



Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

Masterarbeit

Kai Bielenberg

**Einsatz eines Eyetracker basierten Miningverfahrens für ein
Companionsystem**

*Fakultät Technik und Informatik
Studiendepartment Informatik*

*Faculty of Engineering and Computer Science
Department of Computer Science*

Kai Bielenberg

**Einsatz eines Eyetracker basierten
Miningverfahrens für ein Companionsystem**

Masterarbeit eingereicht im Rahmen der Masterprüfung

im Studiengang Master of Science Angewandte Informatik
am Department Informatik
der Fakultät Technik und Informatik
der Hochschule für Angewandte Wissenschaften Hamburg

Betreuender Prüfer: Prof. Dr. Kai von Luck
Zweitgutachter: Prof. Dr. Andreas Meisel

Eingereicht am: 17. Mai 2016

Kai Bielenberg

Thema der Arbeit

Einsatz eines Eyetracker basierten Miningverfahrens für ein Companionsystem

Stichworte

Companion Technologie, Eyetracking, Emotion Detection, Wissensextraktion, KDD, Data Mining

Kurzzusammenfassung

Diese Arbeit beschreibt die Companion Technologie im Kontext des EmoBike Projektes der HAW-Hamburg. Insbesondere wird der Bereich der Emotionserkennung mithilfe eines Eyetrackers betrachtet. Es wird untersucht ob Algorithmen aus dem Data Mining Bereich bei der Auswertung hilfreich sein können. Abschließend erfolgt eine Vorstudie um zu zeigen, dass eine Erweiterung des EmoBike Projektes durch einen Eyetracker sinnvoll ist.

Kai Bielenberg

Title of the paper

Usage of an eyetracker based data mining procedure for an companion system

Keywords

Companion Technology, Eyetracking, Emotion Detection, Knowledge Discovery, KDD, Data Mining

Abstract

This thesis describes the companion technology in the context of the EmoBike project of the HAW-Hamburg. The emotion detection with an eyetracker is an integral part of this thesis. It is shown, that algorithms of the data mining context can be used to classify emotions. A preliminary study is conducted to present the usefulness of an eyetracker in the EmoBike context.

Inhaltsverzeichnis

1. Einleitung	1
1.1. Zielsetzung	2
1.2. Gliederung	2
2. Analyse	4
2.1. Companion Technologie	4
2.2. Emotionen	6
2.2.1. Grundemotionen	7
2.2.2. Valence-Arousal-Dominance Modell	7
2.2.3. SAM, das Self-Assessment Manikin	8
2.3. Emotionserkennung in der Companion Technologie	10
2.4. Augen und Emotionen	12
2.5. Emotionsinduktion	14
2.6. Data Mining	16
2.6.1. KDD-Prozess	17
2.7. Datenauswertung	19
2.8. Zusammenfassung der Anforderungen	20
3. Versuchsaufbau	22
3.1. EmoBike Projekt	22
3.2. Eyetracker Erweiterung	24
3.2.1. Eyetracker Hardware	24
3.2.2. Eyetracker Software	26
3.2.3. Eyetracker Integration	31
3.3. Virtuelle Umgebung	33

Inhaltsverzeichnis

3.4. Self-Assessment	36
3.5. Datenauswertung im KDD Prozess	38
3.5.1. Datenselektion	38
3.5.2. Datenvorverarbeitung	39
3.5.3. Datentransformation	42
3.5.4. Data Mining	43
3.5.5. Evaluation & Interpretation	43
4. Versuchsdurchführung	46
4.1. Auswertung	48
5. Fazit und Ausblick	59
A. Anhang	63

Tabellenverzeichnis

3.1. Übersicht der Levevents mit emotionaler Reaktion (Darstellung der Events in Abbildung A.11)	37
4.1. Informationen über die Probanden	46
4.2. Ergebnis der SAM Self-Assessment-Befragung	47
4.3. Übersicht der Events inklusive der auszuwertenden Datenpakete	48
4.4. Übersicht der Ergebnisse der Datenauswertung	57

Abbildungsverzeichnis

2.1.	Die drei Dimensionen der SAM 9-Punkte Skala: Valence:oben, Arousal:mittig, Dominanz:unten[34].	10
3.1.	Eyetracker Browser (links) und Config Tool (rechts)	29
3.2.	Beispiel einer Eyetracker Kalibrierung[31]	30
3.3.	Physische Übersicht des EmoBike Projektes inklusive Eyetracker Erweiterung	31
3.4.	SAM mit angepasster Skala[34]	37
3.5.	Oben: Pupillengrößendurchschnitt vom linken und rechten Auge Unten: Anwendung der Interpolation (Orange) und des gleitenden Mittelwertes (Blau) Horizontale Linie: Falling Event (Magenta)	41
3.6.	Transformation eines Falling Events	42
3.7.	Boxplot der Scare Events, links vorher, rechts nachher	45
4.1.	Boxplot: Levelmitte Level 1	50
4.2.	Boxplot: TeddyHit Event	51
4.3.	Boxplot: Coin Events in Level 3	51
4.4.	Boxplot: Coin Events in Level 6	52
4.5.	Boxplot: Boost Events	53
4.6.	Boxplot: Falling Events	54
4.7.	Boxplot: Wall Events	55
4.8.	Boxplot: SpiderAttack Events	56
4.9.	Boxplot: Scare Events	57
A.1.	Beispiel des Self-Assessment Fragebogens	63

Abbildungsverzeichnis

A.2. User Coordinate System (UCS) Beispiel[31]	64
A.3. Track Box Coordinate System (TBCS) Beispiel[31]	64
A.4. logische Sicht des EmoBike Projektes erweitert um den Eyetracker. (Quelle Ursprungsbild: Jonas Hornschuh)	65
A.5. Übersicht von Level 1 mit einem grünen Start und einem roten Ziel	66
A.6. Übersicht von Level 2 mit zusätzlichen Teddybären (einer ist exemplarisch mit blau Markiert))	66
A.7. Übersicht von Level 3 mit Warnkegeln in der Mitte der Straße (drei beispielhaft in blau) und versetzten Münzen (drei exemplarisch in lila)	67
A.8. Übersicht von Level 4 mit dem blau markierten Boost und der lila markierten Rampe	67
A.9. Übersicht von Level 5 mit der blauen Steigung, der lila Wand und den orangen Spinnen	68
A.10. Übersicht von Level 6 mit drei exemplarischen blauen Mün- zen und dem lila scare Event. Das Level spielt in der Nacht und ist nur für die Übersicht aufgehellt	68
A.11. Übersicht der Levevents	69

1. Einleitung

Heutzutage haben Nutzer es mit einer immer komplexeren und technisierteren Welt zu tun. Interaktionen mit vielen unterschiedlichen Systemen sind eine Selbstverständlichkeit.

Diese komplexen Systeme lassen sich immer schwieriger mit einem einfachen Interface abbilden. Dies erschwert eine einfache und intuitive Nutzung der Systeme. Daher geht der Trend weg von immer einfacheren Interfaces hin zu Interfaces, die sich an den Nutzer anpassen können.

Die Companion Technologie unterstützt den Ansatz, der sich auf den den Nutzer einstellenden Interfaces. Ein Companion unterstützt den Nutzer in dieser hochtechnisierten Welt auf eine natürliche Art und Weise. Damit der Companion auf die unterschiedlichen Bedürfnisse des Nutzers reagieren kann, ist ein tiefer Einblick in den Nutzer notwendig. Der Companion muss erfahren wie sich der Nutzer fühlt, um richtig auf eine gegebene Situation reagieren zu können.

Hierfür ist ein Verständnis der Emotionen des Nutzers unabdingbar. Ein Companion muss den Nutzer daher auf emotionaler Ebene verstehen.

Das EmoBike Projekt der HAW Hamburg untersucht die Möglichkeiten der Companion Technologie anhand eines Ergometers. Das Ergometer wird so erweitert, dass es in der Lage ist, den Nutzer je nach bedarf zu motivieren oder auch zu beruhigen. Innerhalb dieses Projektkontextes

1. Einleitung

wird untersucht inwieweit ein Eyetracker zur Entwicklung der Companion Technologie beitragen kann.

1.1. Zielsetzung

Zunächst wird einen Überblick über die Companion Technologie gegeben um die Arbeit in den richtigen Kontext zu setzen.

In dieser Arbeit wird im Rahmen einer Vorstudie geprüft, ob die Verwendung eines Eyetrackers im EmoBike Projekt (siehe 3.1) sinnvoll ist um Informationen über den emotionalen Zustand des Probanden zu erhalten.

Die Vision der Companion Technologie fordert eine Auswertung des emotionalen Zustandes des Probanden, nur unter dieser Bedingung kann das System sinnvoll auf den Nutzer eingehen.

Anschließend wird begutachtet, wie die Eyetrackerdaten mit dem emotionalen Zustand des Nutzers in Zusammenhang gebracht werden können. Um dies zu ermöglichen, wird untersucht, ob Methoden aus dem Data Mining Umfeld zu einer Lösung beitragen können.

1.2. Gliederung

Diese Ausarbeitung besteht aus fünf Kapiteln. Kapitel 1 beschreibt die Einleitung dieser Arbeit und zeigt das Umfeld und den Zusammenhang auf. Weiterhin wird die Zielsetzung der Arbeit verdeutlicht.

Das darauf folgende 2. Kapitel beschreibt die Analyse der gewünschten Ziele aus Kapitel 1.1. Die Companion Technologie wird definiert und die Arbeit wird in den Kontext der Companions eingeordnet. Weiterhin gibt es einen Überblick über emotionale Modelle. Diese zeigen, wie eine emo-

1. Einleitung

tionaler Zustand vergleichbar und auswertbar dargestellt werden kann. Es wird erläutert, wie Emotionen erkannt werden können. Insbesondere wird hierbei auf die Auswertung der Augen eingegangen. Weiterhin wird analysiert wie die gesammelten Daten aufzubereiten und auszuwerten sind. In diesem Bereich wird der Bezug zum Data Mining deutlich.

Kapitel 3 erläutert den Versuchsaufbau, der aufgrund der aus der Analyse in Kapitel 2 entstandenen Anforderungen, zustande gekommen ist. Das EmoBike Projekt und die Erweiterung durch einen Eyetracker wird beschrieben. Zusätzlich wird die Datenverarbeitung und Auswertung erläutert.

Das 4. Kapitel beschäftigt sich mit der Durchführung des Versuches und der tatsächlichen Auswertung der Messdaten. Diese Kapitel beschreibt die Anwendung der in Kapitel 2 und Kapitel 3 beschriebenen Anforderungen und deren Umsetzung im Versuchsaufbau.

Die Ergebnisse werden in Kapitel 5 zusammengefasst im Kontext der Zielsetzung dargestellt und es wird ein Ausblick auf die Anwendungsmöglichkeiten gegeben, die aus den Ergebnissen dieser Arbeit entstehen.

2. Analyse

Dieses Kapitel dient der Analyse der Emotionserkennung innerhalb der Companion Technologie. Es wird dargestellt, warum die Emotionserkennung in diesem Bereich einen wichtigen Faktor darstellt. Hierfür wird die Companion Technologie untersucht und die Arbeit in diesen Kontext eingeordnet. Weiterhin wird ein Überblick über die Modellierung von Emotionen präsentiert. Im Anschluss wird darauf eingegangen, welche Probleme bei der Emotionserkennung bestehen und wie ein Eyetracker zur Lösung dieser Probleme eingesetzt werden kann. Der Analyse dient das EmoBike Projekt 3.1 der HAW Hamburg als Grundlage.

Weiterhin wird untersucht mit welchen Methoden die gesammelten Eyetracker Daten automatisiert untersucht werden können. Es wird geprüft ob der KDD-Prozess 2.6.1 aus dem Datamining Bereich für die Datenverarbeitung geeignet ist. Wenn dies möglich ist, steht eine gut untersuchte und strukturierte Methode der Datenanalyse zur Datenauswertung bereit.

2.1. Companion Technologie

Yorrik Wilks hat in seinem Buch "Close engagements with artificial companions: key social, psychological, ethical and design issues"[37] den Begriff Companion Technologie genauer definiert:

2. Analyse

By Companions we mean conversationalists or confidants —*not robots*— but rather *computer software agents* whose function will be to get to *know their owners*, who may well be elderly or lonely, and *focusing not only on assistance via the internet* (contacts, travel, doctors etc.) that many still find hard to use, *but also on providing company and Companionship, by offering aspects of personalization.*[1]

Wilks nimmt Bezug darauf, dass Softwareagenten den Zustand ihrer Nutzer kennen sollen, um diesen je nach Bedarf zu unterstützen.

Ein Companion muss in der Lage sein, seinen Nutzer auf persönliche Art zu unterstützen. Es wird herausgestellt, dass hier keine Roboter gemeint sind, sondern Softwareagenten.

Die Software muss nicht nur in der Lage sein, einen bestimmten Nutzer zu erkennen, sondern sie muss sich je nach Zustand des Nutzers entsprechend verhalten, um diesen zu unterstützen.

Der Sonderforschungsbereich Transregio 62 (SFB)[1] hat sich ebenfalls der Companion Technologie angenommen und baut auf der Definition von Wilks auf. Der SFB verdeutlicht zusätzlich, dass ein Companion vertrauenswürdig sein muss. Ein Companion erlangt tiefgreifendes Wissen über den emotionalen Zustand des Nutzers, daher ist das Vertrauen in den Companion essentiell.

Der SFB beschreibt, dass sich Companion Technologie aus folgenden Teiltechnologien zusammensetzt:

1. Planung und Entscheidung
2. Interaktion und Verfügbarkeit

2. Analyse

3. Situation und Emotion
4. Transferprojekte
5. Zentralbereich

Es wird aufgezeigt, dass die Companion Technologie ein großes Forschungsgebiet ist, dass mehrere Disziplinen und Forschungsfelder vereint. Diese Ausarbeitung wird sich mit dem dritten Teilbereich, Situation und Emotion, befassen. Nach Wilks muss ein Companion den Nutzer auf persönlicher Ebene unterstützen können. Hierfür ist ein Einblick in die Emotionen des Nutzers unabdingbar. Der Companion muss daher den emotionalen Zustand des Nutzers auswerten können.

