

Entwicklung und Evaluation einer Trainingsumgebung mit Gamification-Elementen zur Vorbereitung auf einen VR-basierten Fahrradsimulator im Studieneinsatz

Bachelorarbeit

im Studiengang Computervisualistik und Design
vorgelegt von

Jasmin Schiffers

Matrikelnummer: [redacted]

am 19.07.2024
an der Hochschule Hamm-Lippstadt

Erstprüferin: Prof. Dr. Merijam Gotzes

Zweitprüfer: Prof. Dr. Georg Birkenheuer

Betreuerin: Donaji Martinez Garcia

Abstract

This thesis describes the development and evaluation of a virtual reality (VR) training environment designed to prepare test subjects for participation in road safety research studies on a bicycle simulator. The objective is to provide a short, standardized, and efficient training program for the bicycle simulator to increase the acceptance while minimizing potential negative effects, such as simulator sickness. In order to achieve this, a training environment was developed that makes use of gamification elements with the intention of improving training results and reducing any negative effects. Two versions of the simulator were created for comparison, one with and one without the gamification elements. The results show that the version with gamification achieves a higher level of learning performance. Furthermore, the incidence of simulator sickness is notably reduced when using the simulator with gamification in comparison to the version without gamification elements. In conclusion, the integration of gamification elements into a VR training environment can be beneficial in enhancing learning success while minimizing simulator sickness.

Inhaltsverzeichnis

1 Einleitung 1

1.1 Problemstellung 2

1.2 Ziel der Arbeit 3

1.3 Aufbau der Bachelorarbeit 4

2 Einordnung 6

2.1 Fahrradsimulator 6

2.2 Menschliche Einflussfaktoren 8

2.2.1 Simulator Sickness 9

2.2.2 Präsenz 11

2.2.3 Akzeptanz 12

2.3 Gamification 13

3 Anforderungen 16

4 Konzeptplanung 21

4.1 Trainingsumgebung 22

4.2 Trainingsszenarios 23

4.3 Gamification-Elemente 24

5 Umsetzung 26

5.1 Modellierung und Anpassung der Assets 26

5.1.1 Map 26

5.1.2 Streckenmarkierungen 30

5.1.3 Fahrrad 31

5.1.4 Sounddesign 31

5.2 Blueprints 32

5.2.1 Aufbau/Projektstruktur 32

5.2.2 Scenario 34

5.2.3 ScenarioObject 35

5.2.4 ScenarioBuilder 36

5.2.5 ScenarioRunner 37

5.2.6 Variant Manager 39

5.2.7 ScenarioEditor 39

5.3 Szenario Erstellung 40

5.4 BikeSim Anbindung und Logging 44

6 Studiendesign 45

6.1 Messmethoden 45

6.1.1 Fragebögen (subjektive Messung) 46
6.1.2 Aufgezeichnete Daten (objektive Messung) 50
6.2 Instruktion 50
6.3 Versuchsablauf 51
7 Ergebnisse 54
7.1 Demographie-Fragebogen 54
7.2 Fahrradsimulator Survey 55
7.3 Fragebogen zum Trainingserfolg 57
7.4 Simulator Sickness Questionnaire 58
7.5 Misery Scale 60
7.6 Präsenz Questionnaire 61
7.7 Technology Acceptance Scale 62
7.8 Daten (objektiver Trainingserfolg) 64
8 Diskussion 66
8.1 RQ1: Trainingserfolg 66
8.2 RQ2: Simulator Sickness 67
8.3 RQ3: Präsenz 68
8.4 RQ4: Akzeptanz 69
8.5 Zusammenfassung 70
8.6 Limitation 71
9 Fazit 74
9.1 Ausblick 75
Literaturverzeichnis I
Anhang V
A: Assetpacks V
B: Blueprints VI
C: Anleitung XIX
D: Loggindaten XXVI
E: Instruktion XXVIII
F: Datenerhebung XXX
Hinweis zum Urheberrecht XXXV
Eidesstattliche Erklärung XXXVI

Abbildungsverzeichnis

Abb. 1: Aufbau der Arbeit (Eigene Darstellung, 2024) 5

Abb. 2: Fahrradsimulator im MoSAIC (*DLR*) 7

Abb. 3: Hardware components of the bicycle simulator (*Donaji Martinez Garcia*, 2021) 8

Abb. 4: Use Case Diagramm (Eigene Darstellung, 2024) 21

Abb. 5: ADAC-Verkehrsübungsplatz, Braunschweig, DE (Google Maps, 2023) 22

Abb. 6: Verteilung der Szenarios auf der Strecke (Eigene Darstellung, 2024) 24

Abb. 7: Modellierung der Strecke in Blender (Eigene Darstellung, 2024) 27

Abb. 8: Fotos und Screenshot in der UE (Eigene Darstellung, 2024) 28

Abb. 9: Splines für die Straßenmarkierungen (Eigene Darstellung, 2024)29

Abb. 10: Splines für Schutzplanken (Eigene Darstellung, 2024)..... 29

Abb. 11: Ziel-, Start- und Pfadmarkierungen (Eigene Darstellung, 2024) 30

Abb. 12: Fahrradmodell (Eigene Darstellung, 2024) 31

Abb. 13: Klassendiagramm BiTS (Eigene Darstellung, 2024)..... 33

Abb. 14: BP_Scenario (Eigene Darstellung, 2024) 34

Abb. 15: BP_DefinedScenario (Eigene Darstellung, 2024)..... 34

Abb. 16: BP_SlalomScenario (Eigene Darstellung, 2024) 35

Abb. 17: Fade out (Eigene Darstellung, 2024)..... 38

Abb. 18: Editor-Map (Eigene Darstellung, 2024)..... 40

Abb. 19: Festgelegte Szenarios (Eigene Darstellung, 2024) 40

Abb. 20: Einstellungen der Szenarios (Eigene Darstellung, 2024)..... 43

Abb. 21: UVs und AVs (Eigene Darstellung, 2024)..... 45

Abb. 22: Computation of SSQ Scores (*Kennedy et al*., 1993) 48

Abb. 23: MISC (Eigene Darstellung nach (Wertheim et al. 1998, 522)) ... 48

Abb. 24: TAS (Eigene Darstellung nach (Van Der Laan et al. 1997,3)) ... 50

Abb. 25: Versuchsablauf (Eigene Darstellung, 2023) 51

Abb. 26: Wie oft wird Fahrrad gefahren? (Eigene Darstellung, 2024)..... 55

Abb. 27: Wo wird Fahrrad gefahren? (Eigene Darstellung, 2024)..... 55

Abb. 28: Diagramm- Fahrradsimulator Survey (Eigene Darstellung, 2024) 56

Abb. 29: Diagramm - Fahrradsimulator Survey (Eigene Darstellung, 2024) 56

Abb. 30: Diagramm - Trainingserfolg Fragebogen (Eigene Darstellung, 2024) 58

Abb. 31: Diagramm - SSQ (Eigene Darstellung, 2024)..... 59

Abb. 32: Diagramm - Total Score - Mit Abbrecher:innen (Eigene Darstellung, 2024) 59

Abb. 33: Diagramm - SSQ-Symptomstärke - Mit Abbrecher:innen (Eigene Darstellung, 2024) 60

Abb. 34: Diagramm - MISC (Eigene Darstellung, 2024) 61

Abb. 35: Diagramm – PQ (Eigene Darstellung, 2024) 62

Abb. 36: Diagramm-PQ nach Kategorien (Eigene Darstellung, 2024) 62

Abb. 37: Diagramm-TAS (Eigene Darstellung, 2024) 63

Abb. 38: Diagramm-TAS Subkategorien (Eigene Darstellung, 2024) 64

Abb. 39: Diagramm Trainingserfolg Points und Obstacles (Eigene Darstellung, 2024) 65

Abb. 40: Diagramm Trainingserfolg Zeit (Eigene Darstellung, 2024)..... 65

Tabellenverzeichnis

Tabelle 1: Technische Spezifikationen BikeSim..... 8

Tabelle 2: Anforderungen 16

Tabelle 3: Realismus Anforderungen..... 23

Tabelle 4: Streckenabschnitte..... 41

Tabelle 5: PQ-Subskalen 49

Tabelle 6: TAS-Subskalen 50

Abkürzungsverzeichnis

HSHL	Hochschule Hamm-Lippstadt
VRU	Vulnerable Road User
DLR	Deutsches Zentrum für Luft und Raumfahrt
TS	Verkehrssystemtechnik
MZS	Menschzentrierte Simulation
MoSAIC	Modular and Scalable Application-Platform for Testing and Evaluating of ITS Component
VRU	Vulnerable Road User
VP	Versuchspersonen
HMI	Human Maschine Interaktion
VR	Virtual Reality
HMD	Head Mounted Display
HCEI	Human Virtual Environment Interaction
MS	Motion Sickness
VIMS	Visuell induzierte Bewegungskrankheiten
TAM	Technology Acceptance Model
UE	Unreal Engine
BP	Blueprint
VL	Versuchsleitung
SSQ	Simulator Sickness Questionnaire
MISC	Misery Scale
PQ	Presence Questionnaire
TAS	Technology Acceptance Scale
FS	Fahrradsimulator Survey

1 Einleitung

Die vorliegende Arbeit umfasst die Entwicklung einer Trainingsumgebung mit entsprechenden Übungsaufgaben für einen Fahrradsimulator. Anhand einer systematisch durchgeführten Evaluation erfolgt die Bewertung der Umsetzung des Projekts sowie eine Einschätzung des Trainingserfolgs.

Aufgrund der erheblichen positiven Auswirkungen auf die Verkehrsüberlastung und die Umwelt findet das Fahrrad immer mehr an Zuspruch (vgl. Ansariyar et al. 2022). Das Fahrrad ist in Deutschland nach dem zu Fuß gehen und Auto fahren, das meistgenutzte Verkehrsmittel 30% fahren regelmäßig, also täglich oder mehrmals die Woche Fahrrad (vgl. Jurczok et al. 2023). Im Straßenverkehr zählen Zweiradfahrer:innen und Fußgänger:innen zu den sogenannten Vulnerable Road User (VRU), knapp 70% aller Verkehrstoten im städtischen Verkehr entfallen in Europa auf diese Gruppe (vgl. Europäische Kommission 2023). Dies macht deutlich, dass der Schutz dieser Verkehrsteilnehmenden verbessert werden muss (vgl. ebd.).

Um mögliche Risikofaktoren im Verkehr zu ermitteln, kommen als Forschungsinstrument häufig Simulationen zum Einsatz. In einer virtuellen Umgebung können Szenarios entwickelt werden, die in der Realität aus zeitlichen, finanziellen oder sicherheitskritischen Gründen nicht umsetzbar sind (vgl. Brooks et al. 2010). Zu den am häufigsten simulierten Aufgaben gehören das Fliegen, medizinische Verfahren und das Autofahren (vgl. ebd.). In der Verkehrsforschung und -entwicklung ist der Einsatz von Fahrsimulatoren weit verbreitet (vgl. Pinto et al. 2008).

Solche Simulatoren sind ein effizientes Instrument, um das Verhalten in verschiedenen Verkehrsszenarios zu untersuchen (vgl. Ansariyar et al. 2022). Die gleichbleibenden und kontrollierbaren Bedingungen ermöglichen eine sichere und reproduzierbare Durchführung von Studien (vgl. ebd.). Darüber hinaus können wichtige Daten wie Geschwindigkeit, Bremsen und Kopfbewegungen gesammelt und gespeichert werden (vgl. ebd.). Trotz der wachsenden Beliebtheit des Fahrrads und der besonderen Gefährdung sind Fahrradsimulatoren im Vergleich zum Auto in der Entwicklung weitaus

weniger vorangeschritten, erforscht und verstanden. Allerdings nimmt die Beschäftigung der Forschung mit dem Thema seit 2018 stark zu (vgl. ebd.).

Im Deutschen Zentrum für Luft und Raumfahrt (DLR) am Standort Braunschweig werden verschiedene Fahr- und Flugsimulatoren entwickelt und kommen dort in Studien zum Einsatz. Das Institut für Verkehrssystemtechnik (TS) gestaltet und erforscht die Mobilität von Menschen und den Transport von Gütern (vgl. DLR o.D.). Ziel ist es einen Beitrag zur Erhöhung der Sicherheit, Effizienz, Nachhaltigkeit, Wirtschaftlichkeit und Qualität des Verkehrs auf Straße und Schiene zu leisten (vgl. ebd.). Bei der Gestaltung des Verkehrs soll die Forschung das Gesamtverkehrssystem mit all seinen Wechselwirkungen im Blick behalten (vgl. ebd.)

Die Mitarbeitenden des Fachbereichs Menschzentrierte Simulation (MZS) entwickeln und evaluieren nutzungsgerechte und anwendungsorientierte Lösungen und Systeme, um Verkehrssituationen erfassen, bewerten und beeinflussen zu können. Zur Unterstützung der wissenschaftlichen Arbeit werden Großforschungsanlagen vom Versuchsfahrzeug bis hin zum komplexen Simulationslabor entwickelt und betrieben.

Eines dieser Labore ist das MoSAIC-VRU-Lab (Modular and Scalable Application-Platform for Testing and Evaluating of ITS Component (MoSAIC) - Vulnerable Road User (VRU)). Dort werden innovative Mobilitätslösungen unter sicheren Bedingungen getestet und evaluiert, bevor sie in realen Testumgebungen zum Einsatz kommen (vgl. DLR o.D.).

1.1 Problemstellung

Beim Einsatz von Fahrsimulatoren in Studien sollen Versuchspersonen (VP) in der virtuellen Umgebung möglichst realistisch auf die simulierten Verkehrssituationen reagieren. Daher ist es wichtig, dass sich die VPs vor Studienbeginn mit dem Fahrverhalten des Simulators vertraut machen.

Es stellt sich also die Frage, wie eine Trainingsumgebung mit entsprechenden Aufgaben gestaltet sein muss, damit VPs während der Übungsphase

möglichst effizient die wichtigsten Manöver wie Beschleunigen, Lenken und Bremsen erlernen können.

Für den Fahrradsimulator im Institut TS wurden in bisherigen Studien Trainingsszenarios verwendet, die auf Abschnitten der für die jeweilige Versuchsfahrt erstellten Strecke basieren. Versuchsleitung (VL) und VP beurteilen nach eigener Einschätzung, ob die Vorbereitung ausreichend war oder Streckenabschnitte wiederholt werden müssen. Somit findet kein einheitliches Training statt. In Zukunft soll für die Eingewöhnungsphase der VPs ein standardisiertes Training zum Einsatz kommen.

1.2 Ziel der Arbeit

Im Rahmen dieser Arbeit wird ein Trainingskonzept für den Fahrradsimulator entwickelt und evaluiert. Unter Berücksichtigung zuvor erfasster Anforderungen werden verschiedene Szenarios mit festgelegten Aufgaben und einem klaren Ziel definierten, um ein reproduzierbares Training von VPs zu ermöglichen. Durch die Vergleichbarkeit kann das Training in Zukunft systematisch evaluiert und weiterentwickelt werden.

Damit die wichtigsten Bewegungsabläufe geübt werden können, muss eine entsprechende Umgebung eingerichtet und die zu absolvierenden Aufgaben festgelegt werden. Das Trainingsprogramm wird mit Hilfe der Unreal Engine 5 (UE5) umgesetzt und auf den Fahrradsimulator angepasst. Einflussfaktoren, die den Trainingserfolg positiv oder negativ beeinflussen können, werden ermittelt und in der Umsetzung entsprechend berücksichtigt. Faktoren wie Präsenz und Akzeptanz sollten für einen guten Trainingserfolg auf einem hohen Level sein. Nebenwirkungen wie Simulator Sickness sollten möglichst reduziert werden.

Eine Annahme ist, dass sich das Lenken der Aufmerksamkeit auf die Aufgabe und gesteigerte Motivation durch gezielten Einsatz von Gamification-Elementen positiv auf die VPs auswirken kann. Um diese Annahme zu überprüfen, werden zwei verschiedene Varianten eine mit und eine ohne Gamification umgesetzt und evaluiert. Dabei sollen die folgenden Forschungsfragen (RQ) beantwortet werden.

RQ1: Haben die Gamification-Elemente einen Einfluss auf den Trainingserfolg beim Einsatz des Fahrradsimulators?

RQ2: Wird Simulator Sickness beim Einsatz des Fahrradsimulators durch Gamification-Elemente beeinflusst?

RQ3: Wird die Präsenz beim Einsatz des Fahrradsimulators durch Gamification-Elemente beeinflusst?

RQ4: Wird Akzeptanz beim Einsatz des Fahrradsimulators durch Gamification-Elemente beeinflusst?

Mittels einer kleinen Stichprobe werden die Fragen überprüft. Zur subjektiven Bewertung kommen verschiedene Fragebögen zum Einsatz. Für eine objektive Bewertung des Trainingserfolgs werden zusätzlich während den Versuchsfahrten gesammelte Daten ausgewertet.

1.3 Aufbau der Bachelorarbeit

Zur Orientierung folgt eine Übersicht der einzelnen Kapitel und deren Inhalte. Das erstes und zweite Kapitel dienen der Einführung in das Themenfeld. Sie informieren über die Problemstellung, die Ziele der Arbeit und die Forschungsfragen. Die Kapitel drei bis sechs beschreiben das Projekt von der Planung bis zum Ergebnis. Betrachtet werden hier die Anforderungen und die darauf aufbauende Planung. Die Projektumsetzung und Studiendurchführung sowie angewandten Methoden werden genauer beleuchtet. Die Kapitel sieben und acht beinhalten die Ergebnisse, die anhand von Diagrammen visualisiert sind und erläutert werden. Anschließend erfolgt die Interpretation im Hinblick auf die Forschungsfragen. Des Weiteren werden Anpassungen des Trainings vorgeschlagen und Forschungsansätze diskutiert. Abschließend folgt die Erläuterung der wichtigsten Ergebnisse und Schlussfolgerungen im Fazit sowie ein Ausblick auf die weitere Verwendung und Verbesserung des Projekts. Die Abb. 1 zeigt die in den einzelnen Kapiteln behandelte Fragestellungen.

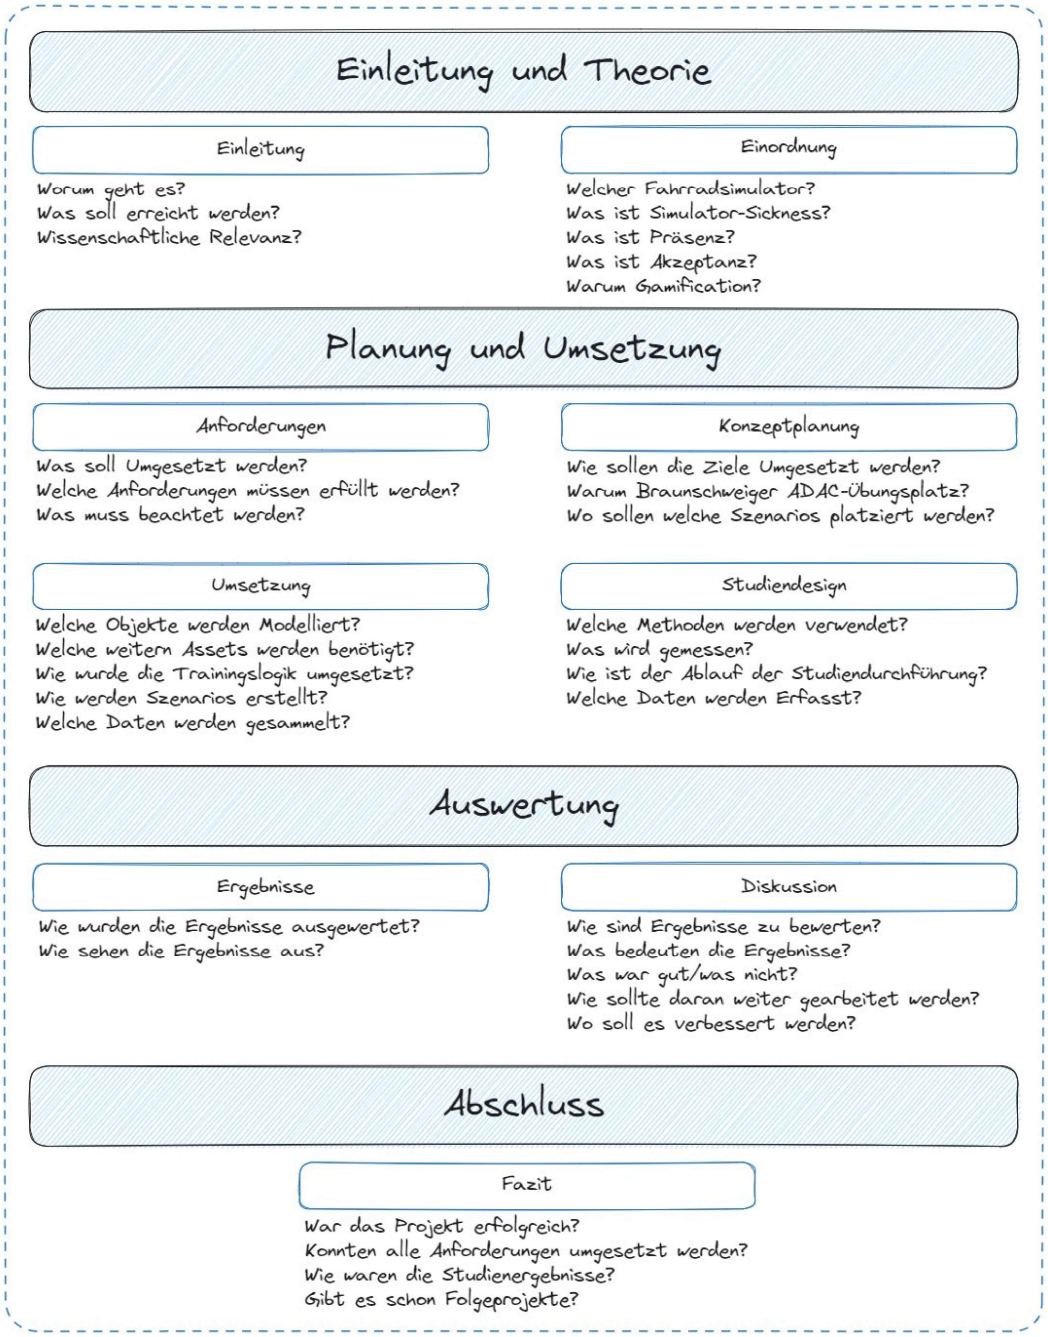


Abb. 1: Aufbau der Arbeit (Eigene Darstellung, 2024)

2 Einordnung

Bei der Entwicklung von menschzentrierten Simulatoren muss neben der Hard- und Software insbesondere der Mensch als Faktor bedacht werden. Bei der Interaktion zwischen Mensch und Maschine können sich verschiedene Einflussfaktoren negativ oder positiv auf die Erfahrung und Leistung einer Person auswirken (vgl. Stanney et al. 1998). Für ein effizientes Training sollten mögliche Faktoren identifiziert, analysiert und bei der Entwicklung beachtet werden.

Im Folgenden wird die durch das DLR zur Verfügung gestellte Hardware des Fahrradsimulators beschrieben. Zudem werden verschiedene menschliche Faktoren benannt, die das Training beeinflussen können. Im Anschluss wird erörtert, inwiefern Gamification dazu beitragen könnte, die Ergebnisse zu verbessern.

2.1 Fahrradsimulator

Entwickelt werden soll das Training für den Fahrradsimulator im MoSAIC Labor des DLRs (Abb. 2). Die Laborräume des MoSAIC bieten eine modulare, skalierbare Infrastruktur mit Multi-User Simulation zum Designen, Entwickeln und Evaluieren von Fahrassistenzsystemen. Mithilfe der verschiedenen Simulatoren wird hier bei der Forschung ein Fokus auf das individuelle Verhalten sowie die Interaktion und Kooperation unterschiedlicher Verkehrsteilnehmenden untereinander oder mit automatisierten Fahrzeugen gelegt. Durch den Aufbau des Labors mit zwei statischen Autosimulatoren, zwei Fußgängersimulatoren und einem Fahrradsimulator können solche Situationen beobachtet und VRUs besonders berücksichtigt werden.



Abb. 2: Fahrradsimulator im MoSAIC (*DLR*)

Der Fahrradsimulator ermöglicht die Integration von Testpersonen auf einem Fahrrad in eine virtuelle Umgebung. Die Hardware besteht aus einem Fahrradgestell mit eingebautem Widerstandskrafttrainer, welches auf einer beweglichen *two degree of freedom* (2-DOF) Plattform montiert ist (Abb. 3). Horizontale und vertikale Bewegungen werden anhand der virtuellen Streckendaten synchronisiert. Durch das Zusammenspiel von Aktorik, Sensorik und Dynamikmodellen wird außerdem ein realistisches Lenk-, Brems- und Beschleunigungsverhalten erzeugt. Zur Vermittlung eines Geschwindigkeitsgefühls kommt ein Fahrtwindsimulator zum Einsatz. Die Darstellung der virtuellen Umgebung erfolgt aktuell durch ein Head Mounted Display (HMD) vom Modell *HTC Vive Pro Eye.* Zusätzlich besteht die Möglichkeit, einen frontal zum Fahrrad ausgerichteten Monitor zu verwenden. Dieser ermöglich einerseits die Studiendurchführung ohne HMD und andererseits kann die VL den Fahrtverlauf beobachten und ggf. eingreifen. Jedoch kann sich die VP bei der Darstellung über den Monitor nicht in der virtuellen Umgebung umschauen und demnach keinen Schulterblick durchführen.

