahl der auswählbaren Ziele} \\ V(g) = \text{Priorität des Ziels } g \end{array}$$

Ebenso wie Horrey und Wickens verknüpften wir die Frequenz und Priorität multiplikativ (Gleichung 1 in (Horrey et al., 2006)). Mit der folgenden, erweiterten Formel entspricht die Auswahl der Ziele bei gleicher Priorität aller Ziele der relativen Ereignisfrequenz der Ziele:

$$P(g_i) = \frac{V(g_i) \cdot Ef_s(g_i)}{\sum_{i=1}^{n_{goals}} (V(g_j) \cdot Ef_s(g_j))}$$

Geplante Evaluierung

Die Verfeinerung und Evaluierung des vorgestellten Konzepts soll schrittweise geschehen: (1) Um die praktische Relevanz der Hypothese zu zeigen, wird die beschriebene Auswirkung der Ereignisfrequenz auf die Aufmerksamkeit in Daten aus Realfahrtstudien untersucht. (2) In Fahrstudien soll die Ereignisfrequenz für Folgefahrszenarien gezielt variiert werden, um Parameter für das Fahrermodell zu gewinnen. (3) Mit den gewonnenen Daten soll ein Fahrermodell erstellt werden, dessen Aufmerksamkeitsverteilung dem der realen Versuchspersonen entspricht.

Schritt 1 wird aktuell durchgeführt. Im Folgenden wird die vorläufige Planung für diesen Schritt vorgestellt. Schritt 2 und 3 sind für Herbst und Winter 2009 geplant. Im Rahmen des EU-Projektes ISi-PADAS wurde eine Realfahrtstudie mit 18 Teilnehmern durchgeführt, die mit einem mit Sensoren und Kameras ausgestattetem Auto ca. 2,5 Stunden hauptsächlich über Autobahnen fuhren. Da kein Eyetracker eingesetzt wurde, kann die visuelle Aufmerksamkeit nicht direkt ermittelt werden. Indirekt soll dies über Reaktionszeiten zwischen Aufleuchten der Bremslichter beim Vordermann und dem Betätigen des Bremspedals des Fahrers geschehen.

Um die Wirkung der Ereignisfrequenz zu untersuchen, muss diese in den Daten messbar sein. Da ein Ereignis e über den Zusammenhang zwischen Umgebungszustand c und Fahreraktion a definiert wurde, wird in den Fahrdaten nach Aktionen a gesucht, die darauf hindeuten, dass der Fahrer auf das Verhalten des Vordermanns reagiert hat. Da hier die Longitudinalkontrolle betrachtet wird, werden Betätigungen des Brems- und Gaspedals gesucht. Dabei werden Gaspedaländerungen um mindestens 1% innerhalb von maximal 300 ms berücksichtigt. Damit der Fahrer genug Zeit hat die Ereignisfrequenz wahrzunehmen, werden Situationen gesucht, in denen der Fahrer für einen gewissen Mindestzeitraum von 30 s demselben Fahrzeug folgt. Zu diesem Zweck wurden Folgefahrsituationen in den Daten mittels Videoanalyse markiert. Auf eine Phase des Folgefahrens soll dann eine Bremsung des Vordermanns folgen. Es sollen nur Beschleunigungen des Vordermanns (a_{LV}) unterhalb von $-1,5 \frac{m}{s^2}$ ausgewertet werden. Da es sich um ein Folgefahrszenario handelt, sollte der Fahrer als Reaktion ebenfalls bremsen. Dies lässt sich durch Betätigung des Bremspedals messen. Der Zeitraum von der Bremsung des Vordermanns t_{brake} bis zur Bremsung der Versuchsperson t_{react} ist die Reaktionszeit RT .




Abbildung 2: Gesuchtes Situationsmuster in den Daten der Realfahrtstudien

Die hier beschriebenen Muster (s. Abbildung 2) werden automatisch in den Fahrdaten gesucht und anschließend anhand der Videos manuell überprüft. Dabei sind alle genannten Parameter angenommene Erwartungswerte. Wir erwarten, dass sich für diese Situationen eine signifikante Abhängigkeit zwischen Ereignisfrequenz $Ef_s = \frac{\#events(t_{react}) - \#events(t_{start})}{t_{react} - t_{start}}$ und RT zeigt.

Zusammenfassung und Ausblick

Es wurde ein Mechanismus für die kognitive Architektur CASCaS vorgestellt, der das Adaptionsverhalten von Fahrern auf Ereignishäufungen im Verkehr realistisch simulieren soll. Zudem wurde die geplante Evaluierung über Fahrstudien präsentiert. In weiteren Schritten soll der Mechanismus verfeinert werden, um den zeitlichen Zusammenhang der Ereignisse stärker zu berücksichtigen. So ist anzunehmen, dass Ereignisse, die kürzlich aufgetreten sind, einen höheren Einfluss auf die Aufmerksamkeitsverteilung haben als länger zurück liegende.

Die Arbeit, die zu den präsentierten Ergebnissen geführt hat, erhielt Finanzierungsmittel aus dem siebten europäischen Rahmenprogramm (FP7) unter dem Förderungsvertrag n° 218552.

Literatur

- Anderson, J. R. (2000). *Learning and Memory*. New York; Chichester: Wiley & Son.
- Bellet, T., & Tattegrain-Veste, H. (1999). A Framework for Representing Driving Knowledge. *International Journal of Cognitive Ergonomics*, 3 (1), S. 37-49.
- Brown, N. R. (2002). Encoding, Representing, and Estimating Event Frequencies: A Multiple Strategy Perspective. In P. Sedlmeier, & T. Betsch, *ETC. Frequency Processing and Cognition* (S. 37-53). Oxford University Press.
- Freymann, R. (2004). Möglichkeiten und Grenzen von Fahrerassistenz- und Aktiven Sicherheitssystemen. *Plenarvortrag zur Tagung "Aktive Sicherheit durch Fahrassistenz"*. TU München, Garching.
- Horrey, W. J., Wickens, C. D., & Consalus, K. P. (2006). Modeling Drivers' Visual Attention Allocation While Interacting With In-Vehicle Technologies. *Journal of Experimental Psychology: Applied*, 12 (2), S. 67-78.
- Lüdtke, A., Weber, L., Osterloh, J.-P., & Wortelen, B. (2009). Modeling Pilot and Driver Behaviour for Human Error Simulation. *Proceedings HCI International. Springer.*
- Salvucci, D. D. (2006). Modeling Driver Behavior in a Cognitive Architecture. *Human Factors*, 48 (2), pp. 362-380.
- Sedlmeier, P., & Betsch, T. (Hrsg.). (2002). *ETC. Frequency Processing and Cognition*. Oxford University Press.
- Senders, J. W. (1964). The Human Operator as a Monitor and Controller of Multidegree of Freedom Systems. *Transactions on Human Factors in Electronics*, (S. 2-6).
- Weber, L., Lüdtke, A. Modellierung der Aufmerksamkeitsverteilung beim Einfädeln auf die Autobahn. In M. Rötting, G. Wozny, Anne Klostermann und J. Huss (Hrsgb.), 7. Berliner Werkstatt Mensch-Maschine-Systeme (S. 35 – 40), Düsseldorf: VDI Verlag, 2007.
- Wickens, C. D., & McCarley, J. S. (2008). *Applied Attention Theory*. Boca Raton: CRC Press.
- Zacks, R. T., & Hasher, L. (2002). Frequency Processing: A Twenty-Five Year Perspective. In P. Sedlmeier, & T. Betsch, *ETC. Frequency Processing and Cognition* (S. 21-36). Oxford University Press.