2.2. Emotionen

Einen Überblick über vier Grundlegende Modelle der menschlichen Emotionen hat R.R. Cornelius in seiner Ausarbeitung "*Theoretical Approaches to Emotion*" [10] gegeben. In dieser werden verschiedene Arten von Emotionsmodellen zusammengefasst. Zwischen den Modellen gibt es viele Überschneidungen.

Dieses Kapitel beschreibt davon zwei grundsätzliche Emotionsmodelle die genutzt werden um menschliche Emotionen zu klassifizieren. Nach der Überführung der Messwerte in ein Emotionsmodell, kann dies genutzt werden um die Emotionen auszuwerten und die Ergebnisse zu vergleichen. Für weiterführende Informationen haben Lottridge et al. [20] eine gute Übersicht über die Klassifikation von Emotionen gegeben.

2.2.1. Grundemotionen

Das Modell der Grundemotionen beruht auf dem Ansatz von Ekman[12]. Die folgenden sieben Grundemotionen wurden von Ekman herausgearbeitet: *Zorn, Überraschung, Verachtung, Traurigkeit, Fröhlichkeit, Angst und Ekel*.

Diese Theorie der Grundemotionen wurden genutzt, um zu beweisen, dass für jede der Grundemotionen universelle Gesichtsausdrücke existieren[12, 13]. Mit diesem Wissen wurde es möglich, Emotionen anhand von Gesichtsausdrücken zu klassifizieren. Weiterhin zeigt dieser Zusammenhang, dass diese grundlegenden Emotionen überall auf der Welt gleich sind und im Gesicht eindeutig erkennbar sind. Andere emotionale Zustände können aus diesen sieben Emotionen durch Kombination gebildet werden.

2.2.2. Valence-Arousal-Dominance Modell

Das Valence-Arousal-Dominance Modell (VAD Modell) [23], auch Pleasure-Arousal-Dominance Modell genannt, beschreibt eine andere Art um Emotionen zu klassifizieren. Im Gegensatz zu dem Grundemotionsmodell (s. 2.2.1), bei dem das Emotionsmodell aus sieben Dimensionen besteht, werden die Emotionen in nur drei Dimensionen klassifiziert. Es wird die Ausprägung der *Wertigkeit(valence)*, der *Intensität(arousal)* und der *Dominanz(dominance)* der Emotionen bewertet. Diese einzelnen Werte lassen sich wie folgt beschreiben:

Valence: Die Valence oder Wertigkeit beschreibt ob die Emotion als positiv oder negativ empfunden wird. Dies ermöglicht eine generelle Unterscheidung zwischen Wohlfühlen und Unwohlsein.

2. Analyse

Arousal: Das Arousal gibt die Intensität der Emotion an. Durch diese zweite Dimension lassen sich zum Beispiel Angst (negative Valence, positives Arousal) und Trauer (negative Valence, negatives Arousal) unterscheiden.

Dominance: Die Dominanz oder auch Kontrolle beschreibt wie sehr die Person von der Emotion beherrscht ist oder umgekehrt. Durch die zusätzliche Dominanz-Achse, lassen sich sehr ähnliche Emotionen wie Angst (negative Valence, positives Arousal, negative Dominanz) und Ärger (negative Valence, positives Arousal, positive Dominanz) unterscheiden. Diese Dimension wird teilweise vernachlässigt, wenn die Unterscheidung durch Arousal und Valence ausreichend ist[20].

Mit diesen Werten lässt sich der emotionale Zustand hinreichend klassifizieren. Aufgrund der geringen Dimensionsanzahl lässt sich dieses Modell, im Gegensatz zum Grundemotionsmodell, besser auf Messwerte abbilden um diese zu klassifizieren.

2.2.3. SAM, das Self-Assessment Manikin

Dieser Abschnitt beschreibt das Self-Assessment Manikin (SAM) welches von Bradley und Lang in [5] entwickelt wurde, um ein nonverbales emotionales Feedback von Probanden einzuholen. Die nonverbale Kommunikation hat den Vorteil, dass keine Missverständnisse aus unterschiedlichem Sprachgebrauch entstehen.

Das SAM bietet die Möglichkeit die drei Dimensionen (Valence, Arousal und Dominanz) in Form eines Self-Assessments abzufragen. Hierfür wird für jede Dimension eine Bildreihe dargestellt, die die Werte der Dimension ausdrücken. Die Bildreihe besteht aus 5-9 Bildern, je nachdem wie fein die

2. Analyse

Unterscheidungsmöglichkeiten sein sollen. Diese Bildreihen sind wie folgt zusammengesetzt:

Valence: Die Valence 9-Punkte Skala (Abb. 2.1 oben) zeigt ein Manikin, welches von einem traurigen zu einem fröhlichen Gesichtsausdruck wechselt. Hiermit wird eine Aussage über die Wertigkeit der Emotion gegeben, also ob es sich um eine positive oder negative Emotion handelt.

Arousal: Die Arousal Skala (Abb. 2.1 mittig) zeigt ein Manikin, welches von einem ruhigen in einen aufgewühlten Zustand übergeht. Dies bewertet die Intensität der Emotion. So können verschiedene Intensitäten von ansonsten gleichen emotionalen Zuständen unterschieden werden.

Dominanz: Die Dominanz Skala (Abb. 2.1 unten) zeigt ein Manikin, welches in der Größe wächst und somit eine Form von Dominanz ausdrückt. Die Veränderung der Größe ist eine vereinfachte Art um Dominanz zu zeigen. Die Dominanz wird auch mit Kontrolle gleichgesetzt.

Zusammenfassend bietet SAM die Möglichkeit die drei Dimensionen des VAD Modells (siehe 2.2.2) in Form eines Self-Assessments abzufragen. Diese Selbstaussagen können als weiteres Mittel der Verifikation der Messergebnisse, wie in [20] vorgeschlagen, genutzt werden. Der Vorteil dieser Methode besteht in der nonverbalen Abfragemöglichkeit. So können Varianzen durch eine Sprachunterschiede vermieden werden.




Abbildung 2.1.: Die drei Dimensionen der SAM 9-Punkte Skala:
Valence:oben, Arousal:mittig, Dominanz:unten[34].

2.3. Emotionserkennung in der Companion Technologie

Dieses Kapitel beschreibt die unterschiedlichen Modelle und Methoden die für die Abbildung und Messung von Emotionen verwendet werden. Es wird untersucht welches Modell am geeignetsten für diesen Versuchsaufbau und die verwendete Methode ist.

Es gibt mittlerweile viele Methoden, um Emotionen bei einem Menschen zu erkennen. Zur Emotionserkennung müssen unterschiedliche Faktoren mit einbezogen werden. Emotionserkennungsmethoden lassen sich in folgende drei Gruppen einordnen:

Gesichtsausdruck: Bei der Bildererkennung wird versucht, Emotionen anhand des Gesichtsausdruckes der Probanden zu erkennen. Ekman und Friesen[13] haben gezeigt, dass jedem der sechs Grundemotionen ein universeller Gesichtsausdruck zuzuordnen ist. Daraufhin wurde von den beiden das Facial Action Coding System (FACS)

erstellt. Dieses System beschreibt die möglichen Gesichtsausdrücke anhand der im Gesicht vorhandenen Muskelstrukturen. So lässt sich jeder Gesichtsausdruck mittels des FACS klassifizieren. Diese Erkenntnis macht das Auswerten der Gesichtsausdrücke zur Emotionserkennung möglich. Als Beispiel ist hier die Shore Bibliothek [16] vom Fraunhofer Institut zu nennen.

Spracherkennung: Bei der Spracherkennung werden die Emotionen anhand der Stimme des Probanden klassifiziert. Busso et al. haben in [8] gezeigt, dass eine Klassifikation von Emotionen durch die Auswertung von Sprachmerkmalen vielversprechend ist. Auch Nwe et al. haben in [27] hohe Erfolgsraten bei der Emotionserkennung mittels Sprachfeatures aufgezeigt. Als grundlegendes Tool für die Sprachauswertung ist die Social Signal Interpretation Toolbox [17] zu nennen. Diese Toolbox unterstützt neben der Spracherkennung von Emotionen auch eine Vielzahl anderer Sensoren wie Kameras, WiiMotes [26] und die Kinect [24].

Biopsychologische Klassifikatoren: Bei der Klassifikation der Emotionen durch biopsychologische Werte wird versucht den emotionalen Zustand des Menschen durch Messungen zu analysieren. Im Gegensatz zur Bild- und Tonverarbeitung, basieren diese Methoden oftmals nicht auf den sechs Grundemotionen sondern auf dem *valence-arousal-dominance (VAD)* Modell [36]. Diese lassen sich effizienter mit Biosensoren messen. Beispielsweise kann die Herzrate, der Hautwiderstand oder die Atemfrequenz gemessen werden um die Emotionen zu klassifizieren. In diesem Bereich lässt sich auch die Emotionserkennung durch die Beobachtung der Augen einordnen.

Besonders interessant ist in diesem Zusammenhang die Pupillengröße, da diese vom autonomen Nervensystem (ANS)[3] gesteuert wird. Das ANS steuert die unbewussten Nervenreaktionen und spiegelt somit die emotionalen Reaktionen wider.

Die Untersuchung der Augen ist wegen der Steuerung durch das ANS sehr vielversprechend. Dies liegt unter anderem daran, dass das ANS den unbewusst gesteuerten Teil des Nervensystems darstellt. Die Steuerung der Pupillengröße ist daher von Probanden nicht bewusst beeinflussbar. Daher lassen sich emotionale Reaktionen ungefiltert durch das Bewusstsein des Probanden klassifizieren.

Aus diesen Gründen wird die Klassifikation des emotionalen Zustandes durch die Beobachtung der Augen im folgenden Kapitel genauer analysiert.

2.4. Augen und Emotionen

Aus der Analyse der Augen mit einem Eyetracker haben sich mehrere Möglichkeiten zur Verbesserung der Emotionserkennung entwickelt.

Besonders interessant sind in dieser Beziehung die *Blickrichtung* und die *Pupillengröße* des Nutzers als Indikatoren des emotionalen Zustandes.

Blickrichtung: Die Blickrichtung eines Probanden kann zur Emotionserkennung beitragen. Diese kann leicht ermittelt werden. Aus der Position der beiden Augen zueinander können Rückschlüsse auf die Kopfeigung gezogen werden. Allgemein kann die Bewegung der Augen im Raum mit der Kopfbewegung assoziiert werden.

Alghowinem et al. haben herausgefunden, dass depressive Patienten dazu neigen keinen Blickkontakt zu halten und nach unten schauen

[2]. Des Weiteren zeigen depressive Patienten im Vergleich zu gesunden Kontrollgruppen weniger und langsamere Kopfbewegungen. Für solche Spezialfälle ist die Blickrichtung als Feature zur Emotionserkennung sehr gut geeignet.

Es gibt Paare von Emotionen (wie zum Beispiel *ärgerlich* und *ängstlich*), die beim Klassifizieren oft miteinander verwechselt werden. Die Erkennungsraten dieser Paare können mit einem Eyetracker verbessert werden. Zhao et al. haben gezeigt, dass sich die sechs Basisemotionen in gerichtete und ungerichtete Emotionen unterteilen lassen um diese Paare besser einzuordnen[39]. Die Angst ist beispielsweise eine ungerichtete Emotion. Ein ängstlicher Mensch neigt dazu, sich von der Quelle der Angst abzuwenden. Ist ein Mensch jedoch verärgert, neigt er dazu sich der Quelle des Ärgers zuzuwenden. Daher ist Ärger eine gerichtete Emotion.

Mithilfe eines Eyetrackers lässt sich z.B. feststellen ob der Nutzer den Bildschirm fokussiert oder den Blick abwendet. Diese Information kann zur Verbesserung der Emotionserkennung genutzt werden.

Pupillengröße: Die Pupillengröße ist ein weiteres Merkmal der Augen, dass zur Emotionserkennung ausgewertet werden kann. Es ist bekannt, dass sich Pupillen in einem Zustand von Stress, Aufregung oder Angst weiten. Babiker et al. haben gezeigt, dass die Änderung des Pupillendurchmessers Rückschlüsse auf den emotionalen Zustand des Nutzers zulässt[4].

Weiterhin wurde gezeigt, dass die Größe der Änderung mit der Valence aus dem VAD-Modell, also der Intensität der Emotion, korrelierbar ist [3]. Ein Zusammenhang von der Valence mit der Pupil-

lengrößenänderung ist umstritten, obwohl es Hinweise auf einen Zusammenhang zwischen Valence und der Dauer der Änderung der Pupillengrößen[3] gibt. Daher wird sich die Datenauswertung vorrangig mit der Klassifikation der Valence beschäftigen.

Um Informationen über die Änderungsrate des Pupillendurchmessers zu erhalten, ist ein Eyetracker gut geeignet. Dieser ist selbständig in der Lage den Durchmesser zu bestimmen. Die Änderungsrate der Pupillen lässt sich aus den gesammelten Daten bestimmen.

Die Verwendung der Pupillengröße als Mittel der Emotionserkennung im EmoBike Projekt ist eine vielversprechende Erweiterung für das Projekt. Die Erweiterung des EmoBike Projektes durch einen Eyetracker wird in Kapitel 3.2 genauer betrachtet. Im folgenden Kapitel 2.7 wird geprüft wie die Daten im Hinblick auf die Emotionserkennung auszuwerten sind. Der Fokus liegt hierbei auf der Pupillengröße und deren Änderungsrate.