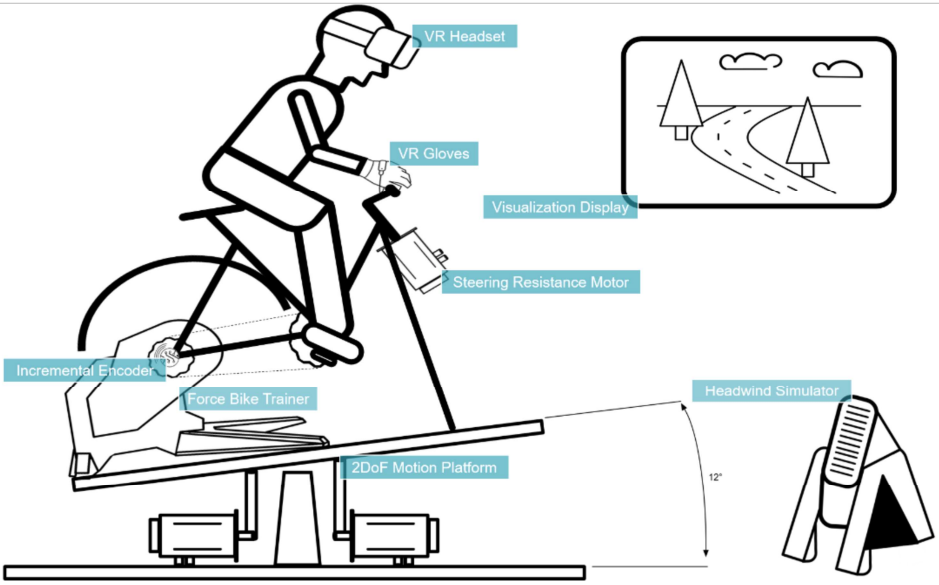


Abb. 3: Hardware components of the bicycle simulator (*Donaji Martinez Garcia*, 2021)

Die beschriebenen Komponenten des Fahrradsimulators und das Trainingsprogramm laufen auf einem System mit folgenden technischen Spezifikationen:

Mainboard	ASUS ROG Z790-F
Prozessor	Intel Core i7-13900K 3.40 – 5.80 GHz
Arbeitsspeicher	64 GB DDR5 5600 MHz, CL28
Grafikkarte	GeForce RTX 4090 OC, 24 GB

Tabelle 1: Technische Spezifikationen BikeSim

2.2 Menschliche Einflussfaktoren

Damit eine Interaktion zwischen Mensch und Maschine effektiv ist und gut angenommen wird, müssen menschliche Einflussfaktoren berücksichtigt werden. Die Benutzung von Simulatoren kann beim Menschen verschiedene unerwünschte Symptome auslösen. Insbesondere führe ein Unwohlsein bei Nutzer:innen zu einer Beeinträchtigung der Messungen, einem verringertem Trainingserfolg und zu einer erhöhten Abbruchquote, weswegen der Einfluss ungewollter Störfaktoren minimiert werden solle (vgl. ebd.; Brooks et al. 2010; Stoner et al. 2011; Dziuda et al. 2014; Bos 2015; Weech et al. 2019).

Nach Szalma ist Motivation „[…] a driving force in humantechnology interaction“ (Szalma 2014, 1453). Die virtuelle Umgebung dient als Schnittstelle und solle möglichst so entworfen werden, dass die Motivation erhöht wird und somit einen positiven Einfluss auf Leistung und Wohlbefinden der Nutzer:innen ausübt (vgl. Szalma 2014). Eine angenehme Erfahrung ohne Stress ermögliche demnach einen effektiveren Trainingserfolg (vgl. ebd.).

Im Folgenden werden typische Faktoren genauer beleuchtet, von denen angenommen wird, dass sie einen Einfluss auf Trainingserfolg und Wohlbefinden der VPs haben können. Simulator Sickness, Präsenz und Akzeptanz sind wichtige Indikatoren zur Bewertung von menschzentrierten Simulatoren und können durch standardisierte Messmethoden erfasst werden. Die verwendeten Fragebögen zur Erfassung der subjektiven Einschätzung der VPs werden in 6.1.1 erläutert.

2.2.1 Simulator Sickness

Simulator Sickness ist eine spezielle Form der Motion Sickness und kann Symptome von Kopfschmerzen und Übelkeit bis hin zum Erbrechen auslösen (vgl. Kennedy et al. 1993; Pausch et al. 1992; Cobb et al. 1999; Stoner et al. 2011; Jerald 2015).

Der Begriff Motion Sickness wird im deutschsprachigen Raum meistens gleichgesetzt mit Reise- oder Bewegungskrankheit, sie wird verursacht durch passive Fortbewegung mit einem Fahrzeug. Während zunächst eher davon ausgegangen wurde, dass die Symptome von niederfrequenten Bewegungen verursacht seien, wurde vor allem im Zuge der Weiterentwicklung des Bewegtbildes und virtueller Umgebungen festgestellt, dass ähnliche Symptome auch durch ausschließlich visuelle Reize entstehen können (vgl. Bos et al. 2010).

Die *Visually Induced Motion Sickness* (VIMS) wird also nicht durch physische Bewegung, sondern durch eine visuelle Bewegung bspw. innerhalb einer virtuellen Umgebung ausgelöst (vgl. Cha et al. 2021).

Zur genaueren Differenzierung der Ursachen und Auswirkungen wurde die VIMS im Laufe der Zeit in weitere Kategorien unterteilt, z.B. *Cyber Sickness* bei Computerspielen (vgl. Weech et al. 2019), *Cinerama Sickness* bei Großbildprojektionen (vgl. Bos et al. 2010) oder *VR Sickness* bei VR-Anwendungen (vgl. Bowman und McMahan 2007).

Die für den Fahrradsimulator zutreffendste Kategorie ist die Simulator Sickness. Sie zählt ebenfalls zur VIMS und werde typischerweise in Flug- und Fahrsimulatoren beobachtet unabhängig des Vorhandenseins einer physisch bewegten Plattform (vgl. Stanney et al. 1998). Habe der Simulator jedoch eine zusätzliche Eigenbewegung, können Latenzen und widersprüchliche Wahrnehmungen zwischen physischer und visueller Bewegung das Unwohlsein verstärken (vgl. ebd.). Stimmen beide Bewegungen überein, könne das Auftreten von Symptomen sogar vermindert werden (vgl. Wertheim 1998). Simulator Sickness könne also nur durch visuelle Reize oder in Kombination mit Bewegung in der Realität verursacht werden (vgl. Stoner et al. 2011).

Die *sensory conflict Theory* von Reason und Brand ist nach Brooks eine der am weitesten akzeptierten Theorie zu Simulator Sickness (vgl. Brooks et al. 2010). Sie beschreibt, dass ein Konflikt entstehe, wenn visuelles und vestibuläres System widersprüchliche Informationen empfingen oder diese nicht mit den mentalen Erwartungen übereinstimmten (vgl. Reason und Brand 1975; nach Brooks et al. 2010). Diese Widersprüchlichkeiten können sowohl bei Eigenbewegung als auch bei Bewegung der Umgebung und eigenem Stillstand beobachtet werden (vgl. ebd.). Weitere gängige Theorien sind die *postural instability Theory* von Riccio und Stoffregen (vgl. Riccio und Stoffregen 1991) oder die *eye movement Theory* von Ebenholtz (vgl. Ebenholtz 1992). Warum die spezifischen Symptome ausgelöst werden, erklärt z.B. Treisman damit, dass das Gehirn sensorische Fehlanpassungen als Zeichen einer Vergiftung interpretiere und ein Abwehrprogramm auslöse, um sich zu schützen (vgl. Treisman 1977; nach Brooks et al. 2010).

Die Auswirkungen unterscheiden sich im Wesentlichen in der Stärke und Häufung der auftretenden Symptome (vgl. Kennedy et al. 1993). Während Symptome, welche durch Bewegung verursacht werden, in der Regel der

Gruppe Übelkeit zuzuordnen seien, träten bei visuell verursachten Symptomen jene aus den Gruppen Desorientierung und Okulomotorik in den Vordergrund (vgl. ebd.). Weech et al. beobachteten, dass während viele Personen Symptome erlebten, andere scheinbar immun seien (vgl. Weech et al. 2019). Individuelle Merkmale wie Erfahrung, Alter, Geschlecht oder mentaler- und gesundheitlicher Zustand gäben weitere Hinweise für das verstärkte Auftreten von Symptomen (vgl. Stanney et al. 1998).

Auch wenn in diesem Forschungsbereich teilweise unterschiedliche Begrifflichkeiten verwendet werden, besteht jedoch Einigkeit darin, dass alle Formen von Bewegungskrankheiten ein großes Problem bei verschiedenen Technologien darstellen können und genauer betrachtet werden müssen (vgl. Brooks et al. 2010; Stoner et al. 2011; Dziuda et al. 2014; Bos et al. 2010; Stanney et al. 1998; Weech et al. 2019). Besonders im Forschungskontext führe Unwohlsein der VPs zu einer möglichen Verfälschung der Daten, weil bspw. Kopf- und Augenbewegung vermieden oder sie die Motivation verlieren würden (vgl. Stoner et al. 2011). Die gestellten Aufgaben können zum Teil gar nicht oder schlechter ausgeführt werden, da ebenfalls eine negative Auswirkung auf kognitive und psychomotorische Kontrolle dokumentiert wurde (vgl. Stanney et al. 1998; Cobb et al. 1999; Bos 2015). Zudem müssen Versuche häufiger vorzeitig abgebrochen werden, weil die Symptome zu stark werden (vgl. Brooks et al. 2010; Stoner et al. 2011).

Für eine sinnvolle Bewertung der Nützlichkeit des Trainings im Forschungskontext müssen negative Effekte von Simulator Sickness bei der Entwicklung berücksichtigt und in der anschließenden Evaluation betrachtet werden.

2.2.2 Präsenz

Präsenz ist ein psychologischer Zustand, der von Witmer und Singer beschrieben wird, als "[...] subjective experience of being in one place or environment, even when one is physically situated in another" (Witmer und Singer 1998, 225). Um Präsenz zu erleben, sei sowohl *Involvement* als auch *Immersion* notwendig (vgl. Witmer und Singer 1998). *Involvement*

hänge davon ab, wie gut die Aktivitäten und Ereignisse die Aufmerksamkeit einer Person auf sich ziehen und halten (vgl. ebd.). Außerdem vom Grad der Bedeutung, die eine Person der Aufgabe beimisst. *Immersion* beschreibe demnach den Zustand, in dem sich eine Person in die Umgebung einbezogen fühle (vgl. ebd.). Isolation von der physischen Umgebung, natürliche Interaktions- und Kontrollmöglichkeiten sowie die Wahrnehmung der eigenen Bewegung trage demnach dazu bei, *Immersion* zu verstärken (vgl. ebd.). Je mehr *Involvement* und *Immersion* vorhanden seien, desto stärker empfinde eine Person Präsenz (vgl. ebd.). Eine gesteigerte Präsenz fördere vor allem realistischere Entscheidungen in der virtuellen Umgebung und verbessere somit die Ergebnisse (vgl. ebd.).

Zudem wird ein positiver Zusammenhang zwischen einer höheren Präsenz und der Aufgabenleistung beobachtet, denn Faktoren, die zur Immersion beitragen, seien auch förderlich in Bezug auf das Lernen, die Leistung und die Motivation (vgl. ebd.). Ein Nachteil von starker Präsenz in virtuellen Umgebungen sei, dass Personen Desorientierung oder Angst empfinden können, wenn sie aus der virtuellen in die reale Welt zurückkehren (vgl. ebd.).

Ein Zusammenhang zwischen Simulator Sickness und Präsenz wird ebenfalls untersucht. Einerseits wird angenommen, dass hohe Präsenz die Simulator Sickness unterdrücken könne, da die Aufmerksamkeit auf die Umgebung gerichtet sei und somit von den Symptomen ablenke (vgl. Weech et al. 2019). Andererseits könne das Auftreten von Symptomen die Aufmerksamkeit von der virtuellen Umgebung weglenken und dadurch das Auftreten von Präsenz verhindern (vgl. ebd.).

2.2.3 Akzeptanz

Akzeptanz beschreibt im Allgemeinen die Bereitschaft einer Person, etwas anzunehmen oder hinzunehmen. Bei der Betrachtung von menschlichen Einflussfaktoren spiele das psychologische Konstrukt von Akzeptanz gegenüber neuen Technologien oder Systemkonfigurationen eine große Rolle (vgl. Szalma 2012).

Das Technology Acceptance Model (TAM) nach Davis beschreibt das Verhalten von Personen bei der Nutzung von Computeranwendungen, wobei die wahrgenommene Nützlichkeit sowie Benutzerfreundlichkeit betrachtet werden (vgl. Davis et al. 1989). Demnach belegen die Arbeiten zum TAM, dass die Berücksichtigung von Faktoren, welche die Motivation beeinflussen, zu positiven Ergebnissen, also zur Akzeptanz der Technologie führe (vgl. ebd.). Das Model basiere auf der Motivationstheorie, welche verschiede Erklärungsansätze z.B. aus psychologischer, soziologischer oder pädagogischer Sicht liefere und beschreibe, warum eine Person eine bestimmte Handlung ausführe (vgl. Schmid 2022).

Die Motivationsgestaltung solle demnach einen Fokus auf die intrinsische Motivation bei der Nutzung der Schnittstelle legen (vgl. Szalma 2014). Also die persönliche Bedürfnisbefriedigung, die eine Person aus einem bestimmten Verhalten ziehe (vgl. ebd.). Um die Akzeptanz einer Technologie zu erhöhen, seien motivierende Auswirkungen von entscheidender Bedeutung. Diese müssen für das Erreichen erfolgreicher Ergebnisse in Bezug auf Benutzerfreundlichkeit, Leistung, verringerte Arbeitsbelastung und Stress berücksichtigt werden (vgl. ebd.).

2.3 Gamification

Die geläufigste Definition von Deterding beschreibt Gamification als "[...] use of game design elements in non-game contexts " (vgl. Deterding et al. 2011, 10). Ähnlich wie Serious Games seien "gamifizierte" Anwendungen nicht primär auf Unterhaltung ausgelegt (vgl. Deterding et al. 2011). Während Serious Games allerdings alle notwendigen Bedingungen erfüllten, um Spiele zu sein, kämen bei Gamification lediglich einige Gestaltungselemente oder Mechaniken von Spielen zum Einsatz (vgl. ebd.). Gängige Elemente seien Punkte, Abzeichen, Level und Ranglisten (vgl. Hamari et al. 2014).

Nach Koivisto und Hamari sei Gamification ein beliebtes Thema für wissenschaftliche Untersuchungen, die Popularität von gamifizierten Anwendungen sei in den letzten Jahren sprunghaft angestiegen und spiegle

sich auch in einer rasch zunehmenden Zahl von Forschungsarbeiten wider (vgl. Koivisto und Hamari 2019).

Die Mehrheit der untersuchten Studien kämen zu dem Schluss, dass der gezielte Einsatz von Gamification vor allem im Bildungs-/Lernkontexten positive Auswirkungen und Vorteile haben könne (vgl. Hamari et al. 2014; Koivisto und Hamari 2019). Berichtet werde Beispielsweise über positive Ergebnisse im Hinblick auf eine gesteigerte Motivation, ein höheres Engagement sowie Spaß bei Lernaufgaben (vgl. Hamari et al. 2014). Bei entsprechendem Einsatz von Gamification könne der Spieltrieb des Menschen genutzt werden, um die Konzentration und Aufmerksamkeit einer Person auf eine bestimmte Aufgabe zu lenken (vgl. ebd.). Durch positives Feedback können gewollte Handlungen weiter bestärkt werden (vgl. Sailer 2016).

Gleichzeitig weisen Studien auch auf negative Ergebnisse hin, die bei der Enwicklung beachtet werden müssen. Ein Beispiel sind die Auswirkungen eines verstärkten Wettbewerbs durch den Einsatzt von Ranglisten. Bei schlechteren Ergebnissen könne dies zu Unsicherheit und Demotivation führen (vgl. Hamari et al. 2014). Koivisto und Hamari bieten einen umfassenden Überblick zu möglichen negativen Auswirkungen von Gamification (vgl. Koivisto und Hamari 2019). Heinz und Fischer betrachten ebenfalls Risiken und Nebenwirkungen eines zunehmend „gamifizierten“ Alltags und weisen darauf hin, dass vor allem der Kontext und die Art des Einsatzes eine entscheidende Rolle spiele (vgl. Heinz und Fischer 2020).

Eine experimentelle Studie von Sailer zeigt, dass der Einsatz von Gamification einen positiven Effekt auf die Erfüllung der psychologischen Grundbedürfnisse haben könne und sowohl auf qualitative als auch auf quantitative Formen von Leistung positiv wirke (vgl. Sailer 2016). Demnach diene Deci und Ryans Selbstbestimmungstheorie der Motivation, welche auf dem Konzept der Bedürfnisbefriedigung beruhe, als geeignetes psychologisches Modell zur Erforschung der Wirkung von Gamification (vgl. Deci und Ryan 1985; nach Sailer 2016). Für eine wissenschaftliche Auseinandersetzung mit dem Konzept Gamification sollen demnach die Auswirkungen auf die Motivation und die Leistung im Mittelpunkt stehen

(ebd.). Die motivierenden Faktoren können, wie in den vorangegangen Kapiteln beschrieben, eine positive Wirkung auf die zu betrachtenden Variablen Präsenz (vgl. Witmer und Singer 1998), Akzeptanz (vgl. Davis 1985) und den Trainingserfolg (vgl. Sailer 2016) haben.

Nach Bos könne das gezielte Lenken der Aufmerksamkeit auf eine Aufgabe die Symptome der Simulator Sickness positiv beeinflussen (vgl. Bos 2015). Wenn die Aufmerksamkeit vom Bewegungsablauf weg und hin zur Aufgabe gelenkt werde, könne die Bewegung unterbewusster ablaufen und auftretende Unstimmigkeiten in der Simulation weniger wahrgenommen werden (vgl. ebd.). Nach Witmer und Singer könne durch die erhöte Aufmerksamkeit ebenfalls das Präsenz-Level und der Trainingserfolg gesteigert werden (vgl. Witmer und Singer 1998).

Es ist zu erwarten, dass Gamification durch ihre positiven Eigenschaften zur Verbesserung des Trainings insgesamt beitragen kann. Der Trainingserfolg sollte demzufolge erhöht und Störungen verringert werden, wenn die Gamification-Elemente gezielt Motivation und Aufmerksamkeit steigern. Jedoch sollten dabei mögliche negative Faktoren ebenfalls im Blick behalten werden.

3 Anforderungen

Die wichtigsten Anforderungen für das Training wurden in Expertenrunden innerhalb der Gruppe MZS und anhand der vorliegenden Literatur zu den in Kapitel 2 beschriebenen Themengebieten festgelegt (Tabelle 2).

ID	Anforderung
A01	Systematisches, wiederholbares, standardisiertes, vergleichbares Training
A02	Unterstützung wichtiger Bewegungsabfolgen/Manöver (Kurven, Beschleunigen, Anfahren, Bremsen, Slalom)
A03	Progressiver Schwierigkeitsgrad
A04	Wiederholung von Bewegungsabfolgen
A05	Grafisch ansprechende Umgebung
A06	Anpassbarkeit Szenarios und Umgebung (Modular)
A07	Überschaubarer Zeitrahmen oder Lernziel
A08	Variante des Trainings
A09	Gesteigerte Präsenz und Immersion
A10	Geringe Simulation Sickness
A11	Schnittstelle zur UE (bspw. als Plugin)
A12	Performance (VR optimiert)

Tabelle 2: Anforderungen

In den folgenden Abschnitten werden, die aufgeführten Anforderungen genauer erläutert.

A01 Systematisches, wiederholbares, standardisiertes, vergleichbares Training

Das Training soll weitestgehend standardisiert ablaufen, um die Trainingserfahrungen der VPs untereinander vergleichbar zu machen. Das Training soll in verschiedene Szenarios unterteilt werden, in denen die VPs von einem Startpunkt aus einem vorgegebenen Streckenabschnitt folgen sollen. Um eine Reproduzierbarkeit des Trainings zu erreichen, sollen die Szenarios in derselben Reihenfolge mit einer entsprechenden Anweisung und einem festgelegten Ziel durchgeführt werden.

A02 Unterstützung wichtiger Bewegungsabfolgen/Manöver

Das Training soll den VPs die Möglichkeit bieten, die wichtigsten und schwierigsten Bewegungsabfolgen (Anfahren, Beschleunigen, Kurven und Bremsen) auf dem Fahrradsimulator zu erproben. Die Szenarios müssen so gestellt sein, dass alle wichtigen Bewegungsabfolgen und Manöver vorkommen. Daher muss der Aufbau der Trainingsumgebung die Möglichkeit bieten, verschiedene Streckenabschnitte zu definieren, die das Einüben der entsprechenden Bewegungsabfolgen ermöglichen.

A03 Progressiver Schwierigkeitsgrad

Um VPs einen möglichst leichten Einstieg zu ermöglichen, soll das Training einfach beginnen z.B. mit einem Abschnitt, auf dem nur geradeaus gefahren werden muss. Im Laufe des Trainings soll der Schwierigkeitsgrad der Szenarios mit verschiedenen Kurven und Aufgaben zunehmen. Ein Grundsatz bei der Gestaltung von Trainingsprozessen sei nach Schröder das Prinzip der progressiven Steigerung (vgl. Schröder 2010).

A04 Wiederholung von Bewegungsabfolgen

Die wichtigsten Bewegungsabfolgen müssen wiederholt werden, damit die VPs in der Hauptfahrt auf die Situation vorbereitet sind und wissen, wie das Fahrrad reagiert. Ein häufig angewandter Lernansatz für motorische Prozesse sei die Wiederholung einer Bewegung, dennoch sei zu beachten, dass eine Variabilität zwischen den Lernaufgaben den Lernprozess beschleunige (vgl. Schöllhorn et al. 2009). So sollen Aufgaben zwar wiederholt werden, jedoch mit leichter Variation der Bedingungen (vgl. ebd.).

A05 Grafisch ansprechende Umgebung

Eine grafisch ansprechende Umgebung des Trainings soll zur Steigerung der Immersion und somit zur Ablenkung des Nutzers von Dissonanzen zwischen physischer und visueller Bewegung in der VR beitragen (vgl. Stoner et al. 2011). Nach Bos sei zu erwarten, dass mentale Ablenkung einen positiven Effekt auf die Aufgabenleistung habe (vgl. Bos 2015). Um die Ablenkung der VPs weiter zu erhöhen, sollte die Umgebung genügend ansprechende und stimmigen Details bereithalten. Jedoch sollte auch darauf geachtet werden, die Umgebung nicht zu überladen. Zum Beispiel wirke sich regelmäßig widerholende Objekte entlang der Strecke negativ auf das Erlebnis der VPs und Simulator Sickness aus (vgl. Stoner et al. 2011). Eine helle, freundliche Gestaltung und eine gute Übersicht vermittle eine positive Grundstimmung (vgl. Jerald 2015).

A06 Anpassbarkeit Szenarios und Umgebung (Modular)

Damit das Training in Zukunft angepasst und verbessert werden kann, müssen Szenarios und Map bearbeitet werden können. Anpassungen wie das Hinzufügen von weiteren Szenarios, einen Wechsel der bestehenden Reihenfolge oder das Austauschen von Sammelitems/Markierungen, die das Training verbessern könnten, sollen durch Modularität einfach umsetzbar sein.

A07 Überschaubarer Zeitrahmen oder Lernziel

Das Training soll in einem überschaubaren Zeitrahmen oder mit festgelegtem Ziel abgehandelt werden können. Dafür soll ein vordefiniertes Ziel als Endbedingung des Trainings festgelegt werden.

Nach Kennedy solle eine belastende Situation nicht länger als 20-30 Minuten andauern oder Pausen eingeplant werden (vgl. Kennedy et al. 2000). Nach Beendigung der Exposition nähme die Intensität der Symptome i.d.R. nach wenigen Minuten stark ab (vgl. ebd.). Da die VPs im Anschluss noch

die eigentliche Versuchsfahrt absolvieren, soll das Training nicht länger als 5-7 min dauern und ggf. eine Pause folgen.

A08 Variante des Trainings

Wie in 2.3 Beschrieben, könnte Gamification dazu beitragen das Training zu verbessern. Um dies zu überprüfen, müssen zwei verschiedene Varianten entwickelt werden, von denen eine Gamification-Elemente enthält.