2.5. Emotionsinduktion

Dieses Kapitel beschreibt verschiedene Möglichkeiten, um die gewünschten Emotionen in einem Probanden hervorzurufen. Um eine sinnvolle Auswertung der Messdaten zu ermöglichen, muss eine Methode gefunden werden um den gewünschten emotionalen Zustand hervorzurufen. Darauf hin können die gewünschten Daten gemessen und ausgewertet werden. Diese sogenannte Emotionsinduktion kann auf unterschiedliche Arten erzeugt werden. Dem Probanden können Audiosignale, Bilder oder Videos gezeigt werden, die eine bekannte emotionale Reaktion haben. Weiterhin kann der Proband in einer virtuellen Umgebung durch wohldefinierte

2. Analyse

Events beeinflusst werden. Eine weitere Möglichkeit besteht darin, dass der Proband durch gezielte Befragung beeinflusst wird. Zusammenfassend bilden sich folgende Arten der Emotionsinduktion heraus:

1. **Befragungen:** Bei der Untersuchung von Depressionen haben Alghowinem et al. Emotionen durch bestimmte Fragen hervorgerufen. Ein Beispiel für so eine Frage ist: "Was war das letzte fröhliche/traurige Ereignis in ihrem Leben". Der Proband denkt dadurch an dieses Ereignis und die entsprechende Emotion wird hervorgerufen.
2. **Visuelle Stimulation:** Für diese Art der Stimulation können dem Nutzer Bilder mit einer vorher klassifizierten emotionalen Reaktion gezeigt werden. Dadurch lässt sich die selbst klassifizierte Reaktion mit den bekannten Daten verifizieren. Ein Beispiel für eine solche Bilddatenbank ist das *International Affective Picture System(IAPS)* [18].
Weiterhin gibt es Datenbanken mit Wörtern[6] und deren emotionaler Klassifikationen. So kann der Proband durch einen vorgefertigten Text zu einer gewünschten Reaktion gebracht werden.
3. **Auditive Stimulation:** Der Proband kann durch Audiosignale emotionale beeinflusst werden. Auch in diesen Bereich gibt es Datenbanken mit klassifiziertem Material. Als Beispiel ist hier die *International Affective Digital Sounds(IADS)*[7] zu nennen. Diese Datenbank enthält unter anderem Klassifikationen von Babygeräuschen, Katzen, Schüssen oder einer weinenden Frau.
4. **Audiovisuelle Stimulation:** Eine Stimulation der audiovisuellen Art kann zum Beispiel durch Videos erzeugt werden. Gross und Le-

venson haben in [15] Ausschnitte aus bekannten Filmen klassifiziert. Diese Ausschnitte können als Basis einer Audiovisuellen Stimulation genutzt werden.

Eine virtuelle Welt kann ebenfalls gewünschte Emotionen triggern[25]. Durch gezielte audiovisuelle Events (s. Kapitel 3.3) in der virtuellen Umgebung kann der Proband emotional beeinflusst werden.

Da das EmoBike Projekt bereits über eine virtuelle Umgebung verfügt, die in der Lage ist gewünschte Events darzustellen, wird der Ansatz der audiovisuellen Emotionsinduktion mittels einer virtuellen Umgebung genutzt.

2.6. Data Mining

Der Begriff *Data Mining* umfasst Methoden um sinnvolle Informationen aus riesigen Datenmengen herauszufiltern[9]. Die Datenmengen sind mit konventionellen Mitteln und Auswertungen nicht mehr handelbar. Es wurden verschiedene Prozesse entwickelt, um die Datenmengen erfolgreich auswerten zu können.

Zwei Beispiele für diese Prozesse sind der *CRISP-DM Prozess* (*Cross Industry Standard Process for Data Mining*) und der *KDD-Prozess* (*Knowledge Discovery in Databases*). Laut *Cleve und Lämmel* beschreibt das *CRISP-Modell* eher die Sicht der Industrie auf das *Datamining* und der *KDD-Prozess* hat einen Fokus auf die eigentliche Datenbereitstellung und Analyse[9, S.8]. Daher wird in dieser Arbeit der *KDD-Prozess* genutzt.

2.6.1. KDD-Prozess

KDD-Prozess(Knowledge Discovery in Databases Prozess) wird anhand der Spezifikation von Cleve und Lämmel[9] beschrieben. Der Prozess besteht aus den folgenden fünf Schritten:

1. **Datenselektion:** Dieser Schritt bezieht sich auf die Auswahl der auszuwertenden Daten. Die gewünschten Daten müssen aus der Quelle extrahiert und für die Verarbeitung bereitgestellt werden. Dies kann unter anderem auch externe Daten, die für die Auswertung interessant sein können, mit einbeziehen. Allgemein wird geprüft, welche Daten vorhanden und welche Daten für eine sinnvolle Auswertung notwendig sind. Es kann vorkommen, dass technische oder rechtliche Beschränkungen einer kompletten Datenkopie entgegenstehen. In diesem Fall ist eine repräsentative Teilmenge auszuwählen.
2. **Datenvorverarbeitung:** In diesem Schritt werden die abgezogenen Daten auf ihre Qualität hin untersucht. Aufgrund von technischen oder menschlichen Fehlern können die extrahierten Daten fehlerhaft sein. Laut Cleve und Lämmel kann von einer Fehlerrate von bis zu 5 % ausgegangen werden. Insbesondere sind in diesem Zusammenhang Datenlücken und Ausreißer zu nennen. Fehlende Werte können beispielsweise mit interpolierten Werten gefüllt werden. Bei Ausreißern muss entschieden werden ob dies korrekt gemessene Werte sind und somit in die Analyse mit eingehen sollten oder ob es sich um falsche Messwerte handelt, die herausgefiltert werden müssen.

3. **Transformation:** Da sich die Rohdaten in ihrer ursprünglichen Form oft nicht zur Analyse eignen, müssen diese entsprechend transformiert werden. Ein weiterer Grund für die Transformation ist, dass viele Analysemethoden spezifische Anforderungen an das Datenformat haben. Weiterhin können durch die Transformation invariante Darstellungsformen der Daten erstellt werden um eine allgemeinere Analyse zu erstellen. Auch eine Reduktion der Datendimension durch Weiterverarbeitung von einigen Attributen kann der Analyse helfen. Dies kann zum Beispiel durch Aggregation von Attributen oder durch Wertintervallbildung erreicht werden.
4. **Data Mining:** Die Daten liegen nun in der gewünschten Qualität und Form vor und es kann damit begonnen werden, die Data Mining Aufgabe genauer zu spezifizieren. Es muss entschieden werden, welche Art von Data Mining Verfahren sinnvoll anzuwenden sind, beispielsweise Klassifizierungs- oder Cluster-Bildungs-Verfahren. Anhand dieser Entscheidung kann ein geeignetes Data Mining Verfahren ausgewählt werden um die Aufgabe zu lösen. Diese wird entsprechend mithilfe der geforderten Parameter für die Aufgabe konfiguriert. Dies kann z.B. die Festlegung von Gewichtungsfaktoren für die Eingangsdaten beinhalten. Das mithilfe der Analyseverfahren erzeugte Datenmodell wird dann als Grundlage für die Datenbewertung im nächsten Schritt genutzt.
5. **Interpretation und Evaluation:** Dieser Schritt wird genutzt um die entdeckten Muster in den Daten zu interpretieren. In diesem Bereich ist Fachwissen zu den auszuwertenden Daten hilfreich, sodass die gefundenen Muster in einen sinnvollen Kontext gesetzt werden.

Diese fünf Schritte sind als Empfehlung anzusehen. In der Realität hat sich gezeigt, dass sich die Schritte teilweise überschneiden oder nach neuen Erkenntnissen wiederholt werden müssen.

2.7. Datenauswertung

Dieses Kapitel beschreibt wie die Daten der Pupillengrößen ausgewertet werden müssen, um im Bereich der Companion Technologie sinnvoll genutzt zu werden. Die Companion Technologie baut auf einem emotionalen Dialog zwischen Nutzer und Companion auf. Hierzu muss der Companion in der Lage sein, die Emotionen des Nutzers zu erfassen und darauf zu reagieren. Diese Arbeit befasst sich mit dem ersten Teil dieser Anforderung, also dem Erfassen der Emotionen des Nutzers.

Das System muss in der Lage sein, die Emotionen des Nutzers zu klassifizieren. Es muss gezeigt werden, dass ein hinreichend großer Unterschied zwischen den emotionalen Zuständen messbar ist. In diesem Bereich gibt es verschiedene Ansätze die sich in zwei Gruppen unterteilen lassen:

- **Lernende Algorithmen:** Diese Algorithmen beruhen darauf, dass ein System mithilfe von vorher klassifizierten Daten trainiert werden kann um folgende Daten automatisch auswerten zu können. Dies setzt eine entsprechend große Datenmenge voraus und die Möglichkeit einen Teil der Daten von Hand zu bewerten. In [27, 36, 8] wurden erfolgreich lernende Modelle angewendet. Unter anderem wurden Neuronale Netze und Support Vektor Maschinen genutzt.
- **Funktionale Analyse:** Diese Methoden nutzen mathematische Analysemethoden, um die Messdaten funktional auszuwerten. Bei-

spielsweise können lokale Minima und Maxima oder die Steigung der Messkurve zur Analyse und Klassifikation herangezogen werden.

Babiker et al. haben gezeigt, dass auch eine funktionale Analyse der Pupillengrößen zur Klassifikation der Emotionen genutzt werden kann[3]. Es wurden statistische Werte wie der Durchschnitt und die Varianz ausgewertet. Durch die Auswertung der Steigung, der Minima und der Maxima der Messkurve wurden die Daten zusätzlich funktional analysiert.

Beide Gruppen von Klassifizierungsmethoden sind vielversprechend. Die vorhandene Datenmenge ist für eine Entscheidung zwischen den beiden Gruppen sehr relevant. Wenn zu wenig Daten vorliegen kann es sein, dass die lernenden Algorithmen zu wenig Trainingsdaten zur Verfügung haben, oder dass zu wenig Daten für die Überprüfung des Trainingsergebnisses vorhanden sind. Dies muss bei einer Entscheidung berücksichtigt werden.

2.8. Zusammenfassung der Anforderungen

Dieses Kapitel beschreibt die Anforderungen an den Versuchsaufbau, die sich aus der Analyse ergeben. Insbesondere wird auf die Erfassung der Daten aus der Beobachtung der Augen eingegangen. Folgende Anforderungen sind zu erfüllen:

- **Beobachtung der Augen:** Der EmoBike Projektaufbau muss so erweitert werden, dass die Bewegung der Augen und die Änderung der Pupillengröße des Probanden erfasst werden können.

2. Analyse

- **Versuchsaufbau:** Der Versuchsaufbau muss so gestaltet werden, dass ein Zusammenhang zwischen induzierten Emotionen, Pupillengröße und daraufhin klassifizierten Emotionen hergestellt werden kann. Die Zeitpunkte der induzierten Emotionen und der Messdaten müssen vergleichbar sein.
- **Datenauswertung:** Die Daten müssen automatisiert verarbeitet werden. Dies bedeutet, dass die Klassifikation der Emotionen ohne Hilfe durch den Menschen erfolgen muss. Hierfür muss gezeigt werden, dass Unterschiede zwischen den emotionalen Zuständen messbar sind.

3. Versuchsaufbau

Dieses Kapitel beschreibt den Versuchsaufbau, der sich aus den Anforderungen der Analyse ergibt. Es wird das EmoBike Projekt beschrieben und wie der Aufbau anzupassen ist. Daraufhin wird erläutert, wie die virtuelle Umgebung genutzt wird, um Emotionen zu induzieren. Im Anschluss wird die Datenverarbeitung mittels des KDD-Prozesses zur Auswertung der Pupillengrößenänderung dargestellt.

3.1. EmoBike Projekt

Das EmoBike Projekt [30] der HAW Hamburg ist ein Forschungsprojekt im Rahmen der Companion Technologie. Das Projekt hat als Metapher die Unterstützung des Patienten bei therapeutischen Maßnahmen.

Momentan muss *ein* Arzt *einen* Patienten eine Stunde auf *einem* Ergometer betreuen. Es handelt sich um eine klassische eins zu eins Beziehung. Wenn das Ergometer den Arzt und den Patienten bei den Rehabilitationsmaßnahmen unterstützen könnte, wäre dies vorteilhaft. Ein Arzt könnte gleichzeitig mehrere Patienten betreuen oder der Patient erhält ein individuelleres und besser abgestimmtes Training.

Das EmoBike stellt so ein verbessertes Ergometer dar. Es muss in der Lage sein, sich individuell auf die Bedürfnisse des Nutzers einzustellen.

3. Versuchsaufbau

Hierzu muss das EmoBike den emotionalen Zustand des Nutzer erfassen, um entsprechend auf den Nutzer einzuwirken. Wenn der Nutzer sich zum Beispiel verausgabt, hat das EmoBike gegenzusteuern und eventuell das Training zu vereinfachen.

Hierfür wurde das EmoBike mit zusätzlichen Komponenten ausgestattet, unter anderem sind folgende Sensoren verbaut:

Lenk-, Brems- und Schaltungssensoren: Diese sind notwendig um auf das Fahrverhalten und das Training Einfluss nehmen zu können. Das EmoBike wurde um einen voll ausgestatteten Lenker erweitert, der drehbar ist.

Biopack: Das Biopack ist eine tragbare Sensoreinheit für Biosensoren. Es besteht unter anderem aus Sensoren für den Hautwiderstand, die Atmung oder den Puls. Mit diesem Sensorkpaket werden biopsychologische Werte gemessen.

Kinect: Die Kinect dient der Erfassung des Gesichtes und ermöglicht die Auswertung des Gesichtsausdruckes.

Visualisierung: Dem Nutzer wird eine virtuelle Trainingsumgebung bereitgestellt. So ist es möglich, dem Nutzer verschiedene Umgebungen zu präsentieren. Diese können unterschiedliche Emotionen induzieren. Diese Visualisierung wird in Kapitel 3.3 noch einmal genauer beschrieben.

Interpreter: Der Interpreter dient zum Verarbeiten der gesammelten Sensordaten.

Mit Hilfe dieser Komponenten sollen möglichst viele Daten über den Nutzer in Erfahrung gebracht werden um diesen in jeder Situation geeignet

unterstützen zu können. Die virtuelle Umgebung zusammen mit den Lenk-, Brems- und Schaltsensoren ermöglicht eine erhöhte Immersion.

Die unterschiedlichen Komponenten sind mithilfe einer Blackboard Architektur unter der Verwendung von ActiveMQ verbunden. Sämtlicher Austausch von Information zwischen den Komponenten läuft über das Blackboard ab. Eine logische Übersicht über die Komponenten des EmoBikes ist im Anhang A.4 zu finden. Die rot markierten Elemente in dieser Ansicht zeigen die im Rahmen dieser Arbeit hinzugefügten Komponenten.

In Kapitel 2.4 wurde festgestellt, dass eine Analyse der Augenbewegung und Pupillengröße mittels eines Eyetrackers eine sinnvolle Methode zur Emotionserkennung darstellt. Bisher gibt es keine umfassende Möglichkeit, die Augen des Patienten mit in die Untersuchung einzubeziehen. Daher muss der Projektaufbau des EmoBikes um einen Eyetracker erweitert werden um den Anforderungen der Analyse aus Kapitel 2.8 zu entsprechen. Diese Erweiterung wird im folgenden Kapitel 3.2 beschrieben.

3.2. Eyetracker Erweiterung

In diesem Kapitel werden die technischen Möglichkeiten des Eyetrackers beschrieben. Danach wird darauf eingegangen wie der Eyetracker in den bestehenden Projektaufbau integriert wird und welche Softwarekomponenten entwickelt werden mussten.

3.2.1. Eyetracker Hardware

Verwendet wird ein Tobii X120 Eyetracker[33]. Dies ist ein stationärer Eyetracker der eine Tracking Box (der Bereich in dem der Eyetracker die Augen erfassen kann) von 30x22x30cm besitzt. Dieser Eyetracker kann

3. Versuchsaufbau

mit einer Rate von bis zu 120Hz folgende Informationen in bis zu drei Koordinatensystemen ermitteln:

1. Koordinatensysteme:

- **Display Area Coordinate System (DACS):** Dieses Koordinatensystem ist zweidimensional mit dem Ursprung in der oberen linken Ecke des Bildschirms. In diesem Koordinatensystem werden üblicherweise die Blickpunkte angegeben.
- **User Coordinate System (UCS):** Ein dreidimensionales Koordinatensystem mit dem Ursprung im Eyetracker. Mit diesem Koordinatensystem kann die Position des Auges im Bezug zum Eyetracker ermittelt werden. Dieses Koordinatensystem ist beispielhaft in A.2 abgebildet.
- **Track Box Coordinate System (TBCS):** Ein dreidimensionales normalisiertes Koordinatensystem mit dem Ursprung in der vorderen rechten oberen Ecke der Tracking Box. Dieses Koordinatensystem dient zum Beispiel der Ausrichtung des Eyetrackers. So kann ermittelt werden ob der Eyetracker gut auf den Nutzer ausgerichtet ist. Für eine bildliche Darstellung siehe auch A.3.

2. Informationen:

- **Position des Auges:** Die Position des Auges steht sowohl im UCS als auch im TBCS zur Verfügung.
- **Aktueller Blickpunkt:** Der Blickpunkt wird normalerweise im DACS angegeben. Er steht auch im UCS zur Verfügung.

3. Versuchsaufbau

Dies ermöglicht eine einfache Berechnung der Blickrichtungsgeraden (diese entspricht der gepunkteten Linie in A.2).

- **Pupillendurchmesser:** Der Eyetracker liefert den aktuellen Durchmesser der beiden Pupillen. Eine Änderung der Pupillengröße kann Aufschluss über eine Änderung im emotionalen Zustand des Nutzers geben.
- **Validitätscode:** Dieser Code gibt Aufschluss über die Güte der gesendeten Daten. Je nach Code wird angezeigt, ob der Eyetracker beide, nur eins, oder keine Augen erkannt hat. Wenn nur ein Auge erfasst wurde, gibt der Code an, ob es sich um das rechte oder linke Auge handelt.
- **Timestamp:** Der Eyetracker synchronisiert sich automatisch mit dem verbundenen Gerät, so dass der Timestamp dazu dient den aktuellen Ereignissen auf dem Bildschirm die richtigen Daten zuzuordnen.
- **Frequenz:** Es wird angegeben in welcher Frequenz der Eyetracker Daten sammelt. Diese kann auf 60Hz oder 120Hz eingestellt werden.

Aus den gesammelten Informationen erschließen sich, wie in Kapitel 2.4 beschrieben, diverse Möglichkeiten die Emotionserkennung zu verbessern.

3.2.2. Eyetracker Software

Dieses Kapitel beschreibt die Softwarekomponente, die entwickelt wurde um den Eyetracker zu steuern und die gesammelten Daten zu loggen.

3. Versuchsaufbau

Die Software baut auf der QT Bibliothek[28] Version 5.2 für C++ auf. Um den Eyetracker ansprechen zu können wurde das Tobii Analytics SDK[31] in der Version 3.0.83 für Linux genutzt. Für die Entwicklung der Eyetracker Softwarekomponente wurde das bestehende *QT Eyetracking Sample* aus dem Analytics SDK erweitert und an die neuen Anforderungen angepasst:

ActiveMQ[14] Anbindung: Es wurde unter der Verwendung der EmobikeLib ein Adapter für ActiveMQ hinzugefügt. So ist eine Kommunikation mit dem Control Center und der Visualisierungskomponente möglich.

Das Control Center informiert die Komponenten über den Start einer Messung und über einen Levelwechsel. Die Visualisierungskomponente stellt die notwendigen Informationen über das Auftreten von Levelvents und deren Zeitpunkte bereit. Diese sind in Kapitel 3.3 noch einmal genauer beschrieben.

Zusätzlich stellt die Eyetracker Komponente die gemessenen Daten anderen Komponenten über die ActiveMQ zur Verfügung.

Datenlogger: Zusätzlich zur Anbindung an die ActiveMQ muss die Eyetracker-Komponente in der Lage sein die Mess- und Eventdaten lokal in eine Datei anzulegen. Der Dateiname erfolgt nach einem festgelegten Muster und wird vom Control Center mitgeteilt. Die Daten werden in zwei CSV Dateien abgelegt.

Ein Eintrag in der Eyetrackerdatendatei besteht aus den folgenden Feldern: *timestamp*, *eyepositions-3d*, *validitycodes*, *eyepositions-3d-relative*, *gaze-points-3d*, *gaze-point-2d*, *left-pupil-diameter*, *right-pupil-diameter*.

3. Versuchsaufbau

Es werden alle Daten geloggt, die der Eyetracker zur Verfügung stellt. Für die Auswertung in dieser Arbeit sind nur der Timestamp, die Pupillengröße und die Validitätscodes interessant.

Die Eventdatendatei besteht aus folgenden Feldern: *Timestamp*, *Level*, *Event*. In dieser Datei werden die vom Spiel erzeugten Levelvents (siehe Kapitel 3.3) zusammen mit dem Zeitpunkt ihres Auftretens gespeichert.

Das Zwischenspeichern in CSV Dateien ermöglicht eine einfache Weiterverarbeitung der Daten, mit zum Beispiel Matlab. Diese Auswertung wird in Kapitel 3.5 beschrieben.

Zeitsynchronisation: Um eine sinnvolle Datenanalyse zu gewährleisten, muss dafür gesorgt werden, dass die Zeitpunkte der auszuwertenden Daten aus den unterschiedlichen Quellen vergleichbar sind. Die Komponenten liegen teilweise auf verschiedenen Systemen mit unterschiedlichen internen Uhren. Die virtuelle Umgebung und der Eyetracker werden auf verschiedenen Systemen betrieben.

Um die Uhren der unterschiedlichen Systeme synchron zu halten, wurde ein eigener Zeitserver eingerichtet. Die Systeme wurden so konfiguriert, dass die internen Uhren in regelmäßigen Abständen über diesen Zeitserver synchronisiert werden.

So ist eine Vergleichbarkeit der Zeitpunkte der Levelvents und der Zeitpunkte der Eyetracker Datenpakete mit einer hinreichenden Genauigkeit sichergestellt. Auf diese Weise wird ein Auseinanderlaufen der Uhren aufgrund von leicht unterschiedlichen Geschwindigkeiten verhindert.

3. Versuchsaufbau

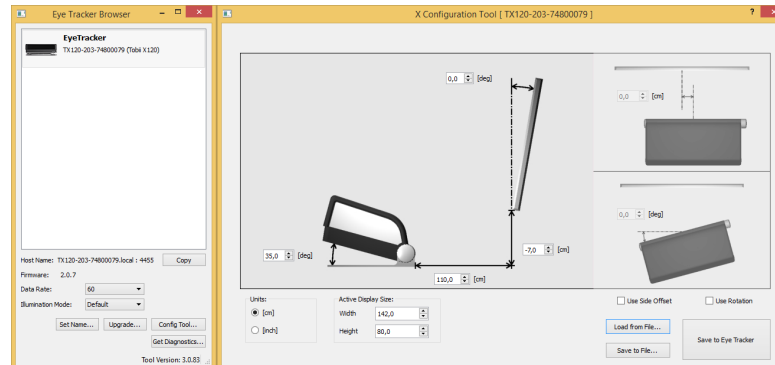


Abbildung 3.1.: Eyetracker Browser (links) und Config Tool (rechts)

Da die Darstellung der virtuellen Umgebung auf einem separaten System in einer Windowsumgebung erfolgt, mussten zusätzlich zu der entwickelten Eyetrackerkomponente für Linux zwei weitere Tools aus dem Tobii Analytics SDK für Windows genutzt werden, um den Eyetracker zu konfigurieren und zu kalibrieren:

1. **Konfiguration mit dem Eyetracker Browser:** Der Eyetracker Browser liegt dem Tobii Analytics SDK bei. Mit diesem Tool ist es möglich, alle Eyetracker, die sich im gleichen Netzwerk befinden, anzuzeigen und zu konfigurieren. Nachdem der Eyetracker im Versuchsaufbau platziert wurde, muss die Position des Eyetrackers im Bezug zum Bildschirm ausgemessen werden. Diese Informationen werden mithilfe des Eyetracker Browser Config Tools im Eyetracker hinterlegt. Die Abbildung 3.1 zeigt links den Eyetracker Browser mit dem der gewünschte Eyetracker ausgewählt werden kann. Rechts ist das Config Tool mit den aktuellen Einstellungen für den Eye-

3. Versuchsaufbau




Abbildung 3.2.: Beispiel einer Eyetracker Kalibrierung[31]

trackeraufbau zu sehen. Diese müssen bei Neupositionierung des Eyetrackers angepasst werden.

2. **Kalibrierung mit dem Eyetracker Sample:** Damit der Eyetracker hinreichend genaue Daten liefern kann, muss dieser für jeden Probanden neu kalibriert werden. Dies erfolgt durch eine Fünf-Punkt-Kalibrierung. Der Proband muss nacheinander auf fünf Punkte auf dem Bildschirm gucken. Da die Position der Punkte auf dem Bildschirm dem Eyetracker bekannt sind, können diese mit dem aufgenommenen Blickpunkten des Probanden verglichen werden. So kann der Eyetracker einen Fehlerkorrekturwert errechnen, um die Genauigkeit einer späteren Datenaufnahme für diesen Probanden zu erhöhen. Das Ergebnis mit den Fehlerkorrekturwerten für die Blickpunktdaten als grüner und roter Vektor wird in Abbildung 3.2 beispielhaft dargestellt.




Abbildung 3.3.: Physische Übersicht des EmoBike Projektes inklusive Eye-tracker Erweiterung

3.2.3. EyeTracker Integration

Dieses Kapitel beschreibt wie der EyeTracker in den bestehenden Versuchsaufbau eingefügt wird. Der Fokus liegt hierbei auf der Platzierung des EyeTrackers im Versuchsaufbau, da die technische Integration der Software bereits in Kapitel 3.2.2 beschrieben wurde.

Die beste Position für den EyeTracker ist direkt vor dem Lenker des Ergometers (siehe 3.3), so dass das Blickfeld auf die virtuelle Umgebung nicht eingeschränkt wird. Der Kopf des Probanden muss innerhalb der Tracking Box (siehe A.3) liegen. Bei der Platzierung und Nutzung des EyeTrackers müssen folgende Regeln beachtet werden:

1. **Ausrichtung des EyeTrackers:** Die Höhe und der Winkel des EyeTrackers werden so eingestellt, dass der EyeTracker die Sicht auf den

3. Versuchsaufbau

Bildschirm nicht beeinträchtigt. Es muss darauf geachtet werden, dass der Eyetracker nahe genug am Probanden ist, damit dessen Augen in der Tracking Box liegen. Dies wird bei einer Entfernung von ca. 50-70cm erreicht.

2. **Entfernung zum Bildschirm:** Der Eyetracker kann laut Tobii Configuration Guide [32] Blickwinkel von 35° nach links, rechts und oben abdecken. Das ergibt horizontal einen Bereich von 70° und vertikal einen Bereich von 35°. Aus dieser technischen Beschränkung ergibt sich je nach Bildschirmgröße und Eyetrackerwinkel ein Mindestabstand zwischen Eyetracker und Bildschirm. Nur so kann garantiert werden, dass der Eyetracker alle Bereiche des Bildschirms abdeckt.

Der verwendete Bildschirm hat eine Größe von 142x80cm und bedingt durch den Aufbau und die Größe der Probanden wird der Eyetracker mit Winkeln von 30° bis 40° betrieben. Aus diesen Angaben berechnet der Tobii Configuration Guide einen Mindestabstand von 110cm zum Bildschirm. Dies ist im aktuellen Versuchsaufbau gegeben.

3. **Beleuchtung des Raumes:** Da der Eyetracker unter anderem mit Infrarot Sensoren arbeitet, führt direkte Sonneneinstrahlung zu verfälschten Messwerten.