Deterding et al. beschreiben Gamification-Elemente als charakteristische Elemente, welche in den meisten, aber nicht in allen Spielen zu finden seien und eine wichtige Rolle im Rahmen des Spielablaufs haben (vgl. Deterding et al. 2011). Als entsprechende Elemente kommen bspw. Punkte, Abzeichen, (Team-) Bestenlisten, Leistungsgraphen, Narrative und Avatare in Betracht da diese einen positiven Effekt auf die Erfüllung der psychologischen Grundbedürfnisse sowie auf qualitative und quantitative Formen von Leistung haben können (vgl. Sailer 2016).

A09 Gesteigerte Präsenz und Immersion

Nach Beendigung des Trainings sollen sich VPs bereits auf einem guten Präsenzlevel befinden und sich möglichst gut als Teil der Simulation empfinden. Sowie in 2.2.2 beschrieben, ist die Erwartung dahinter, dass Testpersonen mit hoher Präsenz zunehmend Entscheidungen träfen, die sie auch in der Realität unter vergleichbaren Umständen getroffen hätten (vgl. Witmer und Singer 1998).

A10 Geringe Simulator Sickness

Das Training soll möglichst wenig Simulator Sickness bei den VPs auslösen. Wie in 2.2.1 beschrieben, können auftretenden Symptome zu unerwünschten Nebeneffekten führen.

Bei der Ausgestaltung des Trainings soll darauf geachtet werden, dass insbesondere die Performance der Simulation in allen Trainingsszenarien ein akzeptables Level erreiche und wenig Latenzen aufweise (vgl. Jerald 2015).

Bei der Erstellung von Szenarios soll beachtet werden, dass schnelle Richtungsänderungen und die Anzahl von starken Abbremsungen schneller zu Simulator Sickness führen können. Auch enge Kurven und schnelle Rechts-Linkswechsel sind dafür bekannt, dass sie die Wahrscheinlichkeit erhöhen, dass Symptome auftreten (vgl. Stoner et al. 2011).

Die virtuelle Umgebung soll so gestaltet sein, dass ein Großteil des Horizonts die meiste Zeit zu sehen sei (vgl. ebd.). Zudem solle die regelmäßige Wiederholung von Objekten am Seitenrand vermieden werden (vgl. ebd.).

A11 Schnittstelle zur UE

Das Training soll als eigenständiges Plugin für die UE 5.1 entwickelt werden. Dabei müssen entsprechende Schnittstellen für den Simulator sowie das Logging-System Dominion bereitgestellt werden.

A12 Performance (VR optimiert)

Um die Perfomance in VR zu erhöhen, empfiehlt Jerald die Verwendung verschiedener LODs und eine Reduzierung von Polygonen und Texturen (vgl. Jerald 2015) Zudem können weitere Einstellungen in der UE 5.1 so angepasst werden, dass die VR-Performance (deutlich) verbessert wird.

4 Konzeptplanung

Im Anschluss an die Anforderungserhebung wird auf dieser Basis das Konzept für die konkrete Umsetzung entwickelt. Insbesondere die Strukturierung und der Ablauf des Trainings und der Szenarios müssen vorab geklärt sein. Zudem ist es für die Projektplanung sinnvoll, die Wahl und Gestaltung der virtuellen Umgebung und der zum Einsatz kommenden Gamification-Elemente zu berücksichtigen.

Das in Abb. 4 dargestellte Use Case Diagramm bietet eine Übersicht der verschiedenen Anwendungsfälle sowie deren Beziehung untereinander und zu den Akteuren VL und VP.

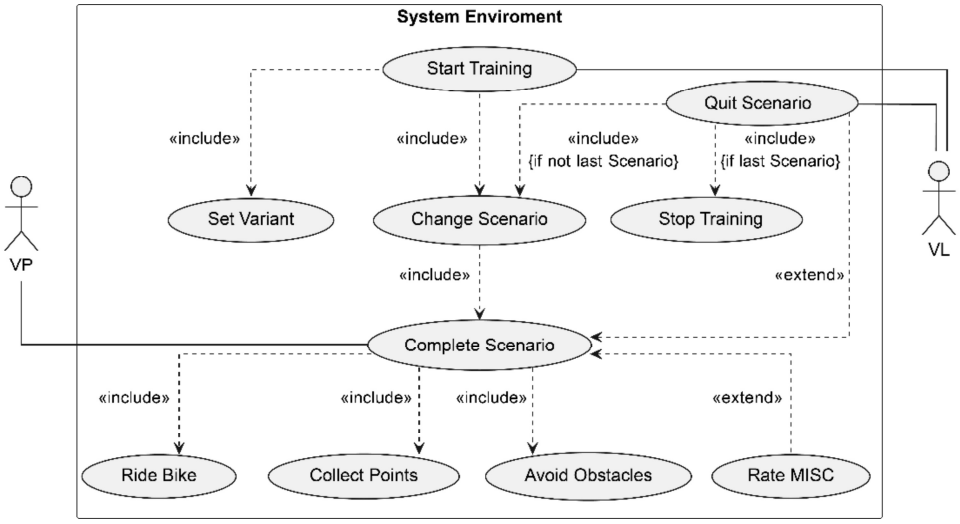


Abb. 4: Use Case Diagramm (Eigene Darstellung, 2024)

Die VL startet das Training und bestimmt die Variante. Wenn die VP das Szenario abgeschlossen hat, wechselt die VL zum nächsten Szenario. Beim Auftreten von Problemen wie bspw. dem Abkommen von der Strecke kann die VL das Szenario vorzeitig abbrechen und ggf. neustarten. Sind alle Szenarios durchlaufen, wird das Training von der VL gestoppt. Um ein Szenario abzuschließen, muss die VP mit dem Fahrradsimulator, dem durch sammelbare Objekte dargestellten Pfad folgen und den Hindernissen ausweichen. Am Ende jedes Szenarios bewertet die VP ihr Wohlbefinden anhand der MISC.

4.1 Trainingsumgebung

Den Anforderungen entsprechend muss die gewählte Umgebung so strukturiert sein, dass alle beschriebenen Szenarios umgesetzt werden können. Innerhalb der Forschungsgruppe ist bereits eine digitalisierte Version des in direkter Nachbarschaft befindlichen ADAC-Übungsplatzes (Abb. 5) vorhanden. Der größte Verkehrsübungsplatz in der Region Braunschweig bietet auf seinem etwa 2 km langen Straßennetz nahezu alle Möglichkeiten, um die wesentlichen Standardsituationen im öffentlichen Straßenverkehr zu trainieren und eignet sich daher ideal als Trainingsumgebung.

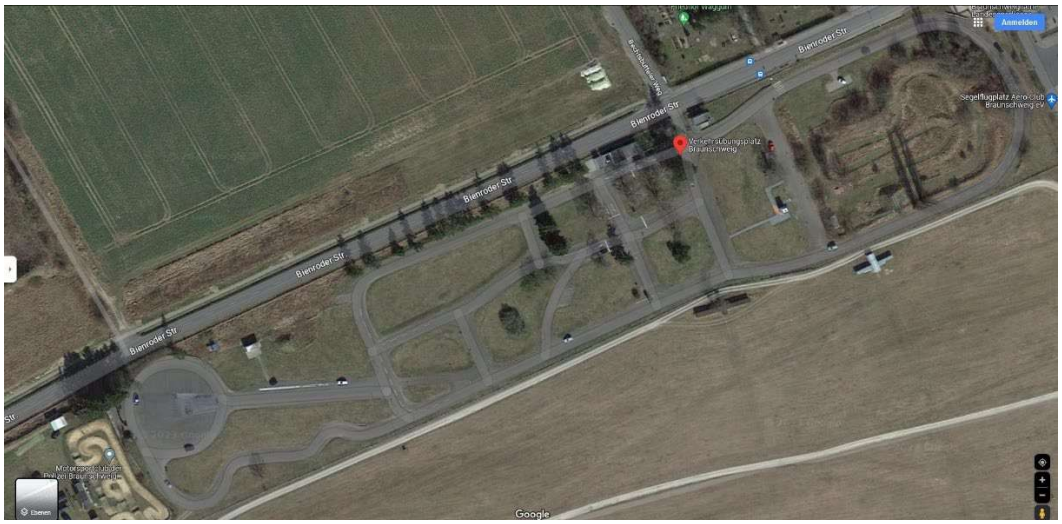


Abb. 5: ADAC-Verkehrsübungsplatz, Braunschweig, DE (Google Maps, 2023)

Durch die Entscheidung für den in der Realität vorhandenen Verkehrsübungsplatz ergibt sich zudem die Planung einer Folgestudie zur Validierung des Fahrradsimulators. Die reale Strecke soll mit dem Forschungsfahrrad BoBBi abgefahren und mit der virtuellen Map auf dem Fahrradsimulator verglichen werden. Dadurch entsteht die zusätzliche Anforderung, dass die Default-Variante möglichst detailgetreu in der Realität reproduzierbar sein soll. Die Pfadmarkierungen müssen in der virtuellen Umgebung so dargestellt werden, dass sie z.B. mit Sprühkreide auf den realen Übungsplatz übertragen werden können. Außerdem muss bei der Platzierung der Szenarios darauf geachtet werden, dass sich die Pfade nicht überschneiden. In Tabelle 3 werden die entsprechenden Anforderungen zum Realismus aufgeführt.

ID	Realismus
RA01	Strecke muss dem Maßstab des ADAC-Übungspatz entsprechen
RA02	Szenarios mit unterschiedlichen Pfaden dürfen sich nicht überschneiden
RA03	Pfadmarkierungen müssen in der Realität umsetzbar sein
RA04	Start und Ende müssen in der Realität umsetzbar sein

Tabelle 3: Realismus Anforderungen

4.2 Trainingsszenarios

Aus den aufgestellten Anforderungen ist bereits zu entnehmen, dass es als sinnvoll erachtet wird, das Training als aufeinander folgende Szenarios auszugestalten. In diesem Sinne handelt es sich bei einem Szenario um einen vorgegebenen Pfad, dem eine VP vom Start- bis Endpunkt folgt und dort bis zum Stillstand kontrolliert abbremsen soll. Die Szenarios können von der VL durchgeschaltet werden.

Anhand einer festgelegten Anzahl und Reihenfolge von vordefinierten Szenarios ist das Training für verschiedene VPs reproduzierbar (A01), weist einen progressiven Schwierigkeitsgrad auf (A03) und unterstütz die wichtigsten Bewegungsabläufe sowie deren Wiederholung (A02 und A04). Zudem ist es durch diesen Aufbau jederzeit möglich, den Trainingsablauf und somit auch den Zeitlichen Aufwand, unabhängig der Umgebung, anzupassen (A06 und A07). Damit sich die VPs erstmal an die Bewegung des Simulators gewöhnen können, werden die ersten Szenarios anstatt mit HMD unter Verwendung der angeschlossenen Monitore absolviert.

Bei der Erstellung von Szenarios wird darauf geachtet, dass schnelle Richtungsänderungen und scharfe Kurven sowie eine hohe Anzahl von starken Abbremsungen möglichst vermieden werden (A10). Für den Wechsel zwischen den Szenarios wird eine *Fade In* bzw. *Fade Out* eingesetzt, damit die Transformation nicht zu Simulator Sickness führt (A10).

Entsprechend der RA02 werden die Szenarios so platziert, dass sie sich nicht überschneiden. Die Grafik in Abb. 6 zeigt die Platzierungen der Szenarios, die Pfade werden in unterschiedlichen Farben dargestellt. Der Anfang eines Pfads wird durch ein Dreieck und das Ende durch einen Kreis dargestellt.

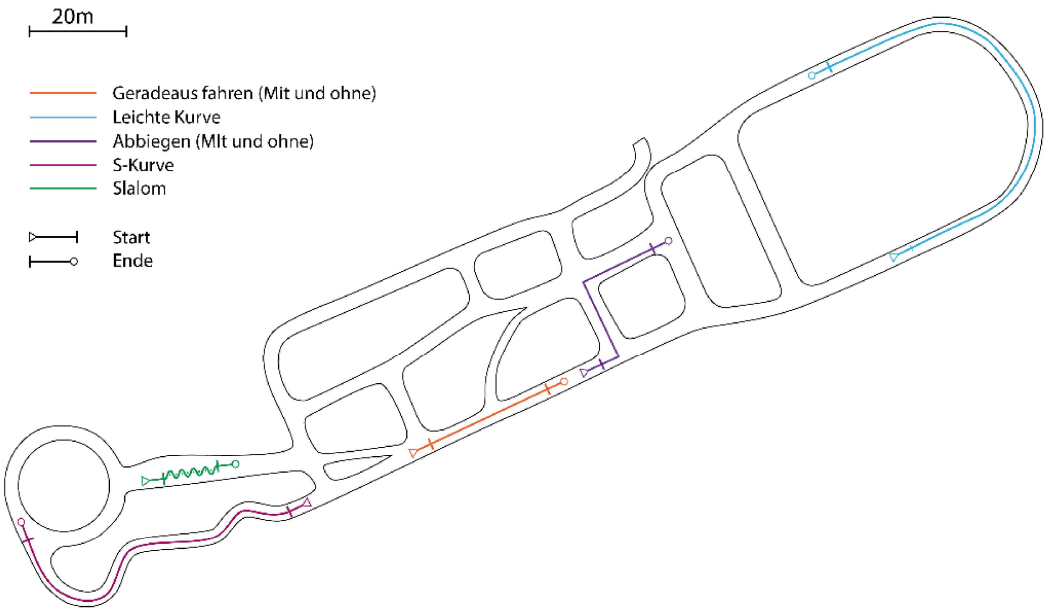


Abb. 6: Verteilung der Szenarios auf der Strecke (Eigene Darstellung, 2024)

4.3 Gamification-Elemente

Für die Umsetzung der beiden Varianten Gamify und Default (A08) muss zunächst bestimmt werden, welche Elemente sich unterscheiden sollen. Die Umgebung und die Szenarios bleiben in beiden Varianten unverändert.

Bei der Entwicklung der Gamification-Elemente wird der Fokus auf die Elemente gelegt, die eine intrinsische Motivation vor allem durch Feedback und Belohnungseffekte fördern. Durch ein höheres Engagement, Spaß bei den Aufgaben und gezieltes Lenken der Aufmerksamkeit werde eine gesteigerte Leistung bzw. Lernerfolg erzielt (vgl. Sailer 2016).

Das Sammeln von Punkten wird als Belohnung und Feedback eingesetzt. Die VP erhält eine sofortige positive Rückmeldung bei erwünschtem Verhalten. Feedback könne eine gewünschte Handlung bestärken (vgl. Jerald 2015). Damit das Einsammeln von Punkten ein positives Feedback vermittelt, erfolgt eine auditive sowie visuelle Rückmeldung, wenn Sammelobjekte berührt werden. Der Pfad, den die VP abfahren soll, wird zusätzlich durch diese Objekte visualisiert. Das Ziel wird somit klar verständlich. Das Erreichen der Haltelinie wird ebenfalls mit positivem Feedback belohnt.

Als weiteres Feedbacksystem wird eine Punkteanzeige mit Informationen zum persönlichen Fortschritt verwendet. Auf diese Weise besteht die Möglichkeit, die eigene Leistung zu evaluieren und einzuordnen. Eine individuelle Information zur Leistung wirke sich vorteilhaft auf die Motivation aus (vgl. Sailer 2016). Die VP bekommt daher im Anschluss ihre gesammelten Punkte, Kollisionen mit Hindernissen und die benötigte Zeit auf einer Tafel angezeigt. Die Verwendung einer Bestenliste wird zwar innerhalb der Gruppe diskutiert, jedoch wird darauf verzichtet, weil eine Konkurrenzebene negative Auswirkungen haben könne, vor allem bei Misserfolg (vgl. Hamari et al. 2014).

5 Umsetzung

Auf Basis des zuvor entwickelten Konzepts erfolgt im nächsten Schritt die konkrete Umsetzung des Trainings in der UE5.1.

Im Folgenden werden die verschiedenen Entwicklungsschritte im Detail betrachtet. Die Strecke, das Fahrrad und andere selbst erstellte Assets werden in Blender modelliert und in die UE importiert. Zur Ausgestaltung der Umgebung werden zusätzlich verschiedene *Asset Packs* aus dem *UE-Marketplace*[1] verwendet (siehe: Anhang A). Die entsprechende Logik wird mit Blueprints (BP) umgesetzt und als Plugin BikeSimTraining (BST) bereitgestellt.

Zuletzt wird das Training mit internen DLR-Plugins für das Loggen der Fahrdaten und zur Kopplung mit der Labor-Hardware in dem UE-Projekt BiTS (Bike Sim Training Study) zusammengeführt. Die erstellten BPs sind in Anhang B zu finden.

5.1 Modellierung und Anpassung der Assets

Bevor auf die Entwicklung der Logikkomponenten eingegangen wird, erfolgt zunächst eine genauere Beschreibung der Modellierung eigener Assets und notwendige Anpassungen bereits vorhandener Komponenten mit Blender[2] sowie die Ausgestaltung der Trainings-Map und des Sounddesigns in der UE.

5.1.1 Map

Am Institut wurde mit Hilfe von TRIAN[3] aus Luftaufnahmen des ADAC-Übungsplatz bereits ein 3D-Modell erstellt und als UE- Projekt umgesetzt. Da nur das UE-Projekt zur Verfügung stand, musste das aus vielen einzelnen *Planes* bestehende Modell der Strecke zur weiteren Bearbeitung als FBX exportiert werden (RA01).

[1] https://www.unrealengine.com/marketplace/en-US/store
[2] https://www.blender.org
[3] https://trian3dbuilder.de

In Blender werden verschiedene Änderungen an den bestehenden 3D-Meshes vorgenommen, um einen realistischeren Eindruck zu erzeugen. Nach dem Zusammenfügen der einzelnen Streckenteile entsteht zunächst eine einzelne *Plane*, welche als Grundlage für das Modell dient (Abb. 7). Diese wird extrudiert, um ein geschlossenes Objekt zu erhalten. Außerdem wird entlang des Streckenrandes eine abgerundete und etwas ungleichmäßige Kante modelliert. Durch eine zusätzliche Umrandung wird der Übergang zum umgebenden Boden erleichtert.

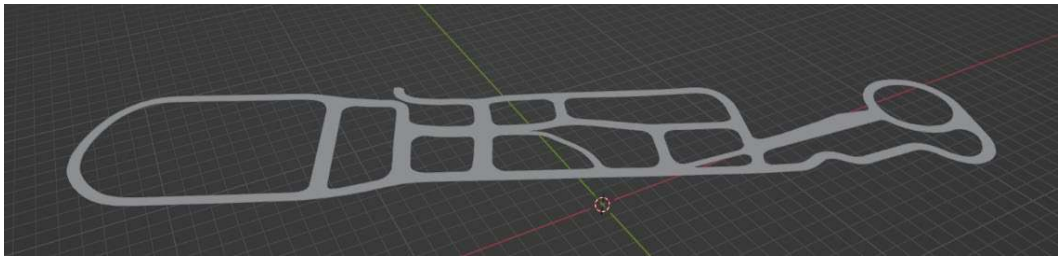


Abb. 7: Modellierung der Strecke in Blender (Eigene Darstellung, 2024)

Danach werden die Meshes in die UE importiert und in einer neu angelegten Map in der Szene platziert. Durch das Anlegen einer *Landscape* wird der Boden um die Strecke herum gestaltet. Unebenheiten, Struktur- und Farbunterschiede vermitteln einen realistischeren Eindruck von der Umgebung. Objekte wie Bäume, Büsche, Gräser, Gebäude und kleinere Gegenstände werden aus verschiedenen *Asset Packs* zusammengestellt und in der Szene platziert. Hierbei wird vor allem darauf geachtet, dass die Umgebung möglichst realistisch aussieht (A09), jedoch werden einige Details zugunsten der Performance in reduzierter Form dargestellt. Zum Beispiel wird darauf verzichtet, den Boden vollständig mit verschiedenen Gräsern zu überziehen. Ebenfalls wir der das Gelände umringende Zaun weggelassen. Die Engmaschige Musterwiederholung kann zu Kantenflimmern führen und sich somit negativ auf das Wohlbefinden der VPs auswirken (A10 und A12). In Abb. 8 befinden sich auf der linken Seite Fotos, die zuvor aufgenommen und als Referenz genutzt werden. Auf der rechten Seite ist der entsprechende Ausschnitt der virtuellen Nachbildung in der UE5 zu sehen.

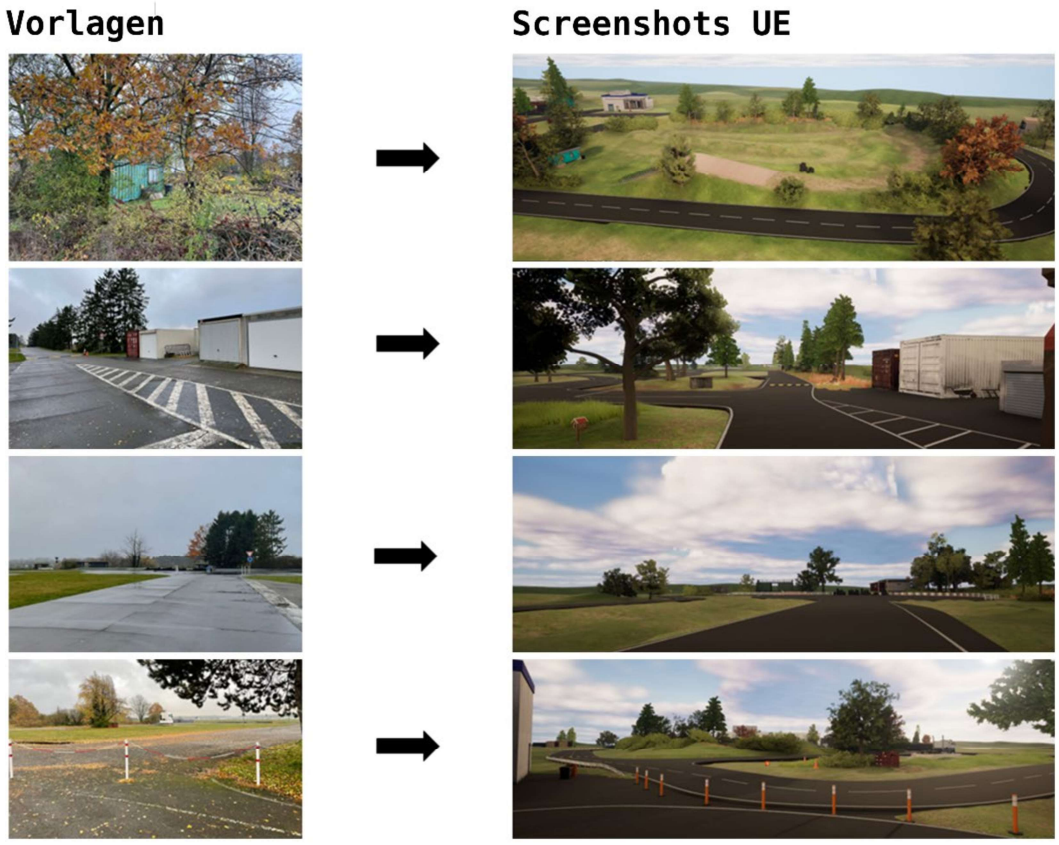


Abb. 8: Fotos und Screenshot in der UE (Eigene Darstellung, 2024)

Damit Straßenmarkierungen in der UE an den richtigen Stellen übertragen werden können, wird in Blender eine UV-Map mit den entsprechenden Markierungen angelegt. Für die zugewiesene Grafik werden Seitenstreifen und Mittellinie mit Illustrator anhand der Satellitenbilder nachgezogen.

Da die auf diese Weise erzeugte UV-Map (Abb. 9A) eine zu geringe Auflösung aufweist und das Resultat in der UE5.1 dementsprechend kein zufriedenstellendes Ergebnis liefert (Abb. 9B), dient die UV-Map nur als Vorlage für die Platzierung der Fahrbahnelemente. Die grundlegende Texturierung der Strecke erfolgt durch die Zuweisung eines prozeduralen Asphaltmaterials (Abb. 9D). Um die Platzierung der Fahrbahnelemente zu erleichtern, werden neben den BPs für die Trainingslogik die BPs für die Straßenmarkierung erstellt. Diese ermöglichen eine (teil-)automatisierte Übertragung der entsprechenden Elemente (Abb. 9C). Entlang eines Splines werden die Meshes platziert, dabei kann für die gestrichelten Markierungen zusätzlich ein Offset zwischen den Meshes gesetzt werden.

Da die BPs für die Straßenmarkierungen die Form und Textur der ausgewählten Objekte verzerrt darstellen, müssen hier Meshes und Materialien, die unabhängig einer möglichen Verzerrung ein visuell überzeugendes Ergebnis liefern, erstellt werden.

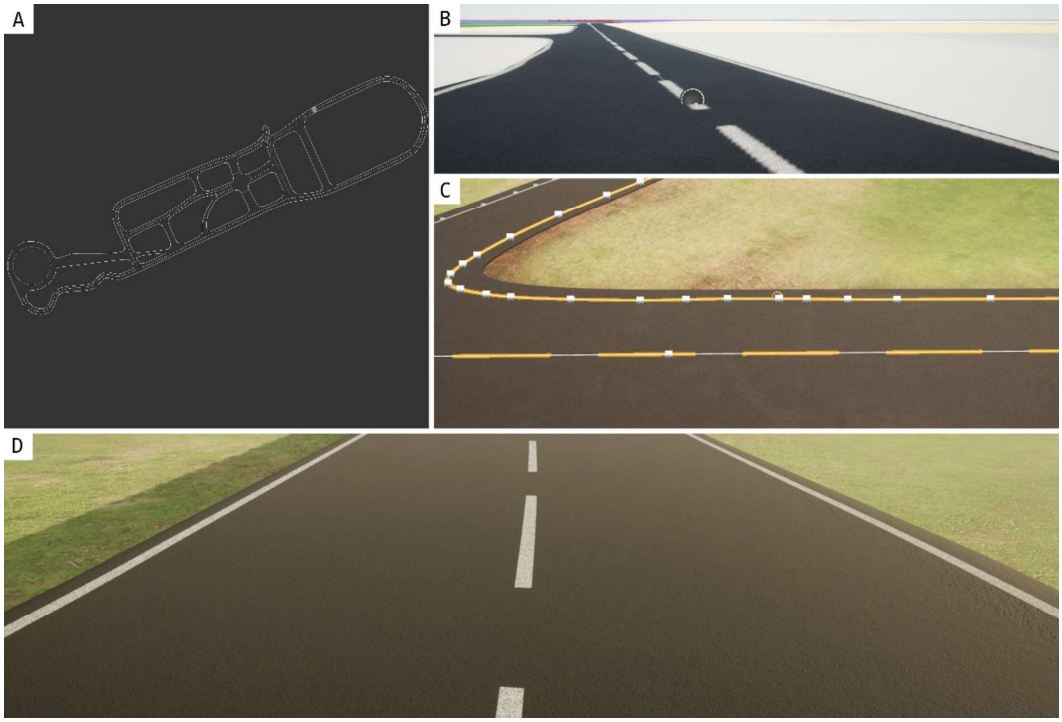


Abb. 9: Splines für die Straßenmarkierungen (Eigene Darstellung, 2024)

Die Schutzplanken werden ebenfalls mit Hilfe von Splines erstellt (Abb. 10). Damit die Form und Texturierung der Schutzplanken unverzerrt dargestellt wird, ist eine zusätzliche Funktion zur Beschränkung der Länge eines Segments nötig. So soll sichergestellt werden, dass die Form des Meshes für die Planken mit realistischen Maßen nur gebogen und nicht in der Länge verändert wird.

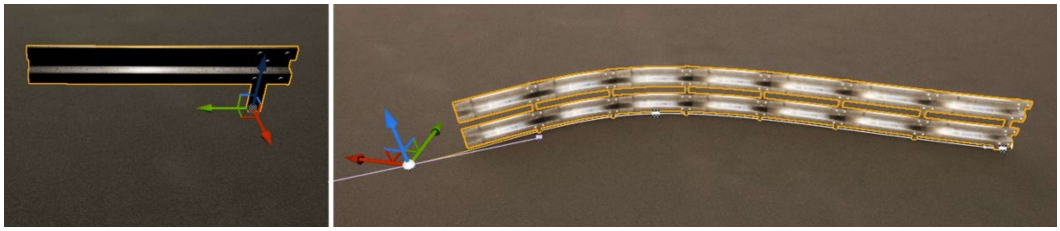


Abb. 10: Splines für Schutzplanken (Eigene Darstellung, 2024)

5.1.2 Streckenmarkierungen

Das Markieren von Start und Ende wird ein Mesh mit Halteline und zwei Verkehrshütchen erstellt (Abb. 11A). Damit die Haltelinie auch auf der realen Strecke dargestellt werden kann, ähnelt die Textur einer mit Sprühkreide aufgemalten Linie (RA04). Die Pfadmarkierung in der Default-Variante werden ebenfalls so gestaltet, dass sie auf der realen Strecke mit Sprühkreide gezeichnet werden können (RA03) (Abb. 11B). Dazu werden Zylinder mit einer Höhe von 2 mm, einem Durchmesser von 25 cm und einer Textur zur Darstellung der Kreidekreise erstellt. In der Gamify-Variante visualisieren Seifenblasen den Pfad (Abb. 11C). Sie sollen das Bedürfnis wecken, diese zerplatzen zu lassen. Dazu werden Kugeln erstellt, die sowie die Kreidekreise einen Durchmesser von 25 cm haben. In der UE wird ein transparentes Material mit Regenbogentextur erstellt und zugewiesen.

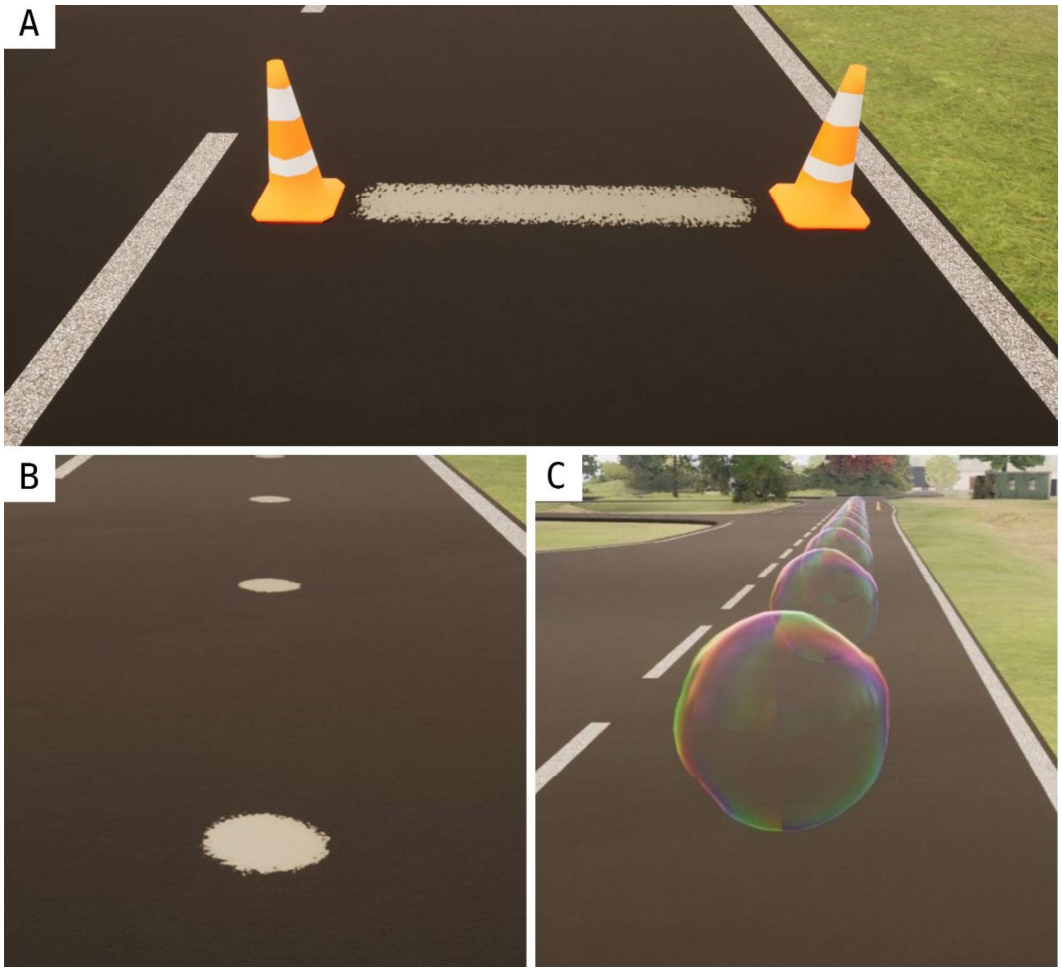


Abb. 11: Ziel-, Start- und Pfadmarkierungen (Eigene Darstellung, 2024)

5.1.3 Fahrrad

Zur Repräsentation des Fahrrads in der virtuellen Umgebung wird ein Modell mit beweglichen Segmenten verwendet (Abb. 12A). Das aktuelle Fahrradmodell wird durch ein angepasstes Modell ersetzt, welches eine Nachbildung des Originalfahrrads (Victoria Trekking 3.3 Wave (2020)) ist (Siehe: 2.1). Das Modell wird mit Hilfe von Fotos mit Bemaßung zunächst in Blender modelliert. Damit Lenker, Pedale und Reifen beweglich sind, werden sie als einzelne Meshes separiert und *Bones* mit den jeweiligen Freiheitsgraden für die beweglichen Teile hinzugefügt. In der UE5 werden passende Materialien hinzugefügt (Abb. 12A).

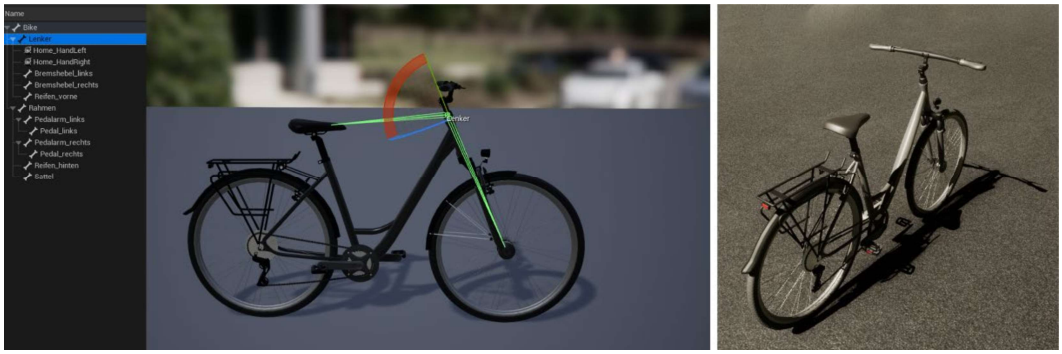


Abb. 12: Fahrradmodell (Eigene Darstellung, 2024)

5.1.4 Sounddesign

Um den Eindruck einer überzeugenden Umgebung zu gewährleisten, muss auch die auditive Ebene berücksichtigt werden. Umgebungsgeräusche, bestehend aus leichtem Wind und Vogelgezwitscher, wird in beiden Varianten eingesetzt. Die Geräusche dienen als auditive Hinweise auf die Umgebung und seien somit Einflussfaktoren für ein erhöhtes Präsenzempfinden (A09) (vgl. Jerald 2015).

In der Gamify-Variante kommen weitere Sounds zum Einsatz (A08). Als Feedback für gesammelte Seifenblasen wird ein angenehmes, „ploppendes“ Geräusch verwendet, welches das Platzen der Seifenblase auditiv vermittelt. Beim Erreichen der Halteline wird eine Komposition aus Klatschen, Jubeln und einer harmonisch aufsteigenden Tonleiter abgespielt.

Hierdurch soll einerseits das erfolgreiche Abschließen der Aufgabe signalisiert werden und andererseits eine positive Bestärkung stattfinden.

5.2 Blueprints

Die Logikkomponenten werden mit Hilfe des *Blueprint Visual Scripting System* der UE umgesetzt. Zunächst erfolgt eine Übersicht zum geplanten Aufbau des Projekts, gefolgt von einer genaueren Beschreibung der erstellten/entwickelten BPs.

5.2.1 Aufbau/Projektstruktur

Bei der Entwicklung der Trainingslogik muss einerseits darauf geachtet werden, dass Szenarios schnell verändert werden können. Andererseits soll die Möglichkeit bestehen, erstellte Szenarios zu verschieben oder in eine neue Map zu kopieren. Das Erstellen der Szenarios als BP ermöglicht die Instanziierung von Szenarios als eigenständige Objekte, mit anpassbaren Pfaden, innerhalb einer Szene.

Das Klassendiagramm (Abb. 13) zeigt grob den Aufbau des Projekts und die erstellten BPs als Klasse, Enum oder Interface.

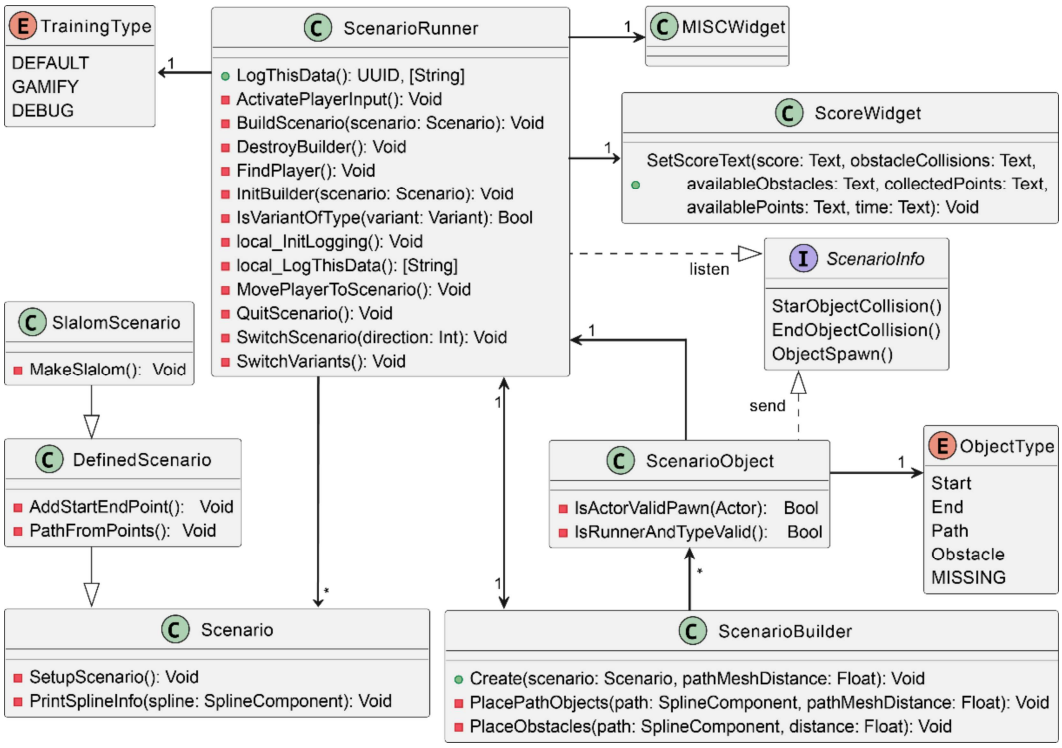


Abb. 13: Klassendiagramm BiTS (Eigene Darstellung, 2024)

Ein *ScenarioObject* dient je nach *ObjectType* als Pfadmarkierung bzw. Sammelobjekt (*Path*), Hindernis (*Obstacle*) oder Start-/Haltelinie (*Start* und *End*). Die Klasse *ScenarioBuilder* ist zuständig für die Platzierung verschiedener *ScenarioObjects* in einem übergebenen *Scenario*.

In der Klasse *ScenarioRunner* werden die verschiedenen Komponenten zusammengeschaltet und entsprechende Konfigurationsmöglichkeiten bereitgestellt. In der Szene platziert, regelt ein *SceanrioRunner* die Inputs für die VL, das Finden und Platzieren der VP sowie das Erstellen, Hinzufügen und Anpassen der Szenarios. Zur vereinfachten Bedienung und schnellen Anpassung des Trainings wurde zusätzlich ein *VariantManager* angelegt. Im Folgenden werden die wichtigsten BPs und deren Funktionsweisen genauer beschrieben.

5.2.2 Scenario

Es gibt drei verschiedene Möglichkeiten, einen Pfad für ein Szenario zu erstellen, mit *Scenario, DefinedScenario* und *SlalomScenario* .

Ein *Scenario* (Abb. 14) enthält eine *SplineComponent* (*Path*), welche in der Szene platziert und manuell angepasst werden kann. Die enthaltene *SplineComponent* bestehet zu Anfang aus zwei Punkten, also einem Segment. In der Szene können weitere Punkte hinzugefügt und der Pfad per handle manipuliert werden. Der erste Punkt eines entstandenen Splines definiert die Startposition, der letzte Punkt definiert die Halteline. Die Debugg-Funktion mit *PrintSplineInfos* gibt die Positionen für jeden Punkt im Output Log aus.

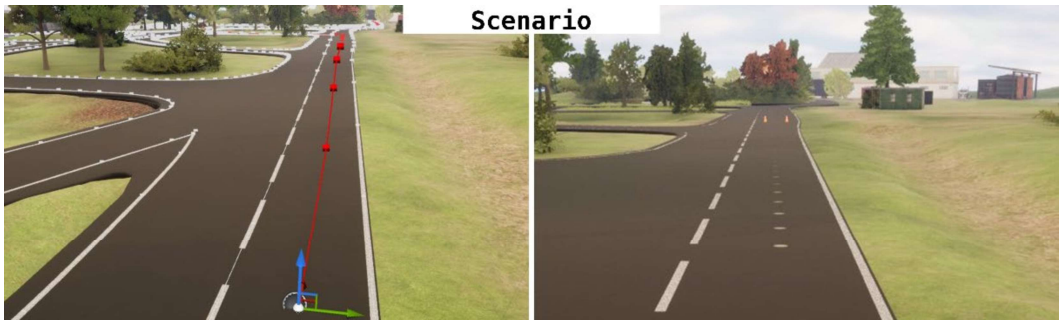


Abb. 14: BP_Scenario (Eigene Darstellung, 2024)

Eine *DefinedScenario* (Abb. 15) erbt von *Scenario* und kann durch feste Werte definiert werden. Mit der Funktion *PathFromPoints* ist es möglich, einen Pfad in der Scene durch Hinzufügen von Punkten in Koordinatenform im *Details Panel* festzulegen.



Abb. 15: BP_DefinedScenario (Eigene Darstellung, 2024)

Eine *SlalomScenario* (Abb. 16) erbt von *DefinedScenario* und ermöglicht das einfache Erstellen von Slalom-Strecken. In der Funktion *MakeSlalom* wird mit Hilfe einer Sinusfunktion ein Spline mit gleichmäßigen Kurvensegmenten erzeugt. Die Frequenz (*Repetitions*), das Intervall (x-Scale), die Amplithude (y-Scale) und die Auflösung (*RepititionsSteps*) können im *DetailsPanel* editiert werden.



Abb. 16: BP_SlalomScenario (Eigene Darstellung, 2024)

5.2.3 ScenarioObject

Ein *ScenarioObject* besteht aus einer *Static Mesh Component* (*VisualMeshComponent*) und einer *Box Collision* (*CollisionDetector*), welche im Construction Skript gesetzt werden.

Mittels eines Enums *ObjectType* wird die konkrete Ausprägung eines Objekts zur Laufzeit festgelegt, also die angewandte *VisualMeshComponent* und die Dimension eines *CollisionDetectors*. Die aktuell zur Verfügung stehenden Objekttypen sind *Start*, *End*, *Path*, *Obstacle* und *Missing,* wobei letzteres als Standardwert gesetzt wird. Die Platzierung und Zuweisung des *ObjektTypes* erfolgt automatisch im *ScenarioBuilder*.

Um andere Objekte in der Szene über Kollisionen mit der VP zu informieren (siehe: 5.2.5), implementiert ein *ScenarioObject* das Interface *ScenarioInfo*. Im *Event Graph* werden bei Kollisionen mit einem *CollisionDetector* des jeweiligen *ScenarioObjects* die entsprechenden Signale gesendet. Auf diese

Weise erhalten andere Objekte, die ein *ScenarioInfo* implementieren, eine Referenz auf das betroffene *ScenarioObject* sowie die Art des Kollisionsereignisses.

Im *Event Graph* werden Interface-Funktionen durch verschiedene Events aufgerufen, beim Zutreffen der im *ScenarioBuilder* festgelegten Bedingungen senden sie ein Signal an den *ScenarioRunner*. *Start- und EndOverlap* Events lösen eine Überprüfung des kollidierten Objekts aus, ist es ein *PlayerPawn*, werden die Interface-Funktionen *StartObjectCollision* und *EndObjectCollision* ausgeführt.

Weitere Funktionen dienen der Überprüfung der Validität von *ScenarioRunner*, *ObjectType* und *PlayerPawn*.

5.2.4 ScenarioBuilder

Der *ScenarioBuilder* enthält verschiedene Funktionen zum Erstellen der Scenarios und platzieren der Objekte. Mit *PlacePathObjects* wird das aktuelle Szenario übergeben und die entsprechenden *ScenarioObjects* entlang des Pfads platziert.

Objekte des Typs *Start* und *End* werden am ersten und am letzten Index positioniert. Vom zweiten bis zum vorletzten Punkt werden Objekte des Typs *Path* entsprechend der *PathLoopDetails* und mit dem Abstand *pathDistance* entlang des Pfades aufgereiht. Somit bleiben erstes und letztes Segment ohne Objekte und dienen so als An- und Ausfahrt (*Start*- und *EndOffset)*. Im *DetailsPanel* des *Scenarios* können die entsprechenden Parameter festgelegt werden.

Die Meshes und Kollisionsdimension der *ScenarioObjects* können sowohl im *ScenarioRunner* als auch im *Variant Manager* für den jeweiligen Modus und Objekttyp angepasst werden.

Ein *SlalomScenario* benötigt zusätzlich Hindernisse, also ein *ScenarioObject* vom Typ *Obstacle*. Diese werden mit Hilfe der Funktion *PlaceObstacles*

und den entsprechenden Einstellungen des jeweiligen *SlalomScenarios* platziert.

Mit *Create* wird das übergebene *Scenario* anhand der vorgegebenen Einstellungen aufgebaut bzw. die *ScenarioObjects* platziert. Das Event *DestroyActor* löst das Entfernen der verbliebenen *ScenarioObjects* aus.

5.2.5 ScenarioRunner

Die Klasse *ScenarioRunner* ist für Aufbau und Management der Szenarios verantwortlich. Um den Trainingsablauf festzulegen, muss der Szene ein *ScenarioRunner* hinzugefügt werden. In diesem ist es möglich, die Reihenfolge der erstellten Szenarios festzulegen, dabei ist es auch möglich, ein Szenario mehrmals hinzuzufügen.

Im *EventGraph* werden verschiedene Inputs für die Versuchsleitung bereitgestellt. Zur Laufzeit können die verschiedenen Szenarios durchgeschaltet, neu gestartet und beendet werden. Außerdem kann der Modus (*Default*, *Gamify* und *Debug*) gewechselt werden.

BeginPlay organisiert verschiedene Funktionen, die am Anfang ausgelöst werden müssen. Der aktuelle *PlayerPawn* wird gesucht, die Inputs aktiviert und der Umgebungssound gestartet.

Die durch die Implementierung des Interfaces *ScenarioInfo* bereitgestellten Events *ObjectSpawned*, *StartObjectCollision* und *EndObjectCollision* ermöglichen dem Runner die Interaktion mit den sendenden *ScenarioObjects*. Anhand des aufgerufenen Events des *ObjectTypes* und des *GameModes* wird entschieden, wie mit dem von der Pawn-Kollision betroffenen *ScenarioObject* verfahren wird.

Die Beendigung der Kollision mit einem *ScenarioObject* vom Type *Start* startet einen Timer dieser wird bei Eintritt des Players in den *CollisionDetector* des Typs *End* gestoppt. Das Erreichen der Haltelinie setzt den *EndTrigger* auf „true“, startet einen Fade out mit einer Verzögerung von 5 Sekunden und löst die Funktion *QuitScenario* aus.

QuitScenario leitet eine Schlusssequenz entsprechend dem Modus ein. Im Gamify Modus wird beim Erreichen der Haltelinie die Animation eines (Konfetti-) Partikelsystems abgespielt, eine *SoundCue* mit verschieden Soundeffekten gestartet und das Scoreboard mit den aktuellen Werten für das Szenario eingeblendet. Die gesammelten Punkte, Kollisionen mit Hindernissen und die benötigte Zeit werden darauf angezeigt. Mit *SetScoreText* werden die im *Runner* gesammelten Ergebnisse als Textvariablen an das *ScoreWidget* übergeben.

In beiden Varianten werden nach dem *Fade out* die Inputs für das Bike gesperrt und die Misery Scale (MISC) (siehe: Abb. 23) eingeblendet, damit die VPs nach jedem Szenario ihr aktuelles Wohlbefinden angeben können. Um einen sanften Übergang zu erreichen, sind die Widgets erst transparent und werden dann langsam eingeblendet (Abb. 17).