In dieser Arbeit wird hauptsächlich die Pupillengröße betrachtet, welche stark Licht abhängig ist. Es muss eine gleichmäßige Beleuchtung mit künstlichem Licht sichergestellt werden. Ansonsten kann nicht unterschieden werden ob die Pupillengrößenänderung auf die Lichtverhältnisse oder eine emotionale Reaktion zurückzuführen ist.

3. Versuchsaufbau

4. **Sehhilfen:** Der Eyetracker berechnet die Pupillengröße anhand der Entfernung der Pupillen zum Eyetracker und der Größe im aufgenommenen Bild. Wenn ein Proband Kontaktlinsen oder eine Brille trägt, verfälscht dies die Messung der Pupillengröße. Die Linsen der Brille lassen die Pupillen auf dem Bild vergrößert oder verkleinert erscheinen. Dies wird vom Eyetracker nicht berücksichtigt.
5. **Make-Up:** Ein zu starkes Make-Up im Augenbereich kann sich negativ auf die Datenerhebung auswirken. Daher ist es wichtig, dass die Probanden für den Versuch kein Augen Make-Up tragen.

In Abbildung 3.3 ist der Aufbau des Eyetrackers gezeigt. Er wurde unter Beachtung der Regeln aus Punkt 1 und 2 aufgestellt. Der Versuchsaufbau befindet sich in einem Raum der abdunkelbar ist, so wird Sonneneinstrahlung verhindert und Punkt 3 berücksichtigt. Weiterhin stehen zusätzliche Strahler zur Verfügung, um den Versuchsaufbau hinreichend zu beleuchten.

Die Punkte 4 und 5 haben keinen direkten Einfluss auf den Versuchsaufbau, werden aber bei der Probandenauswahl berücksichtigt.

3.3. Virtuelle Umgebung

Dieses Kapitel beschreibt die unterschiedlichen Level und deren Levelents. Die Events sind so gestaltet (Mehr Informationen in [25]), dass diese bestimmte Emotionen beim Probanden induzieren sollen. Insgesamt werden sechs Level durchfahren, die sich wie folgt zusammensetzen:

Level 1: Das erste Level dient zur Einführung. Das Level beinhaltet eine längere gerade Strecke mit einer 90° Kurve am Ende. Nach der

3. Versuchsaufbau

Kurve kommt direkt das Ziel. Nach dem Erreichen des Zieles, ist das Level beendet. Der Proband kann sich in diesem Level an die Bedienung des EmoBikes gewöhnen und es können grundlegende Daten über den Probanden aufgezeichnet werden, die bei der Analyse als Normalwert genutzt werden können. Diese Daten spiegeln den emotionalen Grundzustand wider in dem sich der Proband zur Zeit des Versuches befindet. Weiterhin dient dieses Level der Gewöhnung an den Versuchsdurchlauf. So wird anfängliche Aufregung oder ähnliches abgemildert.

Level 2: Das zweite Level wurde so gestaltet, dass es grundsätzlich Fröhlichkeit im Probanden auslöst. Das Level ist hell und einladend gestaltet. Die Streckenführung ist genauso wie im ersten Level. Zusätzlich laufen kleine Teddybären über die Straße. Diesen muss der Proband ausweichen. Wenn ein Teddybär getroffen wird, löst dies ein **TeddyHit Event** aus, das virtuelle Fahrrad stoppt und der Teddy verschwindet. Dies soll ebenfalls eine positive emotionale Beeinflussung zur Folge haben.

Level 3: Dieses Level besteht aus einer geraden Straße. In der Mitte der Straße sind Warnkegel aufgestellt, so dass diese eine Slalomstrecke bilden. Dies soll den Probanden in einen konzentrierten Zustand versetzen. Entlang dieser Strecke sind Münzen verteilt, die der Proband einsammeln muss, um das Level erfolgreich beenden zu können. Wenn das Ziel ohne alle Münzen durchfahren wird, startet der Proband wieder am Levelanfang und muss dann die restlichen Münzen einsammeln. Wenn eine Münze eingesammelt wird, wird ein **Coin Event** erzeugt und die Münze zerfällt in fröhlich lachende Smileys.

3. Versuchsaufbau

Dies soll den Probanden erheitern und eine positive emotionale Reaktion hervorrufen.

Level 4: Das vierte Level soll den Probanden negativ stimmen. Der Weg zum Ziel führt einen schmalen Berggrücken entlang und durch eine scharfe Kurve. Nach einem darauf folgenden schwierigen Sprung kann das Ziel durchfahren werden. Der Sprung ist nur schaffbar, wenn der Proband über den Boost fährt, um das Fahrrad zu beschleunigen. Dies erzeugt ein **Boost Event**. Darauf hin muss eine schmale Rampe überfahren werden um auf die nächste Insel mit dem Ziel zu gelangen. Verfehlt der Proband die Zielinsel und fällt er in den Abgrund, wird ein **Falling Event** ausgelöst. Das Falling Event soll den Probanden in einen negativen Zustand in Form von Frust und Ärger versetzen. Das Level ist so schwierig gestaltet, dass es mehrmals durchfahren werden muss um es erfolgreich zu beenden. Dies erhöht den Frustrationsfaktor mit jedem weiteren Leveldurchlauf.

Level 5: Das fünfte Level dient ebenfalls dazu, den Probanden negativ zu beeinflussen. Zuerst muss eine Steigung überwunden werden. Während die Steigung überwunden wird, ist der Tretwiderstand des Ergometers stark erhöht. Je nach Fitnessgrad des Probanden führt dies zu einer negativen emotionalen Beeinflussung. Kurz nach der Steigung wird der Proband durch eine plötzlich auftauchende Wand komplett gestoppt und dadurch wird ein **WallHit Event** ausgelöst. Dies trägt zur Frustration des Probanden bei. Weiterhin wird er nach diesem Event mit angreifenden Spinnen konfrontiert. Wenn eine Spinne den Probanden attackiert, wird ein **SpiderAttack Event**

3. Versuchsaufbau

erzeugt. Dies soll Stress, Frust und Angst des Probanden beeinflussen. Nach einer Linkskurve kann daraufhin das Ziel durchfahren werden.

Level 6: Das sechste Level dient dazu den Probanden zu erschrecken. In der virtuellen Umgebung ist es Nacht (Die Darstellung A.10 wurde aufgehellt, damit die Strecke sichtbar ist.) und der Proband folgt einer leuchtenden Münzspur. Das Einsammeln der Münzen erzeugt wie in Level 3 ein **Coin Event**. Am Ende der Münzspur ist das Ziel in Form eines leuchtenden Brunnens zu sehen. Kurz bevor das Ziel durchfahren wird, wird ein Schreckensmoment erzeugt. Es tauchen direkt vor dem virtuellen Fahrrad schreckliche Gestalten auf und ein lauter Schrei wird als Audiosignal ausgegeben. Dieses löst ein **Scare Event** aus. Dieses Event soll den Probanden in einen negativen emotionalen Zustand versetzen. Direkt nach diesem Event wird das Level mit der Ankunft an dem leuchtenden Brunnen beendet.

Tabelle 3.1 beinhaltet eine zusammenfassende Übersicht der Level inklusive ihrer Events und den emotionalen Reaktionen. Weiterhin sind die Level übersichtlich im Anhang A.5 bis A.10 abgebildet.

3.4. Self-Assessment

Dieses Kapitel beschreibt die Befragung der Probanden. Diese Art der Datenerhebung ist sinnvoll, um eine weitere Validierung der Messdaten zu erhalten. Es kann geprüft werden ob ein Zusammenhang zwischen Messdaten und Level events besteht. Dieses Ergebnis kann mit der Self-Assessment Befragung verglichen werden.

3. Versuchsaufbau

Level Id	Events	emotionale Reaktion
1	-	-
2	TeddyHit	positiv: Freude
3/6	Coin	positiv: Freude/Überraschung
4	Boost	positiv: Freude/Überraschung
4	Falling	negativ: Frust/Ärger
5	WallHit	negativ: Erschrecken/Frust
5	SpiderAttack	negativ: Erschrecken/Frust/Angst
6	Scare	negativ: Erschrecken/Angst

Tabelle 3.1.: Übersicht der Levevents mit emotionaler Reaktion (Darstellung der Events in Abbildung A.11)




Abbildung 3.4.: SAM mit angepasster Skala[34]

Das Self-Assessment des emotionalen Zustandes erfolgt mithilfe von SAM (siehe Kapitel 2.2.3 und Abbildung 2.1). Für jede der drei Dimensionen des VAD (Kapitel 2.2.2) wird eine Bildreihe dargestellt. Diese bildliche Beschreibung der Emotionen hat den Vorteil, dass keine Missverständnisse durch verbale Befragung entstehen. Weiterhin ist diese Befragung schnell und ohne großen Aufwand durchführbar. Daher ist sie geeignet, um nach jedem Level durchgeführt zu werden.

So kommt pro Proband und pro Level ein Datensatz mit einer VAD-Bewertung zustande. Die Skala wurde so ausgelegt, dass der Mittelpunkt als neutrale Null gilt. So ist eine Abstufung von -4 bis 4 möglich. Es wurde

den Probanden mitgeteilt, dass die Mitte den neutralen Zustand darstellt. Diese Skala ist beispielhaft in Abbildung 3.4 anhand der Arousal Bilderreihe dargestellt. Ein vollständiger Fragebogen für einen Level ist im Anhang A.1 abgebildet.

3.5. Datenauswertung im KDD Prozess

Dieses Kapitel beschreibt, wie die Pupillengrößendaten klassifiziert werden können. Um eine strukturierte Auswertung zu ermöglichen, wird der KDD Prozess angewendet. Dieser Prozess wird anhand der fünf Schritte des KDD Prozesses erläutert. Als Tool zur Datenauswertung wird Matlab[22] genutzt, da es vielseitige Möglichkeiten der Datenanalyse bietet und Erfahrungen mit diesem Tool vorhanden sind.

3.5.1. Datenselektion

Die Eyetrackerdaten werden während eines Versuches direkt in ein Textdokument im CSV Format gespeichert. Laut technischer Spezifikation liefert der Eyetracker (siehe Kapitel 3.2) folgende Daten mit einer Geschwindigkeit von bis zu 120 Hz: Position des Auges, aktueller Blickpunkt auf dem Display, Pupillendurchmesser beider Augen, Validitätscode und Timestamp. Der Zeitpunkt der unterschiedlichen Levelvents (Übersicht in Tabelle 3.1) wird jeweils separat in einem weiteren Dokument im CSV Format gespeichert. Jeder Eintrag besteht aus einem Timestamp, dem aktuellen Level und dem Eventnamen. Für die Auswertung eines Levels müssen daher pro Proband Daten aus zwei Dokumenten extrahiert werden.

3.5.2. Datenvorverarbeitung

In der Datenvorverarbeitung wird entschieden in welcher Form die Daten weiterverarbeitet werden und wie die Daten in die gewünschte Form gebracht werden.

Wie bereits in Kapitel 2.4 beschrieben, wird in dieser Arbeit der Fokus auf die Pupillengröße gelegt. Die Position der Augen und der Blickpunkt auf dem Display sind in diesem Zusammenhang vernachlässigbar und können daher weggelassen werden. Der Timestamp ist wichtig, um die Eyetrackerdaten mit den Events in den EmoBike Levels in Bezug zu setzen. Anhand des Validitätscodes können weitere Daten herausgefiltert werden. In den folgenden Schritten sollen nur Daten mit dem Validitätscode 0 weiterverarbeitet werden. Dies bedeutet, dass beide Augen sicher erkannt worden sind.

Babiker et al. haben in [4] gezeigt, dass sich der Pupillendurchmesser des linken und rechten Auges als Mittelwert zusammenfassen lassen, da sich die beiden Augen in den Versuchen sehr ähnlich verhalten haben. Dies hat den Vorteil, dass so ein Ausgleich von Messungenauigkeiten möglich ist und dass die Dimension der auszuwertenden Daten durch das Zusammenfassen geringer ist.

Da der Proband während der Messungen auf dem EmoBike aktiv ein Ergometer bedient, kommt es aufgrund der Bewegungen zu Messausfällen. Fehlende Messwerte werden durch Interpolation ausgeglichen. Interpoliert wird mit dem linearen Interpolationsverfahren von Matlab mithilfe der $\text{interpl}(X, Y, XQ)$ Funktion. Der X-Vektor enthält die Timestamps, der Y-Vektor die Pupillendurchmesser und der XQ-Vektor die gewünschten in-

3. Versuchsaufbau

terpolierten Punkte. Für XQ wurde eine Schrittweite von $16666 \mu s$ gewählt. Dieser Wert kommt wie folgt zustanden:

$$\text{Daten werden mit 60Hz gesendet: } \frac{60 \text{ Werte}}{1 \text{ s}} \quad (3.1)$$

$$\text{Timestamps sind in Microsekunden: } \frac{60 \text{ Werte}}{1000000 \mu s} \quad (3.2)$$

$$\text{Abstand zwischen den Werten: } \frac{1 \text{ Wert}}{16666,7 \mu s} \quad (3.3)$$

Weiterhin wird die Messkurve unter Verwendung eines gleitenden Mittelwertes geglättet, um Messungenauigkeiten durch die Bewegung des Probanden auszugleichen. Hierfür wird ein 1-D Filter in Matlab verwendet. Der Filter entspricht folgender Gleichung:

$$y(n) = \frac{1}{windowSize} (x(n) + x(n-1) + \dots + x(n - (windowSize - 1))) \quad (3.4)$$

Als *windowSize* wird 30 verwendet, was bei einer Aufnahme Frequenz von 60Hz einer halben Sekunde entspricht. Ein Beispielergebnis dieser Methoden ist in Abbildung 3.5 zu sehen.

Zusätzlich werden gleichartige Events, die enger als eine Sekunde zusammen liegen, herausgefiltert. Diese ungewollte wiederholten Events werden nicht ausgewertet. Es wird nur das erste Event verwendet.

Die Daten werden zusammengefasst wie folgt aufbereitet:

- Nur Datenpakete mit einem Validitätscode von 0 (beide Augen wurden erkannt).
- Nur der Timestamp und die beiden Pupillengrößen werden extrahiert.

3. Versuchsaufbau




Abbildung 3.5.: Oben: Pupillengrößendurchschnitt vom linken und rechten Auge
Unten: Anwendung der Interpolation (Orange) und des gleitenden Mittelwertes (Blau)
Horizontale Linie: Falling Event (Magenta)

3. Versuchsaufbau




Abbildung 3.6.: Transformation eines Falling Events

- Durchschnitt der beiden Pupillengrößen pro Datenpaket.
- Glättung der Kurve durch gleitenden Mittelwert.
- Fehlende Messwerte werden mit linearer Interpolation berechnet.
- Eng beieinander liegende gleichartige Events werden herausgefiltert.

3.5.3. Datentransformation

Für den ersten Schritt in der Datentransformation ist eine Normierung des Pupillendurchmessers auf den Bereich null bis eins sinnvoll. Dies entspricht einer prozentualen Darstellung. So werden spezifische Unterschiede in den Maximal- und Minimalwerten der Pupillengröße angeglichen.

Die Reaktion auf ein emotionales Ereignis wird innerhalb der nächsten 1-3 Sekunden in einer Pupillengrößenänderung sichtbar [10, 4, 38]. Die Daten werden in Pakete aufgeteilt. Da die emotionale Reaktion 1-3 Sekunden nach

dem Ereignis auftritt, müssen bis zu 3 Sekunden nach einem Levevent berücksichtigt werden. Damit geprüft werden kann, ob das Levevent für die Reaktion verantwortlich ist, müssen auch Daten vor dem Event ausgewertet werden. Auch hier ist ein Bereich von 3 Sekunden sinnvoll. Die Daten werden daher in Abschnitten von 6 Sekunden mit dem Event in der Mitte betrachtet. So ist ein sinnvoller Vorher-Nachher-Vergleich möglich und es kann geprüft werden, ob eine Reaktion der Pupillen auf ein Levevent erfolgt ist. Diese Datentransformation ist in Abbildung 3.6 anhand eines Falling Events in Level 4 dargestellt.

3.5.4. Data Mining

Durch das Data Mining soll nachgewiesen werden, dass die Levevents mit einer Veränderung der Pupillengröße in Zusammenhang stehen. Es muss eine Möglichkeit gefunden werden, um die Daten der Vorher- und Nachher-Pakete sinnvoll zu reduzieren und sie vergleichen zu können. Dies wird mit dem Durchschnitt des jeweiligen Pakets erreicht. Es wird der Durchschnitt der 3 Sekunden vor dem Event und der Durchschnitt der 3 Sekunden nach dem Event berechnet.

Insgesamt werden pro Event die Werte aller Probanden zusammengefasst aufgenommen. So können die Messungen aller Probanden für ein Event auf signifikante Änderungen hin untersucht werden.

3.5.5. Evaluation & Interpretation

In diesem Abschnitt wird erläutert mit welchen Methoden die Data Mining Ergebnisse aus dem Abschnitt 3.5.4 ausgewertet und verglichen werden. Aus dem vorherigen Schritt liegen die Daten als 3-Sekunden-Pakete und als

3. Versuchsaufbau

Durchschnittswerte pro Event vor. Es wird ein abhängiger t-Test[29] der Vorher- und Nachher-Durchschnittswerte ausgeführt um zu zeigen, dass zwischen den Datensätzen ein signifikanter Unterschied besteht. Weiterhin wird untersucht, ob der Pupillendurchmesser angestiegen oder gefallen ist.

Ein t-Test benötigt eine hinreichend große Werteanzahl. Da diese Arbeit eine Vorstudie darstellt, ist zu erwarten, dass für einige Events nur wenig Messwerte vorhanden sind. Wenn ein entsprechend großer Effekt erwartet wird, ist auch eine extrem kleine Anzahl ($N \leq 5$) ausreichend [11].

Das erste Level (Abbildung A.5) enthält keine Levelentscheidungen und soll als negatives Beispiel dienen. Wenn der Proband in der Mitte des Levels ist, ist die anfängliche Aufregung verflogen und die Vorfreude auf das nächste Level noch nicht präsent. In diesem Zeitraum sollte der t-Test keine signifikanten Unterschiede feststellen.

Wenn signifikante Unterschiede für mehrere Events gezeigt worden sind, bietet sich die Möglichkeit positive und negative Events zu vergleichen. So wird geprüft, ob mit dieser Methode ein Unterschied zwischen positiven und negativen Emotionen feststellbar ist.

Diese Auswertung kann in einem Boxplot[21] visualisiert werden. So können die Ergebnisse zusätzlich visuell verifiziert werden. So ein Boxplot ist in Abbildung 3.7 abgebildet. Links sind die Durchschnitte (rote Kreise) vor dem Event und rechts die Durchschnitte nach dem Event gekennzeichnet. Diese zusammengehörigen Paare sind mit einer roten Linie verbunden. Generell scheint es eine Tendenz zur Verkleinerung der Pupillengröße zu geben. Zusätzlich ist eine Anomalie mit einer vergrößerten Pupille zu sehen.

3. Versuchsaufbau




Abbildung 3.7.: Boxplot der Scare Events, links vorher, rechts nachher

Weiterhin werden die Ergebnisse der SAM Fragebögen zur Verifikation herangezogen. So können die Ergebnisse der Versuchsdatenauswertung mit den Selbsteinschätzungen der Probanden verglichen werden. Dadurch ist eine zusätzliche Verifikation der Auswertung möglich.

4. Versuchsdurchführung

Dieses Kapitel beschreibt, in welcher Form die Versuche mit den Probanden vorgenommen worden sind. Insgesamt wurden fünf verschiedene Probanden zu Versuchen eingeladen. Die Probanden waren im Alter von 25-30 Jahren und 3 waren männlich. 3 Probanden haben angegeben, dass sie sportlich sind und 3 Probanden verfügen über Erfahrungen im Computerspielbereich. Zusammengefasst sind die Informationen in Tabelle 4.1 dargestellt.

ID	Alter	Geschlecht	Sportlich?	Computerspielerfahrung
P1	30	m	ja	ja
P2	28	w	ja	nein
P3	30	m	ja	nein
P4	26	w	nein	ja
P5	25	m	nein	ja

Tabelle 4.1.: Informationen über die Probanden

Bei der Auswahl der Probanden wurde darauf geachtet, dass diese für den Versuch keine Sehhilfe brauchen und dass kein Make-Up getragen wurde. Zusätzlich wurde direkte Sonneneinstrahlung verhindert und der Raum mithilfe von Strahlern gleichmäßig beleuchtet. Durch das künstliche Licht wurden gleiche Lichtbedingungen für alle Probanden geschaffen.

4. Versuchsdurchführung

Diese Bedingungen sind aufgrund der Einschränkungen des Eyetrackers (s. Kapitel 3.2.3) notwendig, um möglichst gute Messergebnisse zu gewährleisten. Jeder Proband hat die Level 1 bis 6 (A.5 - A.10) in der nummerierten Reihenfolge durchfahren.

Nach jedem abgeschlossenen Level musste ein Fragebogen (A.1) ausgefüllt werden. Mithilfe der dargestellten SAM wurden die Valence, Arousal und Dominanz Werte abgefragt. Die Ergebnisse sind in Tabelle 4.2 zusammengefasst.

ID	Valence / Arousal / Dominance					
	Level 1	Level 2	Level 3	Level 4	Level 5	Level 6
P1	3/3/0	4/3/2	1/2/1	4/3/3	-1/2/-1	-2/1/-1
P2	2/0/1	3/0/0	1/1/-1	0/2/-2	-1/-1/-1	1/0/1
P3	1/-2/0	1/-2/0	1/-1/0	1/0/1	1/1/0	1/0/0
P4	1/0/0	3/1/1	2/1/1	-1/1/-1	2/2/1	3/2/2
P5	2/-1/0	2/1/1	1/3/-1	0/3/-3	0/3/0	0/3/1
Ø	1,8/0/0,2	2,6/0,6/0,8	1,2/1,2/0	0,8/1,8/-0,4	0,2/1,4/-0,2	0,6/1,2/0,6

Tabelle 4.2.: Ergebnis der SAM Self-Assessment-Befragung

Zwischen jedem Level wurde eine Pause von fünf Minuten eingelegt. In dieser Zeit wurde die Befragung durchgeführt, der Proband konnte sich erholen und sein emotionaler Zustand konnte sich normalisieren. Die Daten von Proband P4 zu Level 5 konnten nicht verwertet werden, da der Proband sich aufgrund der Anstrengung zu viel bewegt hat. Der Eyetracker konnte zu wenig relevante Daten aufnehmen.

Insgesamt wurden Daten zu den sieben unterschiedlichen Levelents und zusätzlich zur Mitte von Level 1 aufgenommen. Die Mitte von Level 1 soll, wie in Kapitel 3.5.5 beschrieben, als Gegenbeispiel dienen. Dadurch

4. Versuchsdurchführung

wird gezeigt, dass der Test fehlschlägt, wenn keine besonderen Einflüsse auf den Probanden einwirken. Da einige Events mehrfach vorkommen und einige Level mehrfach probiert werden mussten, gibt es unterschiedlich viele Mengen an Daten zu den einzelnen Events. Eine Übersicht ist in Tabelle 4.3 dargestellt. Zu beachten ist, dass das Coin Event von Level 3 und Level 6 getrennt betrachtet wird, da Level 6 in der Nacht stattfindet und somit komplett unterschiedliche Grundvoraussetzungen herrschen.

Level Id	Events	Anzahl Datenpakete
1	Levelmitte	5
2	TeddyHit	4
3	Coin	100
4	Boost	46
4	Falling	53
5	SpiderAttack	16
5	WallHit	3
6	Scare	5
6	Coin	92

Tabelle 4.3.: Übersicht der Events inklusive der auszuwertenden Datenpakete

Die Auswertungen der Coin, Boost und Falling Events sind besonders vielversprechend, da entsprechend viele Pakete vorliegen.

4.1. Auswertung

Dieses Kapitel beschreibt die eigentliche Auswertung der Messdaten aus der Versuchsdurchführung in Kapitel 4. Insgesamt werden 9 verschiedene Events auf ihre Signifikanz geprüft. Wichtig ist, dass die Aussagen einer

4. Versuchsdurchführung

Tendenz entsprechen, da in der Vorstudie nur fünf Versuchsdurchläufe gemessen worden sind. Trotzdem sind die Ergebnisse hilfreich, um den Mehrwert des Eyetrackers im EmoBike Projekt einschätzen zu können. Die Events und ihre Anzahl an gemessenen Datenpaketen sind in Tabelle 4.3 noch einmal dargestellt.

Als erstes wurde das Level 1 durchfahren. Dieses Level hat keine gesonderten Events und soll als negativ Beispiel des Testverfahrens dienen.

Die Abbildung 4.1 zeigt den Boxplot von den Datenpaketen zur Mitte von Level 1. Ein t-Test mit den Vorher- und Nachher-Durchschnittswerten fällt negativ aus. Dies bedeutet, dass die Nullhypothese H_0 (Die Vorher-Pakete unterscheiden sich signifikant von den Nachher-Paketen) abgewiesen wurde. Es konnte daher kein signifikanter Unterschied festgestellt werden. Die Ablehnungswahrscheinlichkeit liegt bei 50%. Das Levelmitte Event zeigt daher den gewünschten Effekt. Unter normalen Umständen, ohne Einflüsse auf den Probanden, ist kein signifikanter Unterschied feststellbar. Dies wird auch durch das durchschnittliche Arousal von 0 bei den Selbstaussagen gestützt.

Das TeddyHit Event, welches ausschließlich in Level 2 auftritt, wurde insgesamt sechs mal ausgelöst. Dieses Event soll den Probanden fröhlich stimmen, daher ist eine positive signifikante Änderung zu erwarten. Der Boxplot der Ergebnisse ist in Abbildung 4.2 dargestellt. Es ist zu erkennen, dass der Pupillendurchmesser sich bei fast allen Fällen gesteigert hat. Der t-Test für diese Werte fällt mit einer Ablehnungswahrscheinlichkeit von 14% trotzdem negativ aus, obwohl der Durchschnittswert der vorher und nachher Pakete sich deutlich unterscheidet. Der fehlgeschlagene t-Test bedeutet nicht, dass das Event keine Emotionen induzieren konnte oder dass die Messungen die Emotionen nicht erkannt haben. Der Fehlschlag zeigt,

4. Versuchsdurchführung




Abbildung 4.1.: Boxplot: Levelmitte Level 1

dass in dieser kleinen Versuchsgruppe keine hinreichenden Unterschiede zu verzeichnen waren. Der SAM Test zeigt im Durchschnitt ein Arousal von 0,6 für das zweite Level. Dies liegt nur knapp über der neutralen Null des SAM Tests. Dies stützt den fehlgeschlagenen t-Test.

Das Coin Event wird in Level 3 und Level 6 genutzt. Aufgrund der Levelunterschiede werden diese getrennt untersucht. Ein Coin Event soll einen positiven emotionalen Effekt auf den Probanden haben.

Im dritten Level wurden insgesamt 100 Coin Events erzeugt. Aufgrund der Häufigkeit der Coin Events und der Pflicht im dritten Level alle Coins einzusammeln, war eine hohe Eventanzahl zu erwarten. In Abbildung 4.3 ist der Boxplot der 100 Events dargestellt. Es ist keine Tendenz ersichtlich und die Durchschnittswerte liegen eng beieinander. Eine negativer t-Test ist zu erwarten. Der t-Test der Coin Events aus Level 3 schlägt mit einer Ablehnungswahrscheinlichkeit von 39% fehl.