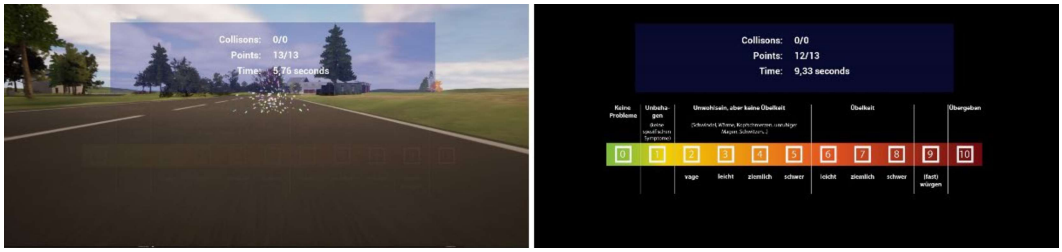


Abb. 17: Fade out (Eigene Darstellung, 2024)

Beim Beginn einer Kollision mit einem Objekt des Typs *Path* wird der Wert *CollectedPoints* inkrementiert. In gleicher Weise erhöht der Beginn einer Kollision mit einem *Obstacle* den Wert *ObstacleCollision.* Für den Fall, dass der boolesche *Wert RemovePathObjectOnCollision* für das Szenario im *ScenarioRunner* bzw. im *Variant Manager* auf „true“ gesetzt wurde, verschwindet das Objekt und ein Sound wird abgespielt.

Um das aktive Szenario zu wechseln oder neu zu starten, dient die Funktion *SwitchScenario*, in der die Elemente des aktuellen Szenarios entfernt werden und anschließend das über den Index angegebene Szenario geladen wird. Zudem wird die VP auf die Startposition gesetzt. Diese Funktion wird verwendet, um der VL die bereits erwähnten Inputs (Abb. 4.) bereitzustellen. Außerdem werden alle Widgets entfernt und ein *Fade In* gestartet.

BuildScenario ruft weitere Funktionen auf. *DestroyBuilder* zum Entfernen des *Builders* und zurücksetzen der Variablen. Anschließend wird die Funktion *InitBuilder* zur Initialisierung des neuen *Builders* und dessen Funktion *Create* mit den entsprechenden Parametern aufgerufen.

Die Funktion *SwitchVariants* ist für den Wechsel zwischen den Modi *Default*, *Gamify* und *Debug* zuständig. Die Varianten werden als *ScearioSet* im *Variant Manager* festgelegt.

5.2.6 Variant Manager

Im *Variant Manager* können verschiedene Sets mit unterschiedlichen Varianten angelegt werden. Jede Variante definiert einen Modus, für den die im *Runner* definierten Variablen individuell verändert werden können. Die Meshes der verschiedenen Objekttypen können ausgetauscht und deren Position, Abstand zueinander und Dimension des *CollisionDetector*s angepasst werden. Die boolesche Variable *RemovePathObjectOnCollision* legt für die jeweilige Variante fest, ob ein Objekt nach der Kollision verschwindet.

5.2.7 ScenarioEditor

Die Map *ScenarioEditor* enthält den ADAC-Übungsplatz ohne weitere Umgebungselemente und wird verwendet, um die Szenarios unabhängig von der zur Versuchsdurchführung verwendeten Map zu erstellen (Abb. 18A). Dabei muss nur beachtet werden, dass die Positionierung, Skalierung und Ausrichtung der Strecke in beiden Szenen identisch sind. Hier können die Scenarios erstellt werden ohne die Gefahr, an der Map etwas zu verändern. Wenn alle Scenarios fertig erstellt worden, können sie einfach kopiert und in die aktuelle Trainings-Map überführt werden (Abb. 18B).

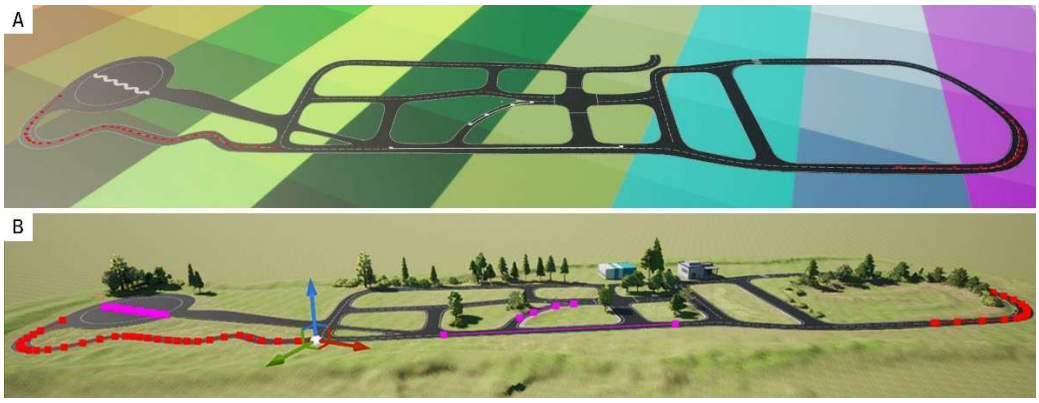


Abb. 18: Editor-Map (Eigene Darstellung, 2024)

5.3 Szenario Erstellung

Nach der Umsetzung der beschriebenen Logikkomponenten werden die entsprechenden Szenarios für die Studiendurchführung auf der Editor-Map erstellt und die Reihenfolge im *Runner* festgelegt. Die fertigen Szenarios werden zusammen mit dem angelegten Runner in die finale Trainings-Map kopiert und die Referenzen auf die Szenarios im *Runner* aktualisiert. Eine detailliertere Anleitung mit einzelnen Schritten zum Erstellen und Hinzufügen eines Szenarios befindet sich im Anhang C. Die folgende Übersicht (Abb. 19) der Szenarios zeigt die Reihenfolge und zu absolvierende Kernaufgaben der Szenarios (von oben nach unten).

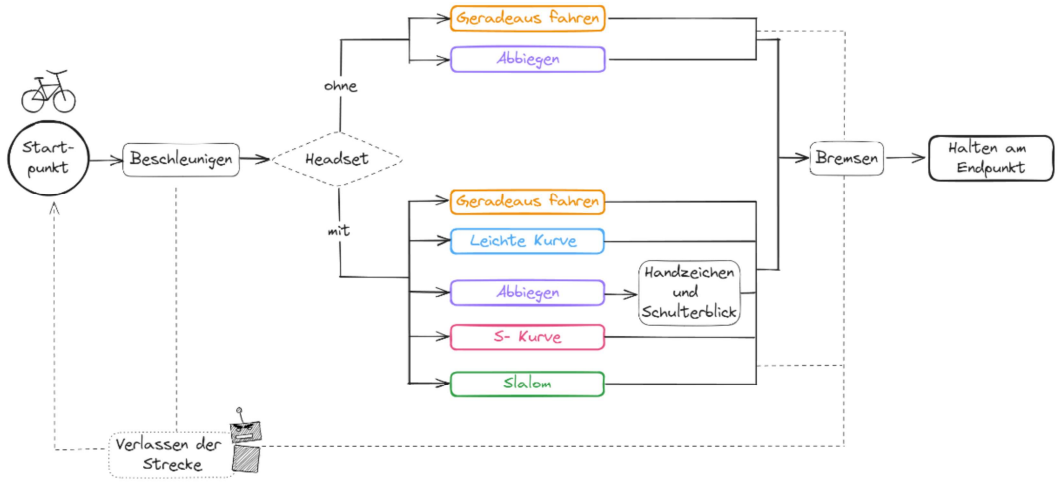
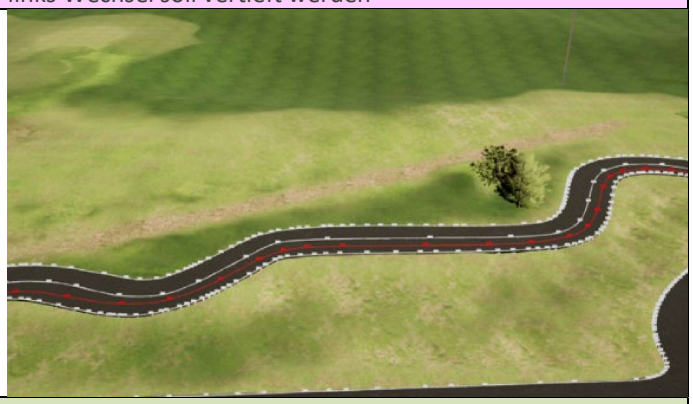


Abb. 19: Festgelegte Szenarios (Eigene Darstellung, 2024)

In Tabelle 4 werden die einzelnen Streckenabschnitte mit den jeweiligen Szenarios genauer beschrieben und der entsprechende Abschnitt auf der Strecke anhand der erstellten Pfade (rote Linien) dargestellt. Die farbliche Codierung der Titelzeilen entspricht der Grafik in (Abb. 19).

Tabelle 4: Streckenabschnitte

Streckenabschnitte mit Szenarios		
1	**Geradeaus (ohne HMD)**	Erstes Fahrgefühl auf dem Fahrradsimulator soll erlangt werden
Interface: Monitor **Beschreibung:** Die VP beschleunigt, folgt dem Pfad Geradeaus und kommt an der Haltelinie zum Stehen.		
2	**Abbiegen (ohne HMD)**	Erstes Gefühl für das Lenken und Lehnen auf dem Fahrradsimulator soll erlangt werden
Interface: Monitor **Beschreibung:** Die VP beschleunigt, folgt dem Pfad Geradeaus, biegt links ab, biegt rechts ab und kommt an der Haltelinie zum Stehen.		
3	**Geradeaus**	Erstes Fahrgefühl mit HMD soll auf bereits bekannter Strecke erlangt werden
Interface: HMD **Beschreibung**: Die VP beschleunigt, folgt dem Pfad Geradeaus und kommt an der Haltelinie zum Stehen.		

4	**Lange Kurve**	Ein Gefühl für das Lenken und Lehnen mit HMD soll erlangt werden, zunächst auf leichter Kurve
Interface: HMD **Beschreibung**: Die VP beschleunigt, folgt dem Pfad Geradeaus, einer langen Linkskurve und kommt an der Haltelinie zum Stehen.		
5	**Abbiegen**	Ein Gefühl für das Lenken und Lehnen beim Abbiegen mit HMD und Handzeichen soll erlangt werden
Interface: HMD **Beschreibung**: Die VP beschleunigt, folgt dem Pfad Geradeaus, biegt links ab, biegt rechts ab und kommt an der Haltelinie zum Stehen. Beim Abbiegen sollen die VPs Handzeichen verwenden.		
6	**S-Kurve**	Das Lenken und Lehnen in verschiedenen Kurven mit rechts, links Wechsel soll vertieft werden
Interface: HMD **Beschreibung:** Die VP beschleunigt, folgt dem Pfad Geradeaus, einer kleinen Rechtskurve, einer kleinen Linkskurve, erneut einer kleinen Linkskurve, einer langen Rechtskurve und kommt an der Haltelinie zum Stehen.		
7	**Slalom**	Der Slalom soll das Lenken und Lehnen, in schnellem Wechsel zwischen Links- und Rechtskurve trainieren
Interface: HMD **Beschreibung**: Die VP beschleunigt, folgt dem Pfad Geradeaus bis zum ersten Hindernis, weicht dann abwechselnd zehn Hindernissen rechts bzw. links aus und kommt an der Haltelinie zum Stehen.		

Entsprechend dieser Reihenfolge werden die Szenarios dem *ScenarioRunner* hinzugefügt. Da das erste und zweite Szenario sowohl mit als auch ohne VR durchgeführt werden soll, werden diese kopiert und umbenannt.

Im *Variant Manager* werden die Einstellungen für die verschiedenen Varianten festgelegt. Unterschiede zwischen den Varianten beziehen sich vor Allem auf die Einstellungen der *PathMeshes*, für Default werden Kreidekreise und Seifenblasen für Gamify verwendet.

Die Einstellungen (Abb. 20) für die jeweiligen Maße und Positionen werden anhand von Testfahrten in einer kleinen Gruppe ermittelt und festgelegt.

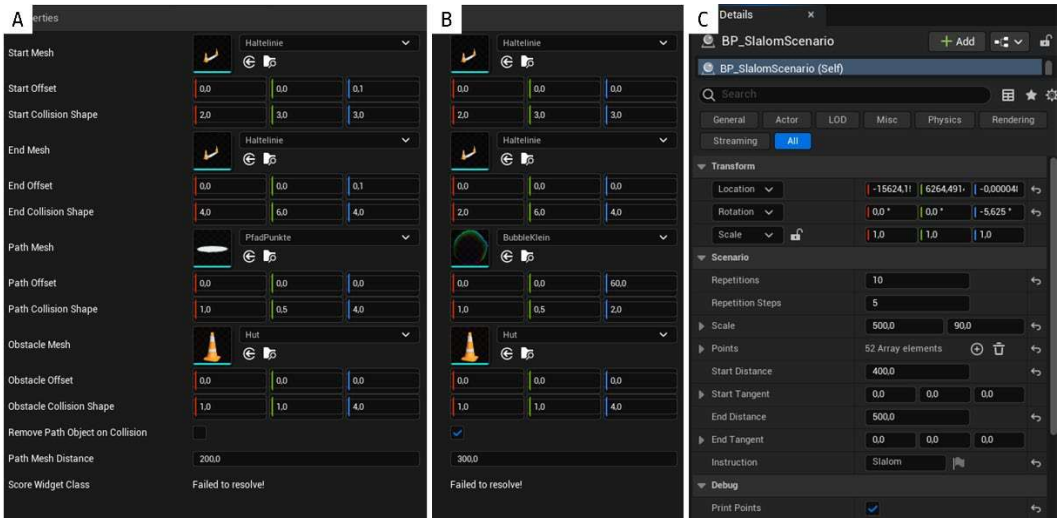


Abb. 20: Einstellungen der Szenarios (Eigene Darstellung, 2024)

Die Kreise werden auf dem Boden mit einem Abstand von 2 m platziert (Abb. 20A). Die Seifenblasen schweben in einer Höhe von 60 cm und haben einen Abstand von 3 m (Abb. 20B). Das Entfernen eines gesammelten Objekts ist nur bei Gamify aktiviert (Abb. 20B). Das Slalom-Szenario wird mit zehn Wiederholungen, einem Abstand der Hindernisse von 5 m und einer Breite von 90 cm erstellt. Das erste Hindernis ist 4 m hinter der Startlinie und das Ende ist 5 m hinter dem letzten Hindernis positioniert (Abb. 20C).

5.4 BikeSim Anbindung und Logging

Das Training wird mit verschiedenen Plugins des DLRs zum Anbinden des Fahrradsimulators und zum Loggen der Daten in das UE-Projekt BiTS importiert. Eine Tabelle der Variablen, die durch das Logging erfasst werden, befindet sich im Anhang D. Das Plugin *BikeSimEgoVehicle* enthält die BP *BikeEgo* vom Typ *Pawn*. Hier werden unter anderem Mesh, Position und Animation für das Fahrrad bestimmt. Die *SkeletonAnimBlueprint* wird auf das neue Modell angepasst, damit virtuelle Animationen des Models zu den Bewegungen des Fahrradsimulators passen. Für die Szenarios, die ohne HMD absolviert werden sollen, wird eine zweite Camara hinzugefügt, damit das Interface auf den Monitor gewechselt werden kann. In den Projekt Settings muss *BikeEgo* als *PawnClass* ausgewählt werden.

6 Studiendesign

Anhand einer kleinen Stichprobe werden die zu Beginn aufgestellten Forschungsfragen überprüft. Die experimentelle Untersuchung wird in einem Between-Subject-Design durchgeführt, wobei die VPs im Wechsel der Variante, Gamify oder Default zugewiesen werden.

6.1 Messmethoden

Die von den Forschungsfragen abgeleiteten abhängigen Variablen (AV) Trainingserfolg, Simulator Sickness, Präsenz und Akzeptanz werden unter dem Einfluss der unabhängigen Variablen (UV), die sich entsprechend der Trainingsvarianten unterscheiden, betrachtet. In Abb. 21 werden UVs mit den jeweiligen Ausprägungen und AVs mit den verwendeten Messmethoden gezeigt.

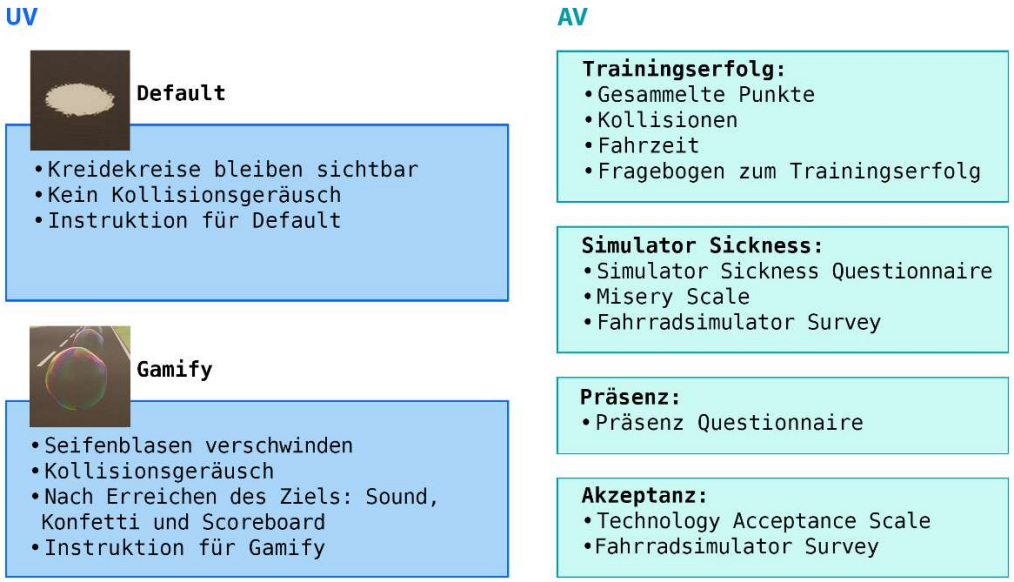


Abb. 21: UVs und AVs (Eigene Darstellung, 2024)

Die während des Versuchs aufgezeichneten Daten werden genutzt, um eine objektive Bewertung des Trainingserfolgs zu ermitteln. Im Folgenden werden die Instruktion, die zum Einsatz kommenden Messmethoden sowie Aufbau und Ablauf des Versuchs erläutert.

6.1.1 Fragebögen (subjektive Messung)

Die im Folgenden beschriebenen Fragebögen wurden auf die Web-Applikation *SoSci Survey*[4] übertragen, damit die Erhebung von den VPs auf Tablets ausgefüllt werden kann. Auf diese Weise entfällt die Zeit für das Übertragen der Ergebnisse, Übertragungsfehler werden vermieden und die Ergebnisse können jederzeit in maschinenlesbarer Form exportiert werden.

Demographie-Fragebogen

Der Demographie Fragebogen (DF) erfasst datenschutzkonform Alter, Geschlecht und Fahrerfahrung der VPs. Genutzt wurde eine bereits vorhandene Vorlage des Instituts. Die Ergebnisse geben einen groben Überblick zur demographischen Zusammensetzung der Stichprobe.

Fahrradsimulator Survey

Der Fragebogen mit einer 7-Punkte-Skala wurde für eine Fahrradsimulator-Studie (FS) an der Technischen Universität Braunschweig erarbeitet (vgl. Berghoefer und Vollrath 2023). Er dient der subjektiven Bewertung verschiedener Strecken anhand von fünf Kriterien. Gefragt wird nach der Beurteilung von mentalem Komfort, Interaktion, Umgebung, Benutzerfreundlichkeit und Fahrkomfort. Die Ergebnisse beziehen sich nicht auf eine bestimmte Forschungsfrage, sondern geben einen allgemeinen Überblick zu verschiedenen Empfindungen der VPs bezüglich der Umgebung.

Fragebogen zum Trainingserfolg

Der subjektiv wahrgenommenen Trainingserfolg (TE) wird durch verschiedene Fragen anhand einer 4-Punkte-Skala von 1 „sehr schlecht“ bis 4 „sehr gut“ und einer abschließenden offenen Frage beantwortet. Der Fragebogen wurde in Rücksprache mit einer Expertenrunde des MZS erstellt. Die VPs

[4] https://www.soscisurvey.de/

sollen beurteilen, wie gut sie die Pfadmarkierungen erkennen und ihnen folgen konnten. Ob sie das Fahrrad nach dem Training besser kontrollieren können, was ihnen besonders dabei geholfen hat und wie gut sie sich vorbereitet fühlen, auf dem Simulator eine Studie mit realistischen Verkehrsbedingungen durchzuführen.

Simulator Sickness Questionnaire

Zur subjektiven Bewertung des Wohlbefindens der VPs wird der Simulator Sickness Questionnaire (SSQ) nach Kennedy et al. verwendet (vgl. Kennedy et al. 1993). Er gilt als Standard und vollständigste Zusammenfassung der Symptome (vgl. Cobb et al. 1999; Bos et al. 2010; Brooks et al. 2010; Stoner et al. 2011; Jerald 2015; Weech et al. 2019). Die VPs schätzen nach der Fahrt den Schweregrad von 16 Symptomen während des Versuchs anhand einer vierstufigen Skala von „gar nicht“ bis „schwer“ ein.

Zur Auswertung werden, die Symptome wie in Abb. 22 dargestellt, in drei Gruppen Okulomotorisch (O), Desorientierung (D) und Übelkeit (N) unterteilt und mit der jeweiligen Gewichtung berechnet (vgl. Kennedy et al. 1993). Der *Total Score* wird aus anhand der Summe der Gruppenergebnisse und mit einem Wert von 3,74 multipliziert.

Computation of SSQ Scores

SSQ Symptom[a]	Weight N	Weight O	Weight D
General discomfort	1	1	
Fatigue		1	
Headache		1	
Eyestrain		1	
Difficulty focusing		1	1
Increased salivation	1		
Sweating	1		
Nausea	1		1
Difficulty concentrating	1	1	
Fullness of head			1
Blurred vision		1	1
Dizzy (eyes open)			1
Dizzy (eyes closed)			1
Vertigo			1
Stomach awareness	1		
Burping	1		
Total[b]	[1]	[2]	[3]

Score
N = [1] × 9.54
O = [2] × 7.58
D = [3] × 13.92
TS[c] = [1] + [2] + [3] × 3.74

[a]Scored 0, 1, 2, 3. [b]Sum obtained by adding symptom scores. Omitted scores are zero. [c]Total Score.

Abb. 22: Computation of SSQ Scores (*Kennedy et al.*, 1993)

Misery Scale

Um den Zustand der VPs im Verlauf des Trainings zu erfassen, erfolgt nach jedem Szenario eine Selbstauskunft der VPs. Hierfür kommt die am *TNO Human Factors Research Institute* entwickelte Misery Scale (MISC) (Abb. 23) zum Einsatz (vgl. Wertheim 1998). Anhand dieser wird der Schweregrad des Unbehagens der VPs bewertet.



Abb. 23: MISC (Eigene Darstellung nach (Wertheim et al. 1998, 522))

Die Befragung kann in kurzer Zeit durchgeführt werden und deshalb unmittelbar nach jedem Szenario stattfinden (vgl. Wertheim et al. 1998). Um zu vermeiden, dass das HMD nach jedem Szenario ab- und wieder aufgesetzt werden muss, wird die oben gezeigte Skala innerhalb der virtuellen Umgebung eingeblendet.

Präsenz Questionnaire

Der Präsenz Questionnaire (PQ) von Witmer und Singer besteht ursprünglich aus 32 Frageitems, die anhand einer 7-Punkte-Likert-Skala beantwortet werden (vgl. Witmer und Singer 1998). In der aktuellen Version (Vs. 3.0) von Witmer et al. werden die Items 26, 27 und 28 aus Gründen der Zuverlässigkeit entfernt (vgl. Witmer et al. 2005).

Für die Auswertung der Ergebnisse wurde das *4-Factor Model* verwendet (vgl. ebd.). Die Frageitems werden wie in Tabelle 5 dargestellt, in vier Subskalen unterteilt:

Subskala	Abkürzung	Items
Involvement	INV	1-4, 6-8, 14,17,18,29
Sensory Fidelity	SF	5, 11-13,15,16
Adaptation/Immersion	AI	9, 20, 21,24,25,30-32
Interface Quality	IQ	19,22,23 (invertiert)

Tabelle 5: PQ-Subskalen

Technology Acceptance Scale

Der Technology Acceptance Scale (TAS) von van der Laan et al. misst die Akzeptanz einer Person gegenüber eines bestimmten komplexen soziotechnischen Systems (vgl. Van Der Laan et al. 1997). Sie ist abgeleitet vom TAM (Siehe: 2.2.3) und besteht aus zwei Unterskalen, Nützlichkeit und Zufriedenheit (vgl. ebd.).

Anhand einer 5-Punkte-Skala (-2 bis +2) mit 9 Wortpaaren bewerten VPs nach der Fahrt den Nutzen des Systems und ihre Zufriedenheit mit der Anwendung (Abb. 24).



Abb. 24: TAS (Eigene Darstellung nach (Van Der Laan et al. 1997,3))

Die Frageitems werden, wie in Tabelle 6 zu sehen, in zwei Subskalen unterteilt (3,6 und 8 sind invertiert).

Subskala	Items
Usefullness	1,3,5,7,9
Satisfying	2,4,6,8

Tabelle 6: TAS-Subskalen

6.1.2 Aufgezeichnete Daten (objektive Messung)

Neben den Variablen, die als Indikatoren zur subjektiven Bewertung der Trainingserfolg herangezogen werden, sind zudem Daten zur Laufzeit erfasst worden (siehe Anhang: D). Insbesondere der Vergleich der innerhalb eines Szenarios benötigten Zeit (*ScenarioTime*), die gesammelten Punkte (*CollectedPoints*) und Kollisionen mit Hindernissen (*ObstacleCollision*), sowie die Anzahl der platzierten Objekte (*AvailablePoints* und *AvailableObstacles*), werden als Indikatoren für einen Trainingserfolg gewertet.

6.2 Instruktion

Für die verschieden Varianten Default und Gamify kommen jeweils unterschiedliche Instruktionen zum Einsatz. Die verschiedenen Versionen

unterscheiden sich im Wesentlichen in den Abbildungen der Pfadmarkierungen (siehe Anhang: E). Bei *Default* werden die Kreidekreise und bei *Gamify* die Seifenblasen gezeigt. Beide enthalten Informationen zur Benutzung des Fahrradsimulators und zum Ablauf der Versuchsdurchführung. Sowie den Hinweis, dass die VP den Versuch zu jeder Zeit abbrechen kann.

6.3 Versuchsablauf

Die Durchführung erfolgt immer mit zwei VLs. Eine VL betreut dabei primär den Leitstand, das Eintragen der VP-ID, Starten der Szene und Wechseln der Szenarios. Die zweite VL betreut hauptsächlich die VP, sie stellt sicher, dass Dokumente gelesen und unterschrieben werden, gibt kurze Erklärung zum Versuchsablauf, macht die Einweisung für den Simulator, erhebt die verbal mitgeteilten Daten für die MISC und betreut die VP beim Ausfüllen der Fragebögen. In Abb. 25 wird der Ablauf der Versuchsdurchführung dargestellt.

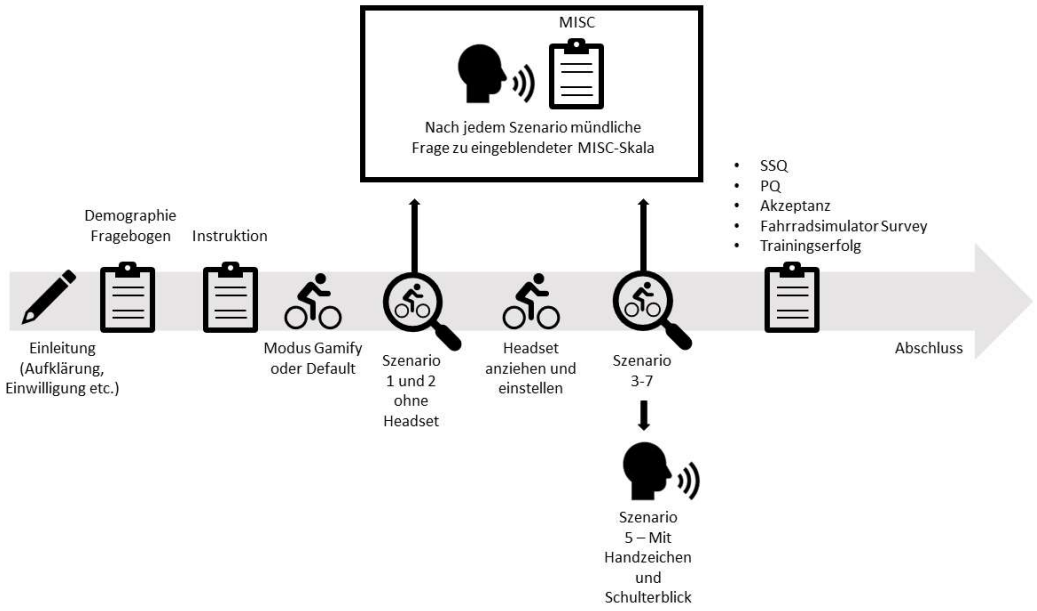


Abb. 25: Versuchsablauf (Eigene Darstellung, 2023)

Es folgt eine ausführliche Beschreibung der einzelnen Schritte der Durchführung sowie der Vor- und Nachbereitung.

Vorbereitung:

Die erste Aufgabe bei der Vorbereitung des Labors ist die Durchführung von Hygienemaßnahmen: Reinigung und Desinfektion der Gegenstände, mit denen eine VP in Berührung kommt. Als nächstes folgt die Vorbereitung der Hard- und Software. Die benötigten Rechner müssen hochgefahren und die zum Einsatz kommende Software gestartet werden. Im nächsten Schritt werden Fahrradsimulator und Headset eingeschaltet und getestet. Auftretende Fehler müssen so lange behoben werden, bis die Anlage den Vorgaben entsprechend lauffähig ist. Außerdem gehört zu der Vorbereitung das Anlegen eines Ordners auf dem Labor-PC, benannt nach der VP-ID. Zudem wird eine Kartei für die schriftlichen Unterlagen im Aktenordner angelegt.

Versuchsablauf:

Der Versuch beginnt mit dem Unterschreiben einer Einwilligungserklärung und dem Ausfüllen des Demographie-Fragebogens auf einem Tablet. Als nächstes erfolgt eine kurze Erläuterung zum Versuchsablauf und die VP bekommt die Instruktion entsprechend der zugewiesenen Variante. Wenn die VP alle nötigen Einweisungen erhalten hat, beginnt die Versuchsfahrt.

Versuchsfahrt:

Das Training wird wie in Abschnitt 5.3 beschrieben, ausgeführt. Die ersten beiden Szenarios werden mit Monitor und die Szenarios 3-7 mit HMD absolviert. Nach jedem Scenario wird von den VPs eine mündliche Angabe zur Einschätzung ihres Wohlbefindens anhand der MISC abgegeben und von einer VL notiert. Beim fünften Szenario bittet die VL die VP, beim

Abfahren der Strecke auch entsprechende Handzeichen zu geben und einen Schulterblick durchzuführen.

Nachbereitung:

Nach der Fahrt erfolgt eine kurze Pause, die VP soll vorsichtig absteigen, sich einen Moment setzten und bei Bedarf etwas trinken. Als nächstes werden die übrigen Fragebögen ausgefüllt.

Im Anschluss haben VPs die Möglichkeit, Fragen zu stellen und Feedback zu geben. Nach der Verabschiedung werden für jede VP zusätzliche Informationen zur Dauer und Abschluss des Trainings sowie besondere Ereignisse notiert. Die erfassten Daten werden sortiert und Datenschutzkonform gesichert.

7 Ergebnisse

Im Folgenden werden die Ergebnisse der subjektiven und objektiven Datenerhebungen vorgestellt (siehe Anhang: F). An der Erhebung nahmen 16 VPs teil, wovon acht das Training ohne Gamification und acht mit Gamification durchliefen. Drei Personen mussten den Versuch aufgrund starker Simulator Sickness Symptomen abbrechen. Die Datensätze werden in den meisten Fällen aus der Datenanalyse ausgeschlossen. Zum Ausgleich wurde ebenfalls die letzte VP aus der Gamify-Gruppe entfernt. Die Auswertung bezieht sich demnach, wenn nicht anders erwähnt, auf eine Gruppengröße $n = 12$, wobei $n_{default}$ und n_{gamify} jeweils sechs VPs aufweisen.

7.1 Demographie-Fragebogen

Die Auswertung des Demografie-Fragebogens bezieht sich auf die Gruppengröße von 16 Personen und weist die folgenden Ergebnisse auf.

Vier weibliche und 12 männliche Personen im Alter von 23-45 Jahren nehmen an der Versuchsdurchführung teil. Das Durchschnittsalter liegt bei 32 Jahren. Zwei weibliche und eine männliche VP brechen den Versuch wegen Simulator Sickness frühzeitig ab.

Die VPs geben an, im Monat zwischen 2 und 750 km, also im Durchschnitt 159,75 km und mindestens einmal im halben Jahr Fahrrad zu fahren (Abb. 26). Dreiviertel der Personen fahren demnach zwischen einmal pro Woche und jeden Tag. Die Antwortmöglichkeiten “gar nicht“ und „einmal im Jahr“ wird nicht genannt.

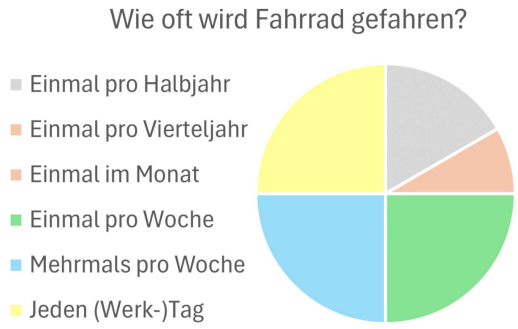


Abb. 26: Wie oft wird Fahrrad gefahren? (Eigene Darstellung, 2024)

Über ein Drittel der gefahrenen Strecken finden im Stadtverkehr statt. Des Weiteren geben VPs an, auf Wald oder Feldwegen und in ländlichen Gebieten Fahrrad zu fahren (Abb. 27). Die Antwortmöglichkeiten „Downhill“ und „sonstiges“ werden nicht genannt.

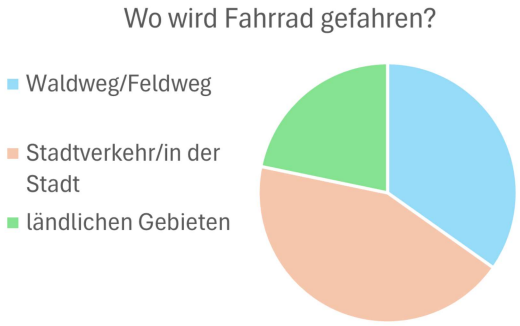


Abb. 27: Wo wird Fahrrad gefahren? (Eigene Darstellung, 2024)

7.2 Fahrradsimulator Survey

Für die Auswertung der Ergebnisse des FS wird die durchschnittliche Bewertung der VPs von 1 (sehr schlecht) – 7 (sehr gut) betrachtet.

Im direkten Vergleich zeigt sich nur ein geringer Unterschied zugunsten der Gamify-Variante. Insgesamt wird die Umgebung durchschnittlich zwischen 5 und 6 bewertet (Abb. 28).

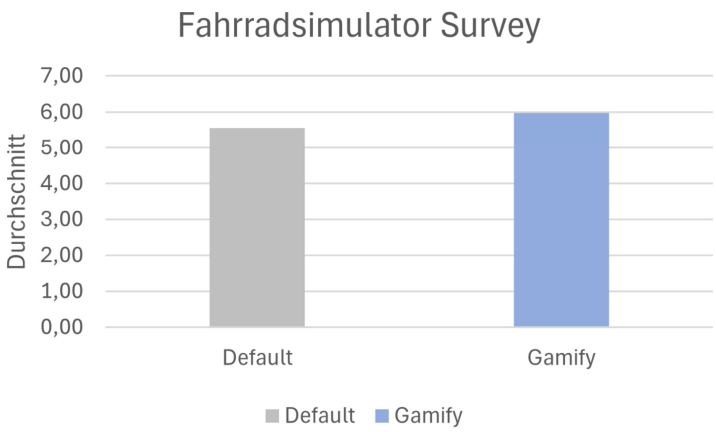


Abb. 28: Diagramm- Fahrradsimulator Survey (Eigene Darstellung, 2024)

Bei der Betrachtung der Subkategorien lassen sich keine Auffälligen Unterschiede erkennen. Bis auf den empfundenen Fahrkomfort schneidet die Variante Gamify in allen anderen Kategorien besser ab, was die Tendenz zugunsten der Gamify-Variante unterstreicht (Abb. 29).

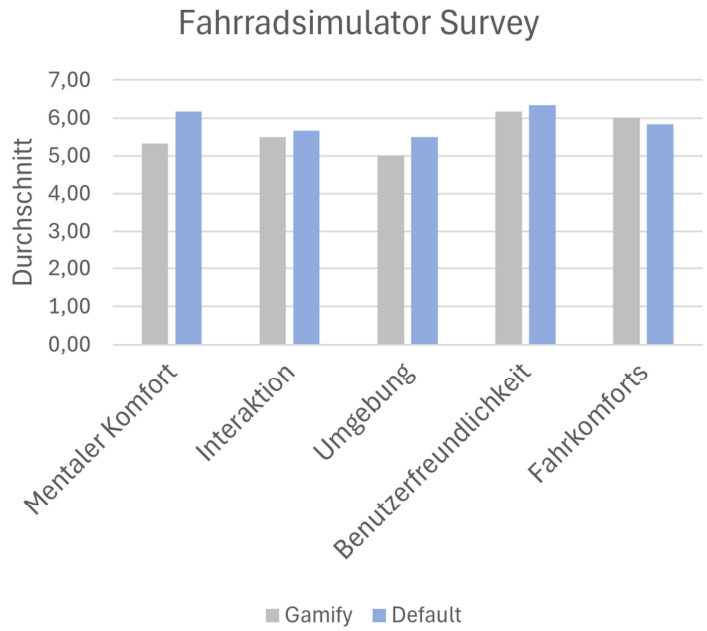


Abb. 29: Diagramm - Fahrradsimulator Survey (Eigene Darstellung, 2024)

In den offenen Fragestellungen sollen VPs beantworten, was sie an der eben gefahrenen Strecke besonders gut oder schlecht finden. Als positiv wird der ansteigende Schwierigkeitsgrad, die variierenden Streckenabschnitte und die Punkteanzeige beurteilt. Das Feedback der Gesammelten Seifenblasen wird als befriedigend wahrgenommen und von einer VP mit „*Mario Kart“* verglichen (siehe: Anhang F).

Eher negativ empfinden die VPs Streckenabschnitte mit engen oder wiederholenden Kurven (siehe: Anhang F). Zudem wird angemerkt, dass Seifenblasen im Schatten nicht gut zu erkennen seien und die Umgebung "künstlich" wirke.

7.3 Fragebogen zum Trainingserfolg

Für die Auswertung der Ergebnisse des Fragebogens zum Trainingserfolg wird die durchschnittliche Bewertung der VPs von 1 (sehr schlecht) – 4 (sehr gut) betrachtet.

Insgesamt wird der Trainingserfolg Durchschnittlich mit 3,01 also „eher gut“ beurteilt. Die Unterschiede in der Gesamtbewertung zeigen eine leichte Tendenz zu Gunsten der Default-Variante mit einem Durchschnittswert von 3,06, während Gamify 2,96 erreicht. In der Betrachtung der einzelnen Fragen zeigt sich jedoch ein eher ausgeglichenes Bild (Abb. 30). Lediglich bei der Frage nach der Erkennbarkeit der Markierungen schneidet die Variante Default deutlich besser ab. Bei der Frage, ob VPs der Markierung gut folgen konnten, ist das Ergebnis wiederum ausgeglichen, mit leichtem Trend Richtung Gamify.

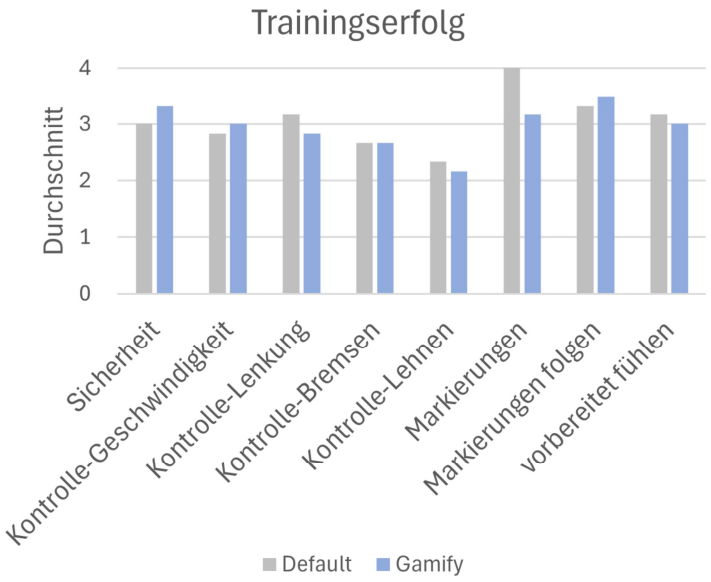


Abb. 30: Diagramm - Trainingserfolg Fragebogen (Eigene Darstellung, 2024)

Bei der offenen Fragestellung nach den Aspekten des Trainings, die am meisten geholfen haben, sich mit dem Fahrradsimulator vertraut zu machen, wird einerseits der ansteigende Schwierigkeitsgrad und andererseits die Abwechslung der Streckenabschnitte positiv bewertet. Einige wünschen sich größere Herausforderungen wie schnelles Fahren, langsames Abbiegen oder verschiedene Bremsmanöver (siehe: Anhang F).

7.4 Simulator Sickness Questionnaire

Der SSQ wird entsprechend der Erläuterung von Kennedy et al. (1993) mit den Gewichtungen für die Kategorien Übelkeit (N), Okulomotorik (O), Desorientierung (D), und den *Total Score* (TS) ausgewertet.

Die Ergebnisse des SSQ zeigen, dass in allen Kategorien deutlich weniger Symptome bei der Gamify-Variante angegeben werden. Der TS für Gamify liegt bei nur 3,49, während der Wert bei Default 8,03 beträgt (Abb. 31). In der Kategorie *Okulomotorik* liegt der Wert bei 1,26 und in den Symptomgruppen *Übelkeit* und *Desorientierung* unter 10. In der Default-Variante liegen alle anderen Werte über 10, bei *Desorientierung* über 15 und bei *Übelkeit* über 20.

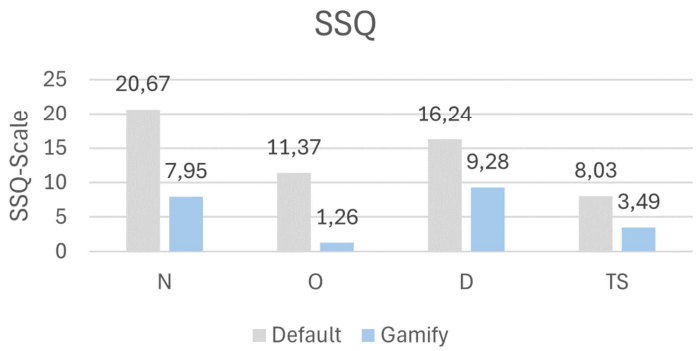


Abb. 31: Diagramm - SSQ (Eigene Darstellung, 2024)

Wenn die VPs dazu gerechnet werden, welche das Training abbrechen mussten, kommt der *Total Score* bei Gamify auf einen Wert von 8,86 und bei Default knapp über 20 (Abb. 32).

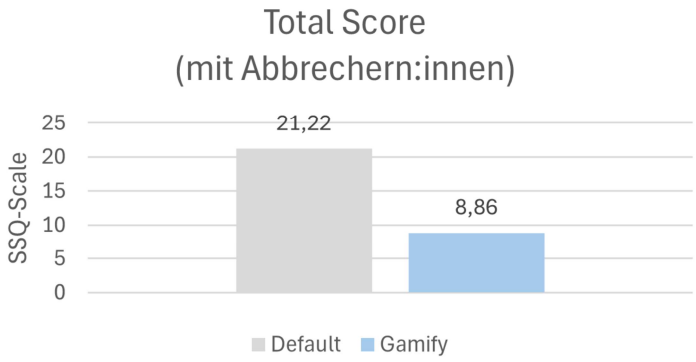


Abb. 32: Diagramm - Total Score - Mit Abbrecher:innen (Eigene Darstellung, 2024)

Bei der Betrachtung der Ergebnisse der einzelnen Symptome (mit Abbrecher:innen), aufgeteilt nach Häufigkeit und Schwere der Nennung in Prozent, lässt sich ebenfalls ein deutlicher Unterschied erkennen (Abb. 33). In der Gamify-Variante liegen die neun genannten Symptome unter 40%. Vier davon traten nur leicht (gelb) auf, vier weiter liegen in einem mittleren Bereich (orange). Nur „schwitzen“ erreicht bei knapp 10% einen schweren Wert.

In der Default-Variante treten doppelt so viele Symptome auf. Auch die Häufigkeit und Schwere der Symptome ist deutlich ausgeprägter. Alle 15

Symptome werden genannt, neun werden sogar als schwer (rot) eingeschätzt. Leichter bis mittelstarker „Schwindel“ tritt bei ca. 80% der VPs auf.

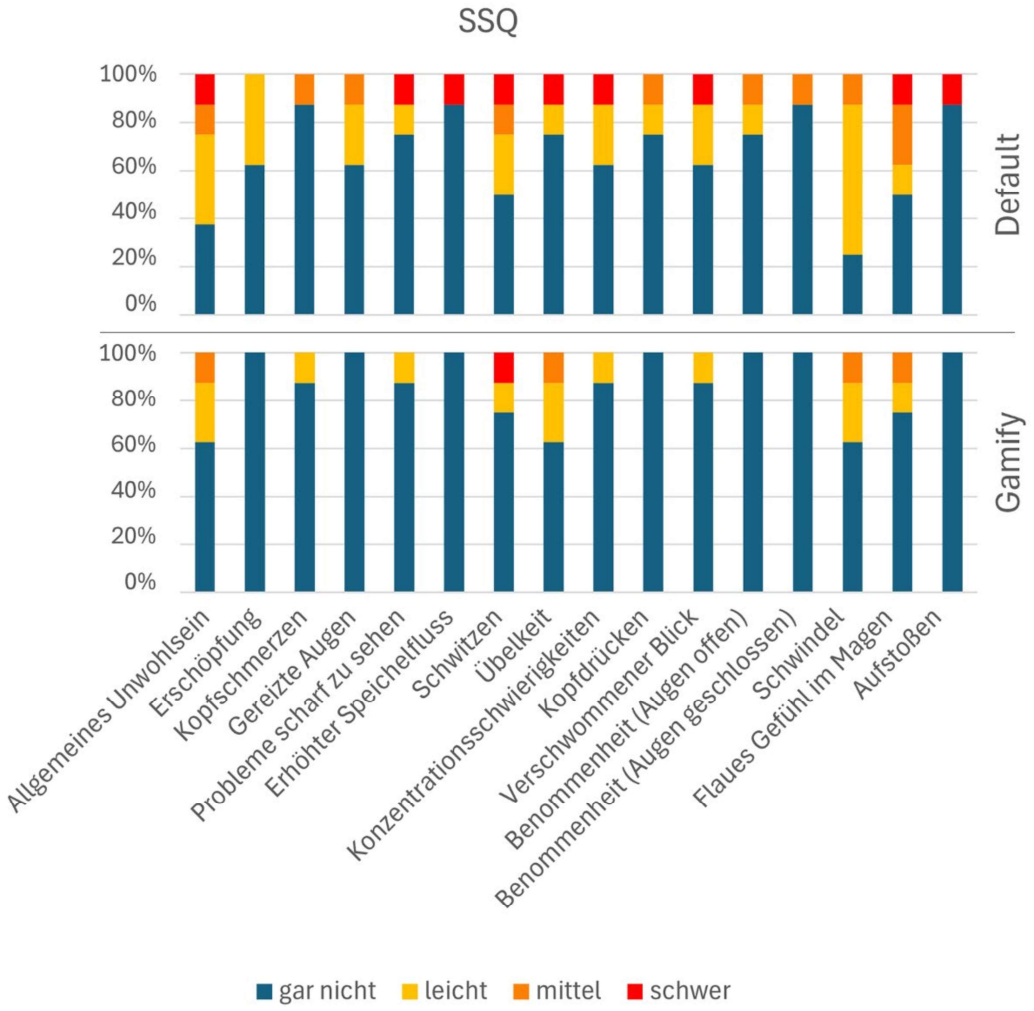


Abb. 33: Diagramm - SSQ-Symptomstärke - Mit Abbrecher:innen (Eigene Darstellung, 2024)

7.5 Misery Scale

Die Ergebnisse der MISC wird je Szenario für beide Varianten gemittelt. Hier zeigt sich, dass die Symptome bei der Default-Variante ausgeprägter sind. Drei Personen müssen das Training bei einem Wert von 6, also leichte Übelkeit, abbrechen. Zwei von drei Personen, die das Training wegen Symptomen abbrechen, fuhren die Default-Variante. Bei anhaltender Exposition steigen die Symptome an (Abb. 34). Das Abbiegen (Szenario 2) und die lange Kurve (Szenario 4) führt auch bei Personen mit geringen Symptomen zu einer leichten Verschlechterung des Wohlbefindens. Werden die Abbrecher:innen mit einbezogen, lässt sich erkennen, dass Simulator

Sickness in der Default-Variante deutlich steiler ansteigt als in der Gamify-Variante. Szenario 6 führt zu einer Art Normalisierung. Während der Wert der stärker ausgeprägten Default-Variante sinkt, bleibt der Wert bei der Gamify-Variante gleich. Szenario 7 führt dann unabhängig der Variante zu einem deutlichen Anstieg.