4. Versuchsdurchführung

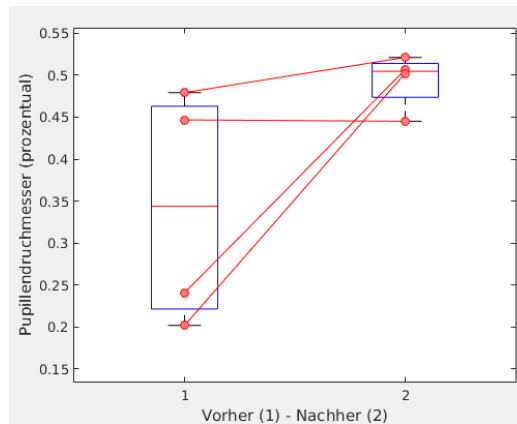


Abbildung 4.2.: Boxplot: TeddyHit Event

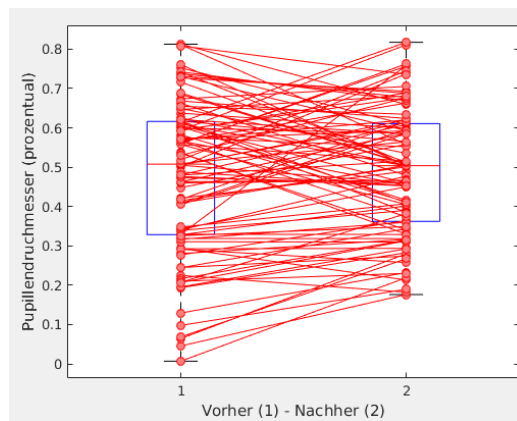


Abbildung 4.3.: Boxplot: Coin Events in Level 3

4. Versuchsdurchführung




Abbildung 4.4.: Boxplot: Coin Events in Level 6

Die Coin Events im sechsten Level wurden insgesamt 92 mal ausgelöst. Obwohl das Einsammeln der Coins keine Pflicht war, wurden nahezu alle möglichen Coins (92%) eingesammelt. Grund dafür könnte das trainierte Einsammeln aus Level 3 sein. Bei den Versuchen hat nur ein Proband die Coins ignoriert und sie nur zufällig eingesammelt. Auch der Boxplot in Abbildung 4.4 zeigt keine auffälligen Tendenzen und die Mittelwerte liegen eng zusammen. Wie bereits in Level 3 schlägt der t-Test mit einer Ablehnungswahrscheinlichkeit von 38% fehl. Level 3 und 6 haben im SAM Test ein durchschnittliches Arousal von 1,2. Dies ist doppelt so hoch wie in Level 2. Dies ist ein Hinweis auf einen Arousalanstieg, der in den Messwerten allerdings nicht nachgewiesen werden kann.

Im vierten Level treten die Boost und Falling Events dicht gefolgt voneinander auf. Das Boost Event wurde 46 Mal gemessen und das Falling Event 53 Mal. Drei der Probanden haben nach einigen Fehlversuchen versucht die Klippe ohne Boost zu überwinden.

4. Versuchsdurchführung




Abbildung 4.5.: Boxplot: Boost Events

Das Boost Event soll den Probanden überraschen. Daher wird eine positive emotionale Reaktion erwartet. Die Abbildung 4.5 zeigt eng zusammen liegende Mittelwerte. Es ist keine Tendenz zu verkleinerten oder vergrößerten Pupillen erkennbar. Der t-Test schlägt mit einer Ablehnungswahrscheinlichkeit von 11% fehl. Auch die Hypothese, dass der Nutzer sich an den Boost gewöhnt und somit die durchschnittliche Pupillenänderung wesentlich geringer wird, kann nicht gehalten werden. Ein t-Test mit dem jeweiligen ersten Versuch jedes Probanden schlägt ebenfalls fehl. Die Ablehnungswahrscheinlichkeit beträgt 24%.

Mit dem Falling Event soll der Nutzer verärgert werden. Es kommt zu einer negativen emotionalen Reaktion. Das Falling Event ist in einem Boxplot in Abbildung 4.6 dargestellt. Es ist ein Anstieg der Durchschnittswerte erkennbar. Auch im Vergleich Durchschnittswerte zeichnet sich eine Tendenz für eine Pupillenvergrößerung ab. Der t-Test der 53 Falling Events ist positiv mit einer Ablehnungswahrscheinlichkeit von 0,0002%. Dieses

4. Versuchsdurchführung




Abbildung 4.6.: Boxplot: Falling Events

Ergebnis zeigt, dass das Falling Event einen signifikanten Unterschied in den Messwerten erzeugt. Dies deutet darauf hin, dass das Falling Event einen messbaren Unterschied im emotionalen Zustand des Nutzers erzeugt. Das vierte Level hat im SAM Test einen Arousal Durchschnitt von 1,8. Dies ist der höchste Durchschnitt im Test. Dies spiegelt den erfolgreichen t-Test des Falling Events wider.

Im fünften Level treten die WallHit und SpiderAttack Events auf. Beide Events sollen den Nutzer erschrecken oder verängstigen. Es werden negative Reaktionen erwartet.

Das WallHit Event wurde nur drei Mal ausgelöst, da zwei Probanden den entsprechenden Bereich umfahren haben. Der Boxplot in 4.7 zeigt eine Tendenz für eine Pupillenerweiterung mit sich deutlich unterscheidenden Durchschnittswerten. Es wird ein positives Testergebnis erwartet. Der t-Test ist mit einer Ablehnungswahrscheinlichkeit von 1% erfolgreich. Die plötzlich auftretende Wand scheint eine messbare emotionale Reaktion

4. Versuchsdurchführung

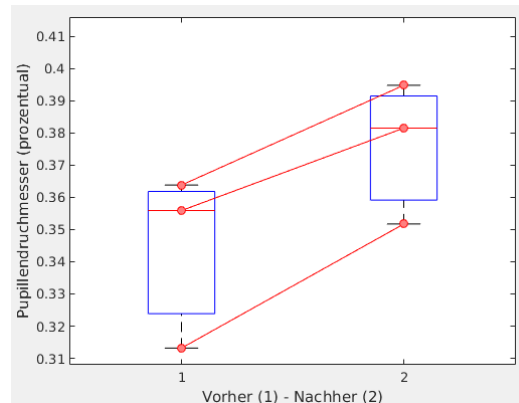


Abbildung 4.7.: Boxplot: Wall Events

beim Probanden hervorzurufen. Da nur drei WallHit Events ausgewertet wurden, ist dies als positive Tendenz zu werten.

Das SpiderAttack Event wurde 16 Mal erzeugt. Die Abbildung 4.8 zeigt den Boxplot mit den Ergebnissen der Messungen. Es ist ein positiver Trend mit einigen Ausreißern zu erkennen. Die Durchschnittswerte unterscheiden sich deutlich im Vorher-Nachher-Vergleich. Der t-Test ist positiv und hat eine Ablehnungswahrscheinlichkeit von 2%. Ein SpiderAttack Event hat einen signifikanten Einfluss auf den emotionalen Zustand des Nutzers. Insgesamt hat das fünfte Level im SAM Test einen Durchschnitt von 1,4 in der Arousal-Dimension Dies entspricht dem zweithöchsten Wert, direkt nach Level 4.

Das sechste Level beinhaltet Coin und Scare Events. Die Coin Events wurden bereits beschrieben. Das Scare Event besteht aus einem plötzlich auftauchenden Monster. Dies soll den Probanden erschrecken und verängstigen. Insgesamt wurden fünf Scare Events gemessen.

4. Versuchsdurchführung




Abbildung 4.8.: Boxplot: SpiderAttack Events

Der Boxplot der Scare Events in Abbildung 4.9 deutet auf eine Pupillenverkleinerung hin. Die Durchschnittswerte der Pupillengröße sind kleiner als vor dem Event. Ein Proband hat mit einer vergrößerten Pupille reagiert. Der t-Test schlägt mit einer Ablehnungswahrscheinlichkeit von 31% fehl. Obwohl der Boxplot eine negative Tendenz zeigt, lehnt der t-Test die Hypothese ab. Dies könnte an den geringen Datenmengen liegen. Je kleiner die Datenmenge, desto größer muss der Effekt sein, um im t-Test nachgewiesen zu werden[11]. Der SAM Test hat für diesen Level einen Arousal durchschnitt von 1,2.

Die Ergebnisse sind in Tabelle 4.4 zusammengefasst dargestellt. Es konnten nur bei Events, die den Probanden negativ beeinflussen, eine signifikante Steigerung der Pupillengröße festgestellt werden. Negative Events scheinen zu größeren Reaktionen in der Pupillengröße zu führen.

4. Versuchsdurchführung

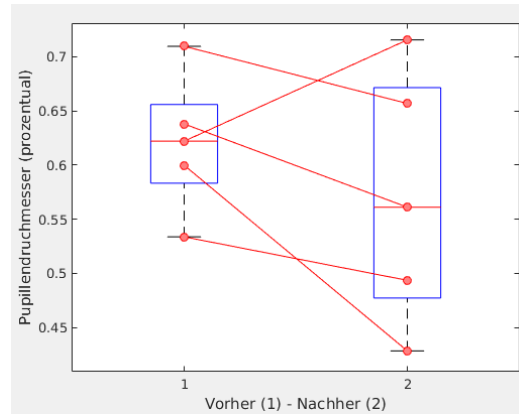


Abbildung 4.9.: Boxplot: Scare Events

Level Id	Events	Anzahl	Emotion	t-Test
1	Levelmitte	5	-	0
2	TeddyHit	4	positiv	0
3	Coin	100	positiv	0
6	Coin	92	positiv	0
4	Boost	46	positiv	0
4	Boost(nur 1. Versuch)	5	positiv	0
4	Falling	53	negativ	1
5	SpiderAttack	16	negativ	1
5	WallHit	3	negativ	1
6	Scare	5	negativ	0

Tabelle 4.4.: Übersicht der Ergebnisse der Datenauswertung

4. Versuchsdurchführung

Der SAM Test spiegelt für die Arousal-Dimension die gleichen Ergebnisse wider. Aufgrund der relativ kleinen Versuchsmenge könnte es sein, dass kleinere Reaktionen nicht im t-Test festgestellt werden können. Der Boxplot der Teddy Events (siehe 4.2) hatte Tendenzen zu einer Pupillenvergrößerung. Bei einer größeren Eventanzahl könnten genauere Aussagen getroffen werden. Das Scare Event ist das einzige Event, das Hinweise auf eine Verkleinerung der Pupillengröße enthält. Dies könnte auch an der kleinen Event-Anzahl von fünf liegen.

Insgesamt gibt es Hinweise darauf, dass der Eyetracker eine sinnvolle Erweiterung des EmoBike Projekts ist. Im Bereich der negativen Emotionen wurden signifikante Änderungen der Pupillengröße bei drei von vier Events festgestellt. Bei den positiven Events wurden keine hinreichenden Änderungen festgestellt werden. Trotzdem wurden Hinweise auf messbare Änderungen herausgearbeitet.

5. Fazit und Ausblick

Diese Arbeit hat einen Überblick über die Companion Technologie gegeben.

Es wurde untersucht inwiefern ein Eyetracker einen Beitrag zum EmoBike Projekt, beziehungsweise zur Companion Technologie, leisten kann.

In diesem Rahmen wurde eine Vorstudie mit fünf Probanden im Rahmen des EmoBike Projektes der HAW-Hamburg durchgeführt. Die Probanden wurden durch definierte Events in den Leveln emotional stimuliert und es wurde untersucht, ob diese emotionalen Änderungen durch die Auswertung der Pupillengröße nachweisbar waren.

Drei der vier negativen Emotionsstimulationen konnten mit signifikanten Änderungen in der Pupillengröße in Zusammenhang gebracht werden. Im Bereich der positiven Stimulation konnten keine Hinweise für eine signifikante Änderung festgestellt werden. Eine Möglichkeit hierfür wäre, dass positive Emotionen eine geringere Pupillengrößenerweiterung erzeugen und somit schwerer nachweisbar sind. Eine andere Möglichkeit wäre, dass die verwendeten positiven Events keine messbare Änderung im emotionalen Zustand des Nutzers hervorrufen.

Für den Auswertungsprozess wurde erfolgreich der KDD-Prozess aus dem Data Mining Umfeld verwendet. Dies ermöglicht eine gut struktu-

rierte Datenanalyse. Lernende Systeme konnten aufgrund der geringen Versuchsdatenmenge nicht sinnvoll eingesetzt werden.

Bisher wurden im EmoBike Projekt keine Auswertung der Augen der Probanden vorgenommen. Die Ergebnisse dieser Studie zeigen, dass eben diese Auswertung eine sinnvolle Methode zur Emotionsklassifikation aufzeigt. Eine vollständige Klassifikation aller Grundemotionen durch den Eyetracker ist bisher nicht sinnvoll. Aber in dieser Arbeit wurde gezeigt, dass der Eyetracker als Arousal Sensor dienlich sein kann. Auf Grund dessen, ist der Eyetracker eine Bereicherung im Bereich der multimodalen Auswertung von Sensordaten. Er kann mit Sensoren in einer Sensorkaskade kombiniert werden, um alle Dimensionen des VAD Modells zur Emotionserkennung abzubilden. Die gesammelten Informationen können in einem multimodalen System verarbeitet werden und zu einer verbesserten Emotionserkennung in der Companion Technologie beitragen.

Im weiteren Verlauf des EmoBike Projektes sollten weitere Eyetracker-Daten ausgewertet werden. Für die Verwendung der Blickrichtung zur Emotionserkennung gibt es bereits gute Ansätze die mit aufgenommen werden können [38, 2]. Eine weitere Studie mit mehr Versuchspersonen und einem verbesserten Self-Assessment kann die gezeigten Ergebnisse verifizieren und eventuell mehr Zusammenhänge feststellen. Wenn dies geschehen ist, können lernende Methoden (Support Vector Machines, Neuronale Netze) genutzt werden, um eine automatisierte Klassifikation zu ermöglichen.

Die Nutzung eines Eyetracker in der Companion Technologie ist in EmoBike ähnlichen Bereichen vielversprechend und sollte weiter verfolgt werden. Wichtig ist, dass die in Kapitel 3.2.3 beschriebenen Einschränkun-

gen beachtet werden. Das größte Problem bei diesem Eyetracker ist, dass die Position des Kopfes in Relation zum Eyetracker bekannt sein muss.