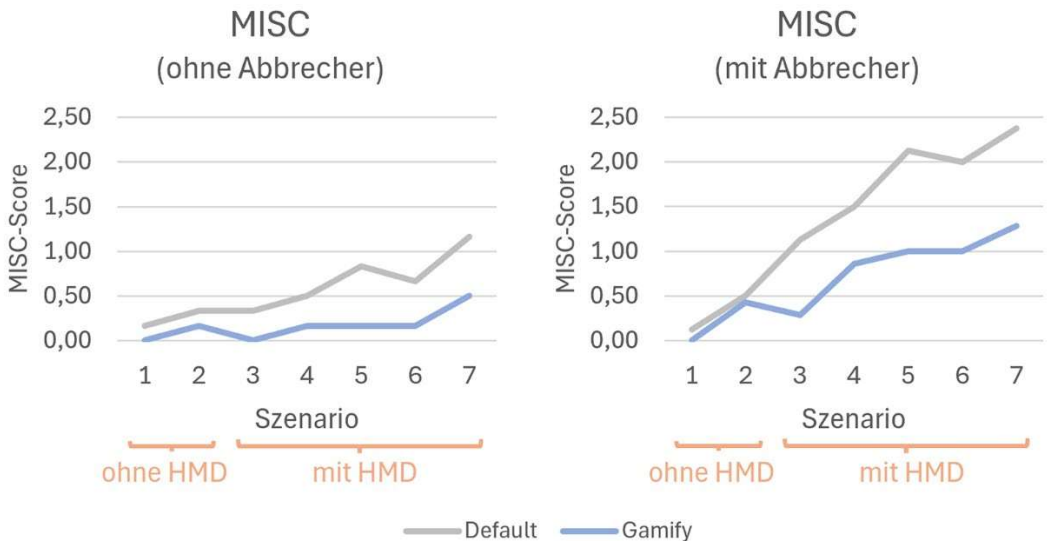


Abb. 34: Diagramm - MISC (Eigene Darstellung, 2024)

7.6 Präsenz Questionnaire

Für die Auswertung wird die durchschnittliche Bewertung der VPs von schlecht bis gut (1-7) der jeweiligen Variante und in den Unterkategorien *Involvement* (INV), *Sensory Fidelity* (SF), *Adaption Immersion* (AI) und *Interface Quality* (IQ) betrachtet. Die Codierung der invertierten Frageitems der Kategorie IQ sind entsprechend neu codiert.

Insgesamt wird die empfundene Präsenz der VPs während des Trainings im oberen Wertebereich eingeschätzt (Abb. 35). Gamify schneidet mit einem Wert von 5,25 besser ab als Default mit 4,67.

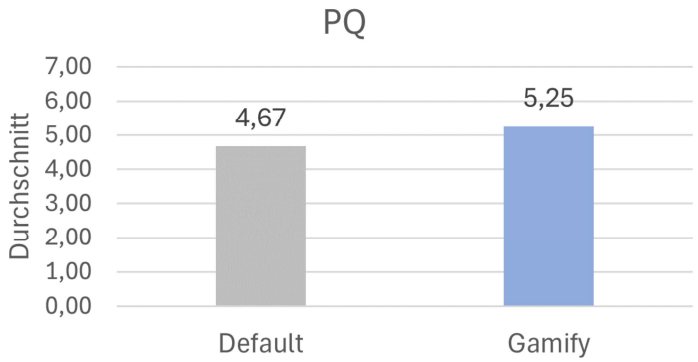


Abb. 35: Diagramm – PQ (Eigene Darstellung, 2024)

Bei der Betrachtung der einzelnen Kategorien zeigt sich, dass die Default-Variante ausschließlich bei der IQ etwas besser abschneidet (Abb. 36). Die Kategorie SF, welche sich auf Sound und die Interaktion mit Objekten bezieht, wird bei Gamify deutlich besser bewertet. Involvement und Immersion nehmen VPs ebenfalls in der Gamify-Variante etwas intensiver wahr.

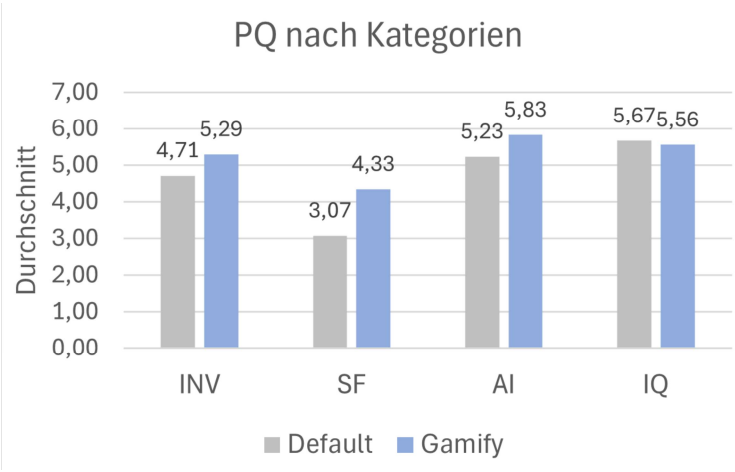


Abb. 36: Diagramm-PQ nach Kategorien (Eigene Darstellung, 2024)

7.7 Technology Acceptance Scale

Für die Auswertung des TAS wird die durchschnittliche Bewertung schlecht (-2) bis gut (2) in den Unterkategorien *Satisfying* und *Usefulness* betrachtet. Die invertierten Frageitems sind neu codiert.

Insgesamt wird das Training bezüglich der Akzeptanz in beiden Varianten zwischen 0,8 bis 1,6 bewertet (Abb. 37) . In beiden Unterkategorien schneidet die Gamification Variante besser ab, für *Satisfying* ist der Unterschied jedoch wesentlich deutlicher.

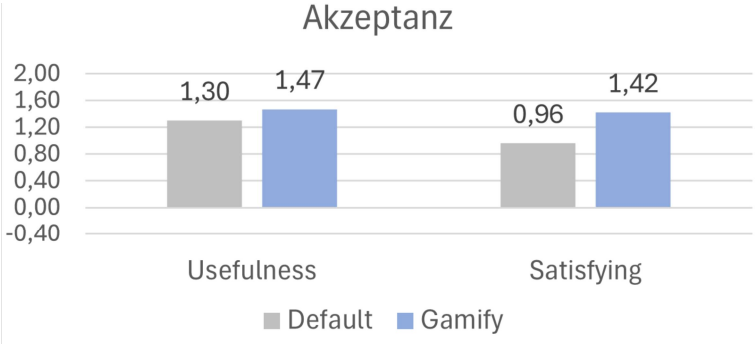


Abb. 37: Diagramm-TAS (Eigene Darstellung, 2024)

Im Bereich *Usefulness* liegen die Ergebnisse in einem Bereich zwischen 0,83 und 1,83, dabei ist ein leichter Trend zur Gamify-Variante zu erkennen (Abb. 38). Die direkte Frage nach der „Nützlichkeit“ wird sogar in der Default Version positiver beurteilt. Als „hilfreich“ und „aktivierend“ werden beide Varianten im gleichen Maße eingeschätzt. Ob das Training „gut“ und „effizient“ ist, beurteilen die VPs wiederum zu Gunsten der Gamify-Variante. In der Kategorie *Satisfying* liegen die Werte in einem Bereich zwischen 0,5 und 1,67, es besteht ein eindeutiger Unterschied zwischen den Varianten. Alle Beurteilungen dieser Kategorie fallen in der Gamify-Variante höher aus. Es wird als „angenehmer“, „netter“, „erfreulicher“ und „wünschenswerter“ empfunden.

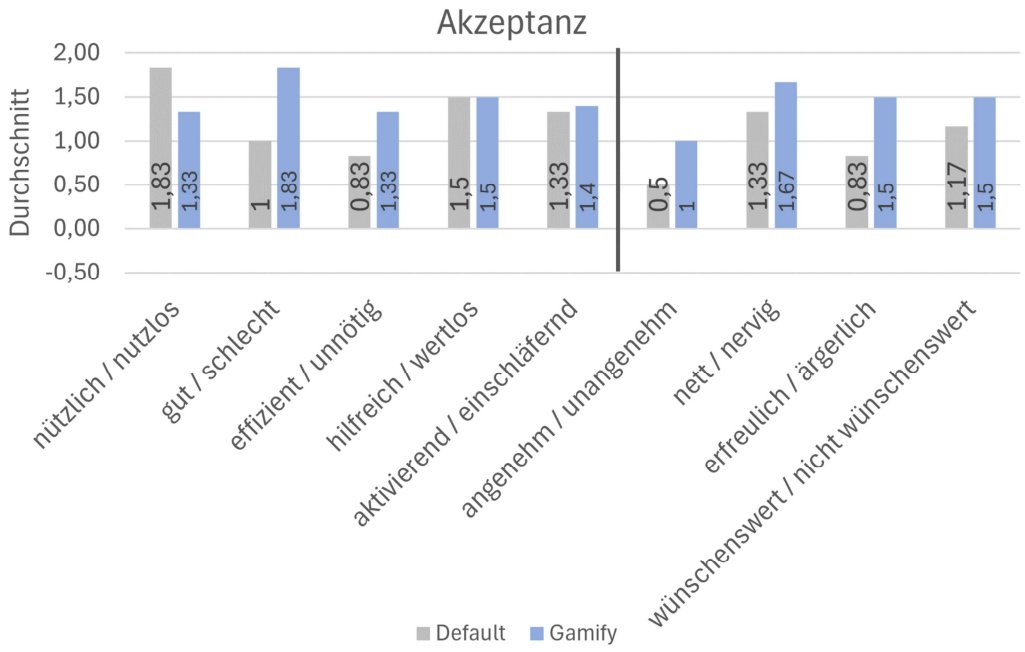


Abb. 38: Diagramm-TAS Subkategorien (Eigene Darstellung, 2024)

7.8 Daten (objektiver Trainingserfolg)

Bei der Auswertung der objektiven Daten werden gesammelte Punkte und berührte Hindernisse Prozentual anhand der im jeweiligen Szenario vorhandenen Objekte ermittelt. Das Training wird durchschnittlich mit 93,6% der zu erreichenden Punkte absolviert (Abb. 39). Die Default-Variante mit 89,77% und Gamify mit 99,6%.

Um zu prüfen, wie erfolgreich das Training hinsichtlich der Kontrolle des Fahrrads ist, werden in Szenario 7 zusätzlich Hindernisse platziert, denen es auszuweichen gilt. Über alle VPs hinweg werden hier 100% der Sammelobjekte/Punkte gesammelt. In der Variante Gamify kollidieren die VPs durchschnittlich mit 71,76% der Hindernisse, während der Wert bei Default nur 63,33% beträgt (Abb. 39).

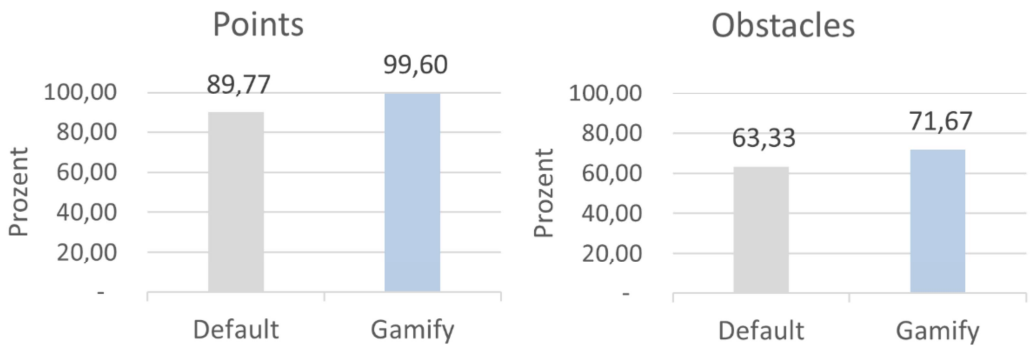


Abb. 39: Diagramm Trainingserfolg Points und Obstacles (Eigene Darstellung, 2024)

Zur Betrachtung der gefahrenen Zeit wird die durchschnittlich benötigte Zeit der einzelnen Szenarios aufsummiert. Insgesamt werden die Szenarios in der Gamify-Variante schneller absolviert (Abb. 40). Die durchschnittliche reine Fahrzeit des Trainings (ohne Unterbrechungen) beträgt 4,25 min.

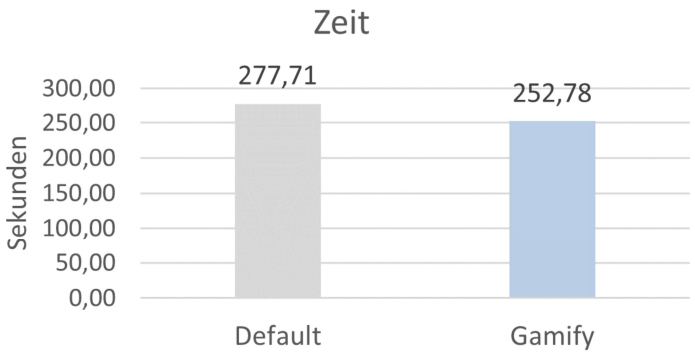


Abb. 40: Diagramm Trainingserfolg Zeit (Eigene Darstellung, 2024)

8 Diskussion

Im Folgenden werden die Ergebnisse im Hinblick auf die Forschungsfragen diskutiert sowie Limitationen und Verbesserungsvorschläge aufgezeigt. Aufgrund der geringen Stichprobengröße sind die Ergebnisse nicht repräsentativ. Da jedoch fast alle Ergebnisse eine ähnliche Tendenz aufweisen, kann dennoch von einer gewissen Aussagekraft ausgegangen werden.

8.1 RQ1: Trainingserfolg

Haben die Gamification-Elemente einen Einfluss auf den Trainingserfolg beim Einsatz des Fahrradsimulators?

Insgesamt kann der Trainingserfolg hinsichtlich der zu erreichenden Anforderungen als positiv bewertet werden. Die VPs fühlen sich gut vorbereitet, erreichen eine hohe Punktzahl und können somit dem Pfad gut folgen, wobei eine leichte Tendenz zu Gunsten der Gamify-Variante zu erkennen ist.

Auf subjektiver Ebene lässt sich festhalten, dass sich die meisten VPs sicher und gut vorbereitet für die Teilnahme an einer Studie mit realistischen Verkehrsszenarios fühlen. Einige VPs wünschen sich sogar noch mehr Herausforderung. Ein auffälliger Unterschied zwischen den Varianten kann nicht festgestellt werden.

Die Betrachtung der objektiven Daten zeigt, dass die VPs in der Gamify-Variante das Training im Schnitt ca. 25 Sekunden schneller absolvieren und zudem 10% mehr Punkte einsammeln. Das bessere Abschneiden bei Gamify könnte ein Indikator für eine hohe Motivation sein. Nach Sailer steigere nämlich eine erhöhte Motivation sowohl die qualitative als auch die quantitative Leistung (vgl. Sailer 2016). Allerdings deuten die häufigeren Kollisionen bei dieser Variante daraufhin, dass das gesteigerte Motivationsniveau ggf. einen negativen Einfluss auf die Präzision des Fahrverhaltens haben kann.

Die gesamte Durchführung des Trainings ohne Pausen beträgt durchschnittlich 4:25 Minuten und sollte somit unter Realbedingungen dem vorgegebenen zeitlichen Rahmen von 5 bis 7 Minuten entsprechen.

8.2 RQ2: Simulator Sickness

Wird Simulator Sickness beim Einsatz des Fahrradsimulators durch Gamification-Elemente beeinflusst?

Die in Bezug auf die Simulator Sickness erhobenen Daten zeigen, dass VPs in der Gamify-Variante eine wesentlich geringere Ausprägung der entsprechenden Symptome aufweisen. Der *Total Score* des SSQ liegt hier mit 3,49 unter 5, also nach Bimberg et al. im Bereich „vernachlässigbar“ (vgl. Bimberg et al. 2020). Während der TS bei der Default-Variante nur knapp unter 10 und somit als „minimal“ bezeichnet werden kann (vgl. ebd.).

Auch bei genauerer Betrachtung der einzelnen Symptome zeigt sich ein deutlicher Unterschied zwischen den Varianten. Sowohl Häufigkeit als auch Schwere der genannten Symptome sind in der Default-Variante eindeutig stärker ausgeprägt. Allerdings ist festzustellen, dass die Symptome „Schwitzen“, „Übelkeit“ und „Schwindel“ auch in der Gamify-Variante häufiger auftreten.

Die Auswertung der MISC zeigt, dass die 90-Grad-Kurven des 2. Szenarios, die lange Kurve des 4. Szenarios und der Slalom in Szenario 7 von den VPs wie erwartet und von Stoner beschrieben als unangenehm empfunden werden (vgl. Stoner et al. 2011). Durch das 6. Szenario mit den seichteren S-Kurven kann scheinbar eine ausgleichende Wirkung erzielt werden. Bei Betrachtung der einzelnen VPs lässt sich auch feststellen, dass wie von Weech et al. beschrieben, bei manchen Personen gar keine Symptome auftreten (vgl. Weech et al. 2019). Drei VPs müssen den Versuch mit einem MISC-Wert von 6 (leichte Übelkeit) vorzeitig abbrechen, davon zwei in der Default- und eine in der Gamify-Variante. Wie von Stoner et al. beschrieben, war die Simulator Sickness der Hauptgrund für abgebrochene Versuche (vgl. Stoner et al. 2011).

Das bessere Ergebnis in der Gamify-Variante deutet darauf hin, dass VPs durch Gamification-Elemente stärker abgelenkt werden, denn nach Bos führe die Lenkung der Aufmerksamkeit auf eine Aufgabe dazu, dass Unwohlsein weniger wahrgenommen werde (vgl. Bos 2015). Zudem ist von einer erhöhten Motivation der VPs auszugehen, die nach Sailer durch Bedürfnisbefriedigung erreicht werden könne (vgl. Sailer 2016). Das Zerplatzen lassen der Seifenblasen und das Anzeigen der gesammelten Punkte wurde von den VPs in offenen Fragen positiv hervorgehoben und als „befriedigend“ beschrieben.

Ein weiterer Grund für das vermehrte Auftreten von Symptomen in der Default-Variante könnte die Platzierung der Sammelobjekte sein. Da sich die Markierungen dieser Variante direkt am Boden befinden, müssen VPs während der Fahrt häufiger nach unten gucken, das könnte Symptome verstärken. Jedoch geben die VPs an, die Markierungen gut erkennen zu können, sogar etwas besser als in der Gamify-Variante. Für eine weitere Verbesserung des Trainings sollte daher getestet werden, ob andere Objekte oder eine Kombination zu besseren Ergebnissen führen.

8.3 RQ3: Präsenz

Wird die Präsenz beim Einsatz des Fahrradsimulators durch Gamification-Elemente beeinflusst?

Insgesamt erreichen VPs in beiden Varianten des Trainings ein mittleres bis hohes Präsenz-Level. Die Ergebnisse zeigen eine leichte Tendenz zu Gunsten der Gamify-Variante.

In den einzelnen Kategorien lässt sich erkennen, dass Gamify insbesondere bei den Fragen zum Sound eindeutig besser abschneidet. Das akustische Feedback durch das Einsammeln der Seifenblasen und Erreichen der Haltelinie hat somit einen positiven Einfluss auf das Empfinden der Präsenz. In den Fragekategorien zu *Involvement* und *Immersion* ergibt sich ebenfalls eine leichte Tendenz zugunsten der Gamify-Variante. Nach Witmer und Singer tragen diese zwei Faktoren maßgeblich zur Erhöhung der Präsenz bei,

vor allem *Involvement* weise auf eine gesteigerte Aufmerksamkeit hin (vgl. Witmer und Singer 1998). Dementsprechend kann davon ausgegangen werden, dass der Einsatz von Gamification-Elementen den Fokus auf die zu erledigende Aufgabe steigert.

Lediglich im Bereich der Interfacequalität schneidet die Default-Variante etwas besser ab. Um die Qualität zu optimieren, könnte die Darstellung der Seifenblasen angepasst oder ein aktuelleres HMD verwendet werden. Letzteres könnte durch eine höhere Auflösung, weniger Latenz und ein breiteres Sichtfeld die Interfacequalität insgesamt verbessern.

8.4 RQ4: Akzeptanz

Wird Akzeptanz beim Einsatz des Fahrradsimulators durch Gamification-Elemente beeinflusst?

Die Ergebnisse zur Akzeptanz zeigen insbesondre in der Kategorie *Satisfying* einen eindeutigen Unterschied zwischen den Varianten, alle Fragen dieser Kategorie werden zu Gunsten der Gamify-Variante beantwortet. Dies ist ein weiterer Hinweis auf eine erhöhte Motivation, durch den Einsatz von Gamification-Elementen, da nach Davis motivierende Faktoren bei der Akzeptanz einer Technologie eine große Rolle spielen (vgl. Davis et al. 1989).

Auch die Kategorie *Usefulness* wird bei Gamify insgesamt besser bewertet. Die direkte Frage nach der „Nützlichkeit“ bzw. „Nutzlosigkeit“ wird allerdings von den VPs in der Default-Variante etwas besser eingestuft. Dies spiegelt sich in den anderen Fragen dieser Kategorie nicht wider. So wird bspw. bei den Fragen nach „gut“ und „effizient“ eindeutig die Gamify-Variante bevorzugt. Ein möglicher Grund dafür könnte sein, dass der Nutzen von Spielen/Simulatoren oft als gering und Zeitverschwendung betrachtet wird. Die Assoziation mit „Mario Kart“ legt nahe, dass VPs den Gamification-Ansatz wahrnehmen.

8.5 Zusammenfassung

Zusammenfassend lässt sich feststellen, dass alle Ergebnisse für das Training sowohl mit als auch ohne Gamification-Elemente positiv ausgefallen sind. Unabhängig von der Variante geben die VPs an, sich gut vorbereitet zu fühlen. Sie können die gestellten Aufgaben wie gewünscht ausführen und den vorgegebenen Pfaden gut folgen. Im letzten Szenario sammelten alle VPs 100% der Punkte ein. Akzeptanz, Präsenz und Trainingserfolg sind in beiden Varianten sehr positiv bewertet. Der *Total Score* für die Simulator Sickness liegt in beiden Varianten unter 10. Dies weist darauf hin, dass Motivation und Aufmerksamkeit auf einem hohen Level waren und nur minimale Nebenwirkungen auftreten.

In Bezug auf den Unterschied zwischen den Varianten zeigt sich die Tendenz, dass Gamification-Elemente einen positiven Effekt haben. Die Ergebnisse zur Akzeptanz weisen einen deutlichen Unterschied zwischen den Varianten auf. In der Gamify-Variante werden alle Fragen der Kategorie *Satisfying* besser bewertet. Bei der Beurteilung der Simulator Sickness ist sogar ein drastischer Unterschied zu erkennen. Die VPs, die den Versuch in der Gamify-Variante absolvierten, geben wesentlich weniger Symptome in geringerer Ausprägung an. Der *Total Score* liegt bei nur 3,49, also im Bereich „vernachlässigbar“. Die Resultate zum Trainingserfolg zeigen eine leicht positive Tendenz zu Gunsten der Gamify-Variante. Die objektiven Daten zeigen, dass die VPs mehr Punkte in einer kürzeren Zeit einsammeln. Das Präsenz-Level ist ebenfalls leicht erhöht, vor allem die Ergebnisse der Kategorie *Sensory Fidelity* weisen darauf hin, dass eine Ablenkung durch das akustische Feedback (Zerplatzen der Seifenblasens) erreicht wird.

Aus diesen Ergebnissen lässt sich schließen, dass in der Gamify-Variante die Aufmerksamkeit noch stärker auf die Aufgaben gerichtet und die Motivation höher ist. Die Gamification-Elemente haben demnach entweder einen positiven oder keinen entscheidenden Einfluss auf die betrachteten Variablen. Außerdem werden keine auffälligen negativen Auswirkungen beobachtet.

8.6 Limitation

Trotz der guten Beurteilung des Trainings können verschiedene Aspekte in Zukunft verbessert, angepasst und erneut evaluiert werden. Der folgende Abschnitt zeigt Limitationen und Verbesserungsvorschläge für das Training sowie die Versuchsdurchführung auf.

Bei der Interfacequalität schneidet die Gamify-Variante ein wenig schlechter ab. Dies spiegelt sich in den offenen Fragestellungen nach negativen Faktoren wider. Von VPs, welche die Gamify-Variante fahren, wird eine „künstliche“ Darstellung erwähnt und darauf hingewiesen, dass die Seifenblasen im Schatten nicht leicht zu erkennen sind. Um dies zu verbessern, könnte ein aktuelleres HMD verwendet werden. Zusätzlich könnten die Seifenblasen durch weitere Markierungen oder Lumineszenz auch in schattigen Bereichen besser kenntlich gemacht werden.

Szenarios, in denen Handzeichen und Schulterblick oder das Ausweichen vor bewegten Objekten im Vordergrund stehen, wären eine sinnvolle Ergänzung des bestehenden Trainings. Durch den modularen Aufbau der Szenarios könnten weitere Szenarios hinzugefügt oder bestehende angepasst werden.