Angenommen die verwendeten Methoden werden weiterentwickelt und es entsteht ein robuster Arousal-Sensor, der einfach und unkompliziert verwendet werden kann. Dieser Sensor hätte vielseitige Anwendungsmethoden in unterschiedlichen Bereichen.

In der Autoindustrie ließe sich ein Arousal-Sensor sinnvoll einsetzen. Der Sensor könnte beispielsweise in einem Auto verbaut werden und den Fahrer überwachen. Wenn der Fahrer in einen erregten emotionalen Zustand gerät, könnte das Auto dies bemerken und je nach Situation entsprechend eingreifen. Der Nutzer könnte darüber informiert werden, dass er eine Pause einlegen soll, oder das Auto drosselt die Höchstgeschwindigkeit um unnötige Gefahren zu vermeiden.

Zusätzlich bietet sich weitere Anwendungsmöglichkeiten in risikoreichen Berufsfeldern an. Eyetracker sind seit einiger Zeit keine statischen Sensoren mehr. Es wurden tragbare Varianten[35] entwickelt. Berücksichtigt man diese Entwicklungen, könnte ein nun tragbarer Arousal-Sensor, in gefährlichen Berufen unterstützend genutzt werden. Bei der Feuerwehr könnte die Leitzentrale einen genaueren Überblick über die Verfassung der Feuerwehrmänner im Einsatz erhalten. Ein Feuerwehrmann würde rechtzeitig zurückgerufen werden, wenn er mental überlastet ist. Weitere Berufsfelder wären die Polizei oder das Militär.

Aber auch in normalen Arbeitsumgebungen kann ein Arousal-Sensor nützlich eingesetzt werden. Der Sensor wäre beispielsweise im Bereich der Stresserkennung und -bewältigung einsetzbar. Es gibt Untersuchungen zu Stress am Arbeitsplatz und wie dieser vermeidbar oder steuerbar ist[19]. Ein Eyetracker könnte zur Stresserkennung genutzt werden und ein

5. Fazit und Ausblick

entsprechender Companion könnte dafür sorgen, dass der Nutzer in stressigen Phasen vor Einflüssen von außen geschützt wird. Zum Beispiel kann das Telefon lautlos und E-Mail Benachrichtigungen können unterdrückt werden.

Ein Eyetracker als Arousal-Sensor würde somit vielseitige Einsatzmöglichkeiten auch abseits der Companion Technologie bieten.

A. Anhang

Proband:

Level:




Abbildung A.1.: Beispiel des Self-Assessment Fragebogens

A. Anhang




Abbildung A.2.: User Coordinate System (UCS) Beispiel[31]

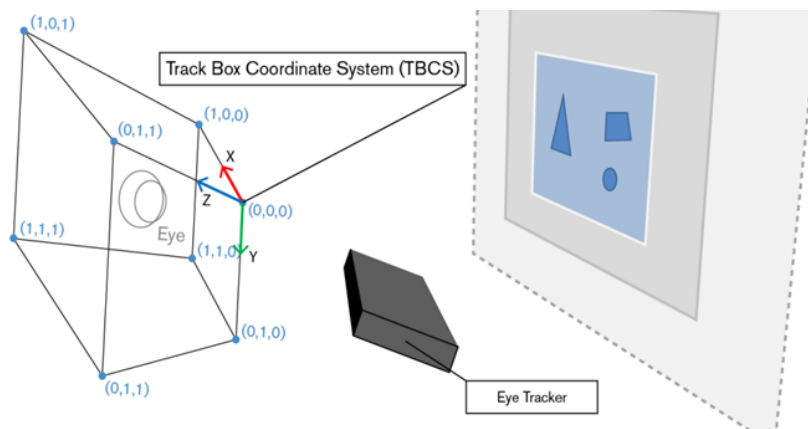


Abbildung A.3.: Track Box Coordinate System (TBCS) Beispiel[31]




Abbildung A.4.: logische Sicht des EmoBike Projektes erweitert um den Eyetracker. (Quelle Ursprungsbild: Jonas Hornschuh)

A. Anhang



Abbildung A.5.: Übersicht von Level 1 mit einem grünen Start und einem roten Ziel




Abbildung A.6.: Übersicht von Level 2 mit zusätzlichen Teddybären (einer ist exemplarisch mit blau Markiert))

A. Anhang




Abbildung A.7.: Übersicht von Level 3 mit Warnkegeln in der Mitte der Straße (drei beispielhaft in blau) und versetzten Münzen (drei exemplarisch in lila)



Abbildung A.8.: Übersicht von Level 4 mit dem blau markierten Boost und der lila markierten Rampe




Abbildung A.9.: Übersicht von Level 5 mit der blauen Steigung, der lila Wand und den orangen Spinnen



Abbildung A.10.: Übersicht von Level 6 mit drei exemplarischen blauen Münzen und dem lila scare Event. Das Level spielt in der Nacht und ist nur für die Übersicht aufgehellt



Abbildung A.11.: Übersicht der Levelvents

Literaturverzeichnis

- [1] SFB Transregio 62. Eine Companion-Technologie für kognitive technische Systeme, 2015. URL <http://www.sfb-trr-62.de/>. Stand 21.02.2015.
- [2] Sharifa Alghowinem, Roland Goecke, Michael Wagner, Gordon Parkex, und Michael Breakspear. Head pose and movement analysis as an indicator of depression. In *Affective Computing and Intelligent Interaction (ACII), 2013 Humaine Association Conference on*, pages 283–288. IEEE, 2013.
- [3] A. Babiker, I. Faye, und A. Malik. Differentiation of pupillary signals using statistical and functional analysis. In *Intelligent and Advanced Systems (ICIAS), 2014 5th International Conference on*, pages 1–6, June 2014. doi: 10.1109/ICIAS.2014.6869498.
- [4] Abubakr Babiker, Ibrahima Faye, und Anuj Malik. Pupillary behavior in positive and negative emotions. In *Signal and Image Processing Applications (ICSIPA), 2013 IEEE International Conference on*, pages 379–383. IEEE, 2013.
- [5] M. M. Bradley und P. J. Lang. Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Be-*

- havior Therapy and Experimental Psychiatry*, 25:49–59, 1994. doi: 10.1016/0005-7916(94)90063-9.
- [6] Margaret M Bradley und Peter J Lang. Affective norms for English words (ANEW): Instruction manual and affective ratings. Technical report, Technical report C-1, the center for research in psychophysiology, University of Florida, 1999.
- [7] Margaret M Bradley und Peter J Lang. The International Affective Digitized Sounds (; IADS-2): Affective ratings of sounds and instruction manual. *University of Florida, Gainesville, FL, Tech. Rep. B-3*, 2007.
- [8] Carlos Busso, Zhigang Deng, Serdar Yildirim, Murtaza Bulut, Chul Min Lee, Abe Kazemzadeh, Sungbok Lee, Ulrich Neumann, und Shrikanth Narayanan. Analysis of Emotion Recognition Using Facial Expressions, Speech and Multimodal Information. In *Proceedings of the 6th International Conference on Multimodal Interfaces, ICMI '04*, pages 205–211, New York, NY, USA, 2004. ACM. ISBN 1-58113-995-0. doi: 10.1145/1027933.1027968. URL <http://doi.acm.org/10.1145/1027933.1027968>.
- [9] J. Cleve und U. Lämmel. *Data Mining*. De Gruyter Studium. De Gruyter Oldenbourg, 2014. ISBN 9783486713916. URL <https://books.google.de/books?id=4i2nngEACAAJ>.
- [10] Randolph R. Cornelius. THEORETICAL APPROACHES TO EMOTION. *ITRW on Speech and Emotion*, 2000.

- [11] J.C.F de Winter. Using the Student's t-test with extremely small sample sizes. *Practical Assessment, Research & Evaluation*, 18(10), 2012.
- [12] Paul Ekman. Are there basic emotions? *Psychological Review*, 1992.
- [13] Paul Ekman und Wallace V. Friesen. Constants across cultures in the face and emotion. *Journal of Personality and Social Psychology*, 17(2):124–129, 1971. URL <http://psycnet.apa.org/journals/psp/17/2/124/>.
- [14] Apache Software Foundation. ActiveMQ, 2016. Stand 08.01.2016.
- [15] James J Gross und Robert W Levenson. Emotion elicitation using films. *Cognition & emotion*, 9(1):87–108, 1995.
- [16] Fraunhofer IIS. SHORE™ - Detektion von Objekten und Gesichtern, 2016. URL <http://www.iis.fraunhofer.de/de/bf/bsy/produkte/shore.html>. Stand 12.05.2016.
- [17] HCM Lab. Social Signal Interpretation, 2016. URL <http://hcm-lab.de/projects/ssi/>. Stand 11.03.2016.
- [18] Peter J Lang, Margaret M Bradley, und Bruce N Cuthbert. International affective picture system (IAPS): Technical manual and affective ratings. *NIMH Center for the Study of Emotion and Attention*, pages 39–58, 1997.
- [19] Benjamin Lindemann. Stress am IT-Arbeitsplatz, 2014. URL <http://users.informatik.haw-hamburg.de/>

~ubicomp/projekte/master12-13-seminar/
lindemann/bericht.pdf.

- [20] D. Lottridge, M. Chignell, und M. Yasumura. Identifying Emotion through Implicit and Explicit Measures: Cultural Differences, Cognitive Load, and Immersion. *IEEE Transactions on Affective Computing*, 3(2):199–210, April 2012. ISSN 1949-3045. doi: 10.1109/T-AFFC.2011.36.
- [21] MathWorks. Matlab Boxplot Dokumentation, 2016. URL <https://de.mathworks.com/help/stats/boxplot.html>. Stand 02.04.2016.
- [22] MathWorks. Matlab, 2016. URL <https://de.mathworks.com/>. Stand 02.04.2016.
- [23] Albert Mehrabian. Pleasure-arousal-dominance: A general framework for describing and measuring individual differences in temperament. *Current Psychology*, 14(4):261–292, 1996.
- [24] Microsoft. Kinect for Windows, 2016. URL <http://www.microsoft.com/en-us/kinectforwindows/>. Stand 01.02.2016.
- [25] Larissa Müller, Sebastian Zagaria, Arne Bernin, Abbas Amira, Naeem Ramzan, Christos Grecos, und Floria"Vogt. *Entertainment Computing - ICEC 2015: 14th International Conference, ICEC 2015, Trondheim, Norway, September 29 - October 2, 2015, Proceedings*, chapter EmotionBike: A Study of Provoking Emotions in Cycling Exergames, pages 155–168. Springer International Publishing, Cham, 2015. ISBN

- 978-3-319-24589-8. doi: 10.1007/978-3-319-24589-8_12. URL http://dx.doi.org/10.1007/978-3-319-24589-8_12.
- [26] Nintendo. WiiMote, 2016. URL <https://www.nintendo.de/Wii/Wii-94559.html>. Stand 01.02.2016.
- [27] Tin Lay Nwe, Foo Say Wei, und L. C. De Silva. Speech based emotion classification. In *TENCON 2001. Proceedings of IEEE Region 10 International Conference on Electrical and Electronic Technology*, volume 1, pages 297–301 vol.1, 2001. doi: 10.1109/TENCON.2001.949600.
- [28] Qt. Qt - Home, 2016. URL <https://www.qt.io/>. Stand 03.01.2016.
- [29] Student. The probable error of a mean. *Biometrika*, pages 1–25, 1908.
- [30] EmoBike Team. Emotionbike - haw-hamburg, 2016. URL <http://emotionbike.org>. Stand 11.04.2016.
- [31] Tobii Technology. *Tobii Analytics SDK Developers Guide*. Tobii Technology, 2013.
- [32] Tobii. *Tobii_X-Series_ConfigurationGuide*, 2013. URL http://www.tobii.com/Global/Analysis/Downloads/User_Manuals_and_Guides/Tobii_X-Series_ConfigurationGuide.xlsx.
- [33] Tobii. *Tobii X60 and X120 Eyetracker*, 2015. URL <http://www.tobii.com/de/eye-tracking-research/germany/produkte/>

- hardware/tobii-x60-x120-eyetracker/. Stand
22.02.2015.
- [34] Tobii. Self-Assessment-Manikin, 2016. URL http://irtel.uni-mannheim.de/pxlab/demos/index_SAM.html.
- [35] Tobii. Tobii Pro Glasses 2, 2016. URL <http://www.tobiipro.com/product-listing/tobii-pro-glasses-2/>.
Stand 12.04.2016.
- [36] S. Walter, Jonghwa Kim, D. Hrabal, S.C. Crawcour, H. Kessler, und H.C. Traue. Transsituational Individual-Specific Biopsychological Classification of Emotions. *Systems, Man, and Cybernetics: Systems, IEEE Transactions on*, 43(4):988–995, July 2013. ISSN 2168-2216. doi: 10.1109/TSMCA.2012.2216869.
- [37] Yorick Wilks. *Close engagements with artificial companions: key social, psychological, ethical and design issues*, volume 8. John Benjamins Publishing, 2010.
- [38] Yisu Zhao, Xin Wang, und E.M. Petriu. Facial expression analysis using eye gaze information. In *Computational Intelligence for Measurement Systems and Applications (CIMSAS), 2011 IEEE International Conference on*, pages 1–4, Sept 2011. doi: 10.1109/CIMSAS.2011.6059936.
- [39] Yisu Zhao, Xin Wang, und E.M. Petriu. Facial expression analysis using eye gaze information. In *Computational Intelligence for Measurement Systems and Applications (CIMSAS), 2011 IEEE International Conference on*, pages 1–4, Sept 2011. doi: 10.1109/CIMSAS.2011.6059936.

Hiermit versichere ich, dass ich die vorliegende Arbeit ohne fremde Hilfe selbstständig verfasst und nur die angegebenen Hilfsmittel benutzt habe.

Hamburg, 17. Mai 2016

Kai Bielenberg