Weitere Gamification-Elemente wie Levelaufstieg, ein Avatar zur Repräsentation der VP oder die Implementierung der Instruktion innerhalb der virtuellen Umgebung könnten dazu beitragen, die Motivation und Aufmerksamkeit weiter zu erhöhen. Allerdings sollten neue Elemente evaluiert werden, um ungewünschte Nebeneffekte besser identifizieren und vermeiden zu können. Das Anzeigen der Fahrzeit in der Gamify-Variante könnte dazu beitragen, dass VPs den Eindruck haben, sie müssten das Training so schnell wie möglich absolvieren. Dies könnte der Grund für die höhere Anzahl an Kollisionen im letzten Szenario sein. Es sollte überprüft werden, ob das Ergebnis besser ausfällt, wenn die Zeit nicht angezeigt wird.

Zudem wäre es sinnvoll, die Versuche mit einem aussagekräftigeren Stichprobenumfang durchzuführen, damit Ergebnisse auch auf Signifikanz überprüft werden können. Interessant wäre auch, die Korrelationen zwischen Trainingserfolg, Simulator Sickness, Präsenz und Akzeptanz zu

evaluieren. Der vorliegende Stichprobenumfang ist sehr klein, weshalb es schwierig ist, zwischen zufälligen und kausalen Zusammenhängen zu unterscheiden. Zum Beispiel ist davon auszugehen, dass sich das mildere Auftreten von Simulator Sickness auf andere Bewertungen auswirkt. Denn nach Weech et al. könne das auftretenden von starken Symptomen die Aufmerksamkeit von der virtuellen Umgebung weglenken und das Präsenz-Level mindern (vgl. Weech et al. 2019). Zudem hätten Faktoren wie Stress eine negative Auswirkung auf die Motivation und somit die Akzeptanz einer Person (vgl. Szalma 2014). Andererseits könnte die Wirkung auch umgekehrt sein, somit wäre die erhöhte Präsenz und Akzeptanz für die geringere Ausprägung der Simulator Sickness Symptome verantwortlich (vgl. Weech et al. 2019).

Da die VPs zudem ausschließlich Mitarbeitende des DLRs waren, ist anzunehmen, dass ein Großteil bereits Erfahrung mit Simulatoren und virtuellen Umgebungen hat. Auch hier könnte ein repräsentativer Stichprobenumfang die Aussagekraft weiter stärken. Außerdem wären zusätzliche Fragen zu den demografischen Faktoren, insbesondere hinsichtlich der Vorerfahrung mit Simulatoren, VR-Anwendungen und Computerspielen hilfreich. Denn nach Kennedy et al. könne durch wiederholte Verwendung ein Gewöhnungseffekt eintreten (vgl. Kennedy et al. 2000).

Für die Erfassung der Präsenz könnte vor der Versuchsfahrt zusätzlich der *Immersive Tendencies Questionnaire* von Witmer und Singer verwendet werden (vgl. Witmer und Singer 1998). Dieser gibt einen Hinweis auf die Tendenz einer Person gesteigerte Präsenz zu empfinden.

Symptome der Kategorie Übelkeit sind in der Default-Variante mit einem Wert von 20,67 besonders stark ausgeprägt. Nach Kennedy et al. seien Symptome dieser Kategorie in der Regel bewegungsinduzierten Auslösern zuzuordnen (vgl. Kennedy et al. 1993). Demnach wäre daraus zu schließen, dass das vermehrte Auftreten von Simulator Sickness weniger durch die visuellen Reize als vielmehr durch die Eigenbewegung des Simulators verursacht wird. Diese Erklärung scheint im Rahmen der durchgeführten Erhebung jedoch keine vollumfängliche Gültigkeit zu haben, da sich die beiden Varianten hauptsächlich auf der Ebene der Darstellung unterscheiden.

Die möglichen DOF des Simulators sind für beide Varianten identisch. Somit lässt sich nicht eindeutig feststellen, ob auftretende Symptome durch asynchrone Bewegung des Simulators oder visuell verursacht werden.

Eine genauere Betrachtung der VPs, die den Versuch vorzeitig abbrechen müssen, könnte wichtige Hinweise bzgl. der auslösenden Faktoren für Simulator Sickness liefern. Die Tatsache, dass manche Personen keine Symptome empfinden, während andere schon nach wenigen Minuten abbrechen müssen, sollte genauer untersucht werden. Die hohe Abbruchquote von 50% bei weiblichen VPs entspricht den Beobachtungen der meisten Studien, dass Frauen stärker zu Simulator Sickness neigen (vgl. Grassini und Laumann 2020). Diese geschlechtsspezifischen Unterschiede sollten näher erforsch werden, um die Abbruchquote zu senken. Vielleicht könnte ein Fragebogen speziell für VPs, die während der Fahrt besonders stark unter Simulator Sickness leiden, weitere Erkenntnisse darüber liefern, welche Faktoren für das vermehrte Auftreten von Symptomen verantwortlich sind. Wünschenswert wäre zudem ein objektives Maß zur Erfassung der Simulator Sickness, bspw. durch die Auswertung biometrischer Daten.

9 Fazit

Die vorliegende Arbeit hatte die Entwicklung und Evaluation einer Trainingsumgebung zur Vorbereitung von VPs auf eine Studie mit Fahrradsimulator zum Ziel. Mit Hilfe der UE5 wurden reproduzierbare Szenarios mit festgelegten Aufgaben entwickelt. Die zu Beginn in Expertenrunden des DLRs festgelegten Anforderungen wurden erfolgreich umgesetzt. Das als Plugin zur Verfügung gestellte Projekt enthält die entsprechende Umgebung, anpassbare Szenarios und ein Fahrradmodell, welches dem Rahmen des Simulators nachempfunden ist. Die Zusammenführung mit den beiden DLR internen Plugins zur Simulatorkopplung und Datenerfassung verlief wie geplant. Zwei verschiedene Varianten mit und ohne Gamification-Elemente wurden erstellt und im Anschluss evaluiert. Zur Erfassung subjektiver Angaben kamen verschiedenen Fragebögen zum Einsatz, während die objektiven Ergebnisse auf den zur Laufzeit erfassten Daten beruhen.

Allgemein lässt sich festhalten, dass unabhängig der jeweiligen Variante ein positiver Effekt auf den Trainingserfolg zu verzeichnen ist. Die VPs geben an, sich gut vorberietet zu fühlen und die Punkte werden im letzten Szenario zu 100% eingesammelt. Dies zeigt, dass die VPs zum Schluss des Trainings das Fahrrad unter Kontrolle haben.

Die Evaluation zeigt außerdem, dass die Gamify-Variante gegenüber der Default-Variante tendenziell besser bewertet wird. Die Akzeptanz ist deutlich gesteigert und Simulator Sickness-Symptome tritt sogar drastisch weniger auf, der *Total Score* liegt bei nur 4,36. Die Ergebnisse zu subjektivem Trainingserfolg und Präsenz zeigen einen leichten Trend zu Gunsten der Gamify-Variante. Die objektiven Daten zum Trainingserfolg zeigen, dass die VPs in der Gamify-Variante 10% mehr Punkte einsammelten und das Training insgesamt schneller absolvierten.

Die Ergebnisse deuten darauf hin, dass Motivation und Aufmerksamkeit durch den Gamification-Ansatz gesteigert werden. Die Gamification-Elemente haben überwiegend einen positiven Einfluss auf die betrachteten Variablen. Auffällige negative Effekte, die gegen den Einsatz der Gamify-

Variante sprechen, zeigen sich nicht. Es lässt sich also festhalten, dass es sich durchaus lohnen kann, Gamification-Elemente für das Training einzusetzen, um das Auftreten unerwünschter Nebenwirkungen zu reduzieren.

In der Forschungsgruppe MZS des DLR wurde das alte Fahrradmodell für den Fahrradsimulator durch das neue angepasste Modell ersetzt und das Plugin wird bereits in verschiedenen Studien zur Vorbereitung der VPs eingesetzt.

9.1 Ausblick

Trotz der guten Bewertungen könnten weitere Anpassungen der Gamification-Elemente und erneute Evaluierungen dazu beitragen, das Training zu optimieren.

Aktuelle Studien auf dem Fahrradsimulator werden bereits mit einem leistungsstärkeren HMD durchgeführt und sollten somit eine bessere Interfacequalität aufweisen.

Eine repräsentativere Stichprobe würde die Aussagekraft der Ergebnisse erhöhen. Insbesondere eine genauere Untersuchung der VPs, die den Versuch wegen Simulator Sickness abbrechen müssen, könnte interessante Erkenntnisse darüber liefern, wie die Abbruchquote gesenkt werden kann.

Die Default-Variante des Trainings ist so aufgebaut, dass die Szenarios auf dem realen ADAC-Verkehrsübungsplatz in Braunschweig umgesetzt werden können. Somit wird ermöglicht, dass das Training als Versuchsfahrt für die Studie „BEAVER“ zur Validierung des Fahrradsimulators verwendet werden kann. Die gesammelten Daten von Fahrten auf dem Fahrradsimulator und einem mit Sensoren ausgestatteten Forschungsfahrrad sollen verglichen werden. Auf diese Weise wird ermittelt, inwiefern die Ergebnisse des Simulators mit realen Situationen vergleichbar sind.

Darüber hinaus wird derzeit das Plugin für die Entwicklung eines angepassten Trainings zur Vorbereitung der VPs für die kommende Studie „Stadt:UP“ verwendet. Hierfür werden die modellierten Sammelobjekte, der virtuelle Übungsplatz und Funktionen zur Erstellung von Szenarios eingesetzt.

Literaturverzeichnis

ANSARIYAR, Alireza, Eazaz **SADEGHVAZIRI** und Mansoureh **JEIHANI**. 2022. Systematic Review of Bike Simulator Studies. *Journal of Science and Cycling* 11, Nr. 1 (30. Juni): 5–29. doi:10.28985/1322.jsc.01.

BERGHOEFER, Frauke Luise und Mark **VOLLRATH**. 2023. Prefer what you like? Evaluation and preference of cycling infrastructures in a bicycle simulator. *Journal of Safety Research* 87 (1. Dezember): 157–167. doi:10.1016/j.jsr.2023.09.013.

BIMBERG, Pauline, Tim **WEISSKER** und Alexander **KULIK**. 2020. On the Usage of the Simulator Sickness Questionnaire for Virtual Reality Research. In: *Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*, 464–467. Weimar: IEEE, 11. Mai. doi:10.1109/VRW50115.2020.00098.

BOS, Jelte. 2015. Less sickness with more motion and/or mental distraction. *Journal of vestibular research : equilibrium & orientation* 25 (17. April): 23–33. doi:10.3233/VES-150541.

BOS, Jelte E., Sjoerd C. **DE VRIES**, Martijn L. **VAN EMMERIK** und Eric L. **GROEN**. 2010. The effect of internal and external fields of view on visually induced motion sickness. *Applied Ergonomics* 41, Nr. 4. Special Section - The First International Symposium on Visually Induced Motion Sickness, Fatigue, and Photosensitive Epileptic Seizures (VIMS2007) (1. Juli): 516–521. doi:10.1016/j.apergo.2009.11.007.

BOWMAN, Doug A. und Ryan P. **MCMAHAN**. 2007. Virtual Reality: How Much Immersion Is Enough? *Computer* 40, Nr. 7 (Juli): 36–43. doi:10.1109/MC.2007.257.

BROOKS, Johnell O., Richard R. **GOODENOUGH**, Matthew C. **CRISLER**, Nathan D. **KLEIN**, Rebecca L. **ALLEY**, Beatrice L. **KOON**, et al. 2010. Simulator sickness during driving simulation studies. *Accident; Analysis and Prevention* 42, Nr. 3 (Mai): 788–796. doi:10.1016/j.aap.2009.04.013.

CHA, Yoon-Hee, John **GOLDING**, Behrang **KESHAVARZ**, Joseph **FURMAN**, Ji-Soo **KIM**, Jose **LOPEZ-ESCAMEZ**, et al. 2021. Motion sickness diagnostic criteria: Consensus Document of the Classification Committee of the Bárány Society. *Journal of Vestibular Research* 31 (26. Februar): 1–17. doi:10.3233/VES-200005.

COBB, Sue V. G., Sarah **NICHOLS**, Amanda **RAMSEY** und John R. **WILSON**. 1999. Virtual Reality-Induced Symptoms and Effects (VRISE). *Presence: Teleoperators and Virtual Environments* 8, Nr. 2 (April): 169–186. doi:10.1162/105474699566152.

DAVIS, Fred. 1985. A Technology Acceptance Model for Empirically Testing New End-User Information Systems. Thesis (Ph. D.), Massachusetts Institute of Technology, Sloan School of Management, 1. Januar.

DAVIS, Fred, Richard **BAGOZZI** und Paul **WARSHAW**. 1989. User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science* 35 (1. August): 982–1003. doi:10.1287/mnsc.35.8.982.

DECI, Edward L. und Richard M. **RYAN**. 1985. Intrinsic Motivation and Self-Determination in Human Behavior. In: . Boston, MA: Springer US.

doi:10.1007/978-1-4899-2271-7http://link.springer.com/10.1007/978-1-4899-2271-7 (zugegriffen: 29. April 2024).

DETERDING, Sebastian, Dan **DIXON**, Rilla **KHALED** und Lennart **NACKE**. 2011. From game design elements to gamefulness: defining „gamification". In: *Proceedings of the 15th International Academic MindTrek Conference: Envisioning Future Media Environments*, 9–15. MindTrek '11. New York, NY, USA: Association for Computing Machinery, 28. September. doi:10.1145/2181037.2181040.

DLR. o.D. Deutsches Zentrum für Luft- und Raumfahrt - Institut für Verkehrssystemtechnik - Home. https://www.dlr.de/ts (zugegriffen: 31. Mai 2023a).

---. o.D. MoSAIC – Labor für Multi-User-Simulation. https://www.dlr.de/de/ts/forschung-und-transfer/forschungsinfrastruktur/simulatoren/mosaic (zugegriffen: 8. Juli 2024b).

DZIUDA, Łukasz, Marcin P. **BIERNACKI**, Paulina M. **BARAN** und Olaf E. **TRUSZCZYŃSKI**. 2014. The effects of simulated fog and motion on simulator sickness in a driving simulator and the duration of after-effects. *Applied Ergonomics* 45, Nr. 3 (1. Mai): 406–412. doi:10.1016/j.apergo.2013.05.003.

EBENHOLTZ, Sheldon. 1992. Motion Sickness and Oculomotor Systems in Virtual Environments. *Presence* 1 (1. Januar): 302–305. doi:10.1162/pres.1992.1.3.302.

EUROPÄISCHE KOMMISSION. 2023. Straßenverkehrssicherheit in der EU. Text. Brüssel: Europäische Kommission. https://ec.europa.eu/commission/presscorner/detail/de/ip_23_953 (zugegriffen: 16. April 2024).

GRASSINI, Simone und Karin **LAUMANN**. 2020. Are Modern Head-Mounted Displays Sexist? A Systematic Review on Gender Differences in HMD-Mediated Virtual Reality. *Frontiers in Psychology* 11 (7. August). doi:10.3389/fpsyg.2020.01604.

HAMARI, Juho, Jonna **KOIVISTO** und Harri **SARSA**. 2014. Does Gamification Work? – A Literature Review of Empirical Studies on Gamification. In: *2014 47th Hawaii International Conference on System Sciences*, 3025–3034. Januar. doi:10.1109/HICSS.2014.377.

HEINZ, Matthias und Helge **FISCHER**. 2020. Ausgespielt? Zu Risiken und Nebenwirkungen von Gamification. In: , 318–331. 4. Dezember.

JERALD, Jason. 2015. *The VR Book: Human-Centered Design for Virtual Reality*. Morgan & Claypool.

JURCZOK, Franziska, Tim **GENSHEIMER** und Felix **SPECHT**. 2023. Fahrrad-Monitor 2023. Heidelberg: SINUS Markt- und Sozialforschung GmbH, mit Förderung des Bundesministeriums für Digitales und Verkehr. https://bmdv.bund.de/SharedDocs/DE/Artikel/StV/Radverkehr/fahrradmonitor.html (zugegriffen: 16. April 2024).

KENNEDY, Robert S., Norman E. **LANE**, Kevin S. **BERBAUM** und Michael G. **LILIENTHAL**. 1993. Simulator Sickness Questionnaire: An Enhanced Method for Quantifying Simulator Sickness. *The International Journal of Aviation Psychology* 3, Nr. 3 (1. Juli): 203–220. doi:10.1207/s15327108ijap0303_3.

KENNEDY, Robert, Kay **STANNEY** und William **DUNLAP**. 2000. Duration and Exposure to Virtual Environments: Sickness Curves During and Across

Sessions. *Presence* 9 (1. Oktober): 463–472. doi:10.1162/105474600566952.

KOIVISTO, Jonna und Juho **HAMARI**. 2019. The rise of motivational information systems: A review of gamification research. *International Journal of Information Management* 45 (1. April): 191–210. doi:10.1016/j.ijinfomgt.2018.10.013.

PAUSCH, R., T. **CREA** und M. **CONWAY**. 1992. A Literature Survey for Virtual Environments: Military Flight Simulator Visual Systems and Simulator Sickness. *Presence: Teleoperators and Virtual Environments* 1, Nr. 3: 344–363. doi:doi.org/10.1162/pres.1992.1.3.344.

PINTO, Maria, Viola **CAVALLO** und Théophile **OHLMANN**. 2008. The development of driving simulators: toward a multisensory solution. *Le travail humain* 71, Nr. 1: 62–95. doi:10.3917/th.711.0062.

REASON, J. T. und J. J. **BRAND**. 1975. *Motion sickness*. Motion sickness. Oxford, England: Academic Press.

RICCIO, Gary und Thomas **STOFFREGEN**. 1991. An Ecological Theory of Motion Sickness and Postural Instability. *Ecological Psychology - ECOL PSYCHOL* 3 (1. September): 195–240. doi:10.1207/s15326969eco0303_2.

SAILER, Michael. 2016. *Die Wirkung von Gamification auf Motivation und Leistung: Empirische Studien im Kontext manueller Arbeitsprozesse*. doi:10.1007/978-3-658-14309-1.

SCHMID, Daniela. 2022. The technology acceptance scale: Its Bayesian psychometrics assessed in a factor analysis via Markov chain Monte Carlo models. *Human Factors and Ergonomics in Manufacturing & Service Industries* 32, Nr. 1: 66–88. doi:10.1002/hfm.20896.

SCHÖLLHORN, Wolfgang, Hendrik **BECKMANN**, D. **JANSSEN** und M. **MICHELBRINK**. 2009. Differenzielles Lehren und Lernen im Sport. Ein alternativer Ansatz für einen effektiven Schulsportunterricht. *Sportunterricht* 58 (1. Januar): 36–40.

SCHRÖDER, Jan. 2010. Grundlagen des Trainings: Ausdauer, Kraft, Bewegung und Koordination. In: *Bewegungstherapie bei internistischen Erkrankungen*, hg. von Klaus-Michael Braumann und Niklas Stiller, 23–37. Berlin, Heidelberg: Springer. doi:10.1007/978-3-642-01332-4_3.

STANNEY, Kay, Ronald **MOURANT** und Robert **KENNEDY**. 1998. Human Factors Issues in Virtual Environments: A Review of the Literature. *Presence* 7 (1. August): 327–351. doi:10.1162/105474698565767.

STONER, Heather, Donald **FISHER** und Michael **MOLLENHAUER, JR.** 2011. Simulator and Scenario Factors Influencing Simulator Sickness. In: , hg. von John Lee. CRC Press, 15. April. doi:10.1201/b10836-15.

SZALMA, James. 2012. Individual differences in stress, fatigue and performance. *The Handbook of Operator Fatigue* (1. Januar): 75–90.

---. 2014. On the Application of Motivation Theory to Human Factors/Ergonomics. *Human factors* 56 (1. Dezember): 1453–71. doi:10.1177/0018720814553471.

TREISMAN, Michel. 1977. Motion Sickness: An Evolutionary Hypothesis. *Science (New York, N.Y.)* 197 (1. August): 493–5. doi:10.1126/science.301659.

VAN DER LAAN, Jinke D., Adriaan **HEINO** und Dick **DE WAARD**. 1997. A simple procedure for the assessment of acceptance of advanced transport

telematics. *Transportation Research Part C: Emerging Technologies* 5, Nr. 1 (1. Februar): 1–10. doi:10.1016/S0968-090X(96)00025-3.

WEECH, Séamas, Sophie **KENNY** und Michael **BARNETT-COWAN**. 2019. Presence and Cybersickness in Virtual Reality Are Negatively Related: A Review. *Frontiers in Psychology* 10 (1. Februar): 158. doi:10.3389/fpsyg.2019.00158.

WERTHEIM, A. H. 1998. Working in a moving environment. *Ergonomics* 41, Nr. 12 (Dezember): 1845–1858. doi:10.1080/001401398186018.

WERTHEIM, A.H, J.E **BOS** und W **BLES**. 1998. Contributions of roll and pitch to sea sickness. *Brain Research Bulletin* 47, Nr. 5 (November): 517–524. doi:10.1016/S0361-9230(98)00098-7.

WITMER, Bob G., Christian J. **JEROME** und Michael J. **SINGER**. 2005. The Factor Structure of the Presence Questionnaire. *Presence: Teleoperators and Virtual Environments* 14, Nr. 3 (1. Juni): 298–312. doi:10.1162/105474605323384654.

WITMER, Bob G. und Michael J. **SINGER**. 1998. Measuring Presence in Virtual Environments: A Presence Questionnaire. *Presence: Teleoperators and Virtual Environments* 7, Nr. 3 (Juni): 225–240. doi:10.1162/105474698565686.

Link zum Projekt (BST-Plugin):

https://gigamove.rwth-aachen.de/de/download/dfc2be99eb386f1b4437283ea511b484

Passwort: [redacted]

(gültig bis zum 1.8.2024)

Anhang

A: Assetpacks

Defuse Studios. 2016. Realistic Trees. UE Marketplace. 3. Februar. https://www.unrealengine.com/marketplace/en-US/product/realistic-trees (zugegriffen: 21. Januar 2024).

KK Design. 2018. Modular Lost Ruins Kit in Environments. UE Marketplace. 17. Juli. https://www.unrealengine.com/marketplace/en-US/product/modular-lost-ruins-kit (zugegriffen: 21. Januar 2024).

Leartes Studios. 2020. Modern City Downtown with Interiors Megapack (Modular Urban Buildings). UE Marketplace. 15. Januar. https://www.unrealengine.com/marketplace/en-US/product/modern-city-downtown-with-interiors-megapack (zugegriffen: 9. Juli 2023).

Pedja Racan. 2020. Modern City Bundle. UE Marketplace. 22. Juni. https://www.unrealengine.com/marketplace/en-US/product/modern-city-bundle (zugegriffen: 21. Januar 2024).

PolyArt3D. 2021. Low Poly Viking World. UE Marketplace. 23. Oktober. https://www.unrealengine.com/marketplace/en-US/product/low-poly-viking-world (zugegriffen: 21. Januar 2024).

PolyArt3D. 2022. SimPoly Town. UE Marketplace. 7. März. https://www.unrealengine.com/marketplace/en-US/product/simpoly-town (zugegriffen: 21. Januar 2024).

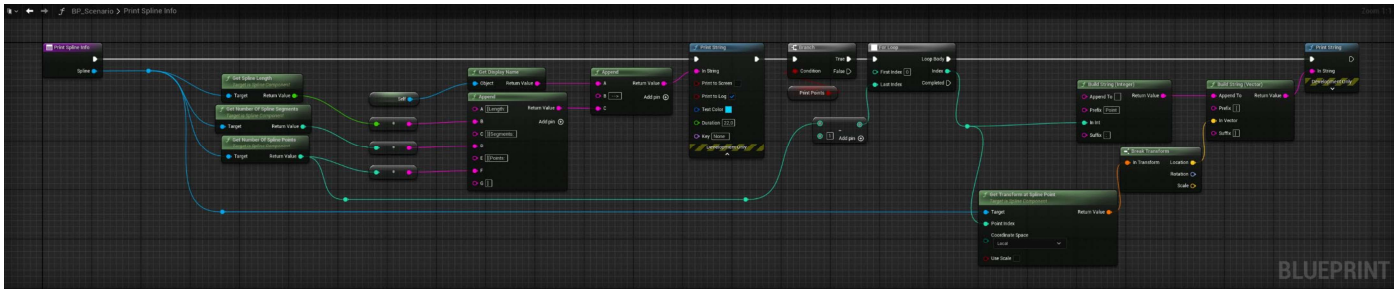
Project Nature. 2018. Temperate Vegetation: Foliage Collection in. UE Marketplace. 30. August. https://www.unrealengine.com/marketplace/en-US/product/interactive-foliage-collection (zugegriffen: 21. Januar 2024).

Quixel Megascans. 2019. Megascans - City Street Vol. 4. UE Marketplace. 1. November. https://www.unrealengine.com/marketplace/en-US/product/b349b05b272d4efaa0e147ea3438902f (zugegriffen: 4. Juni 2024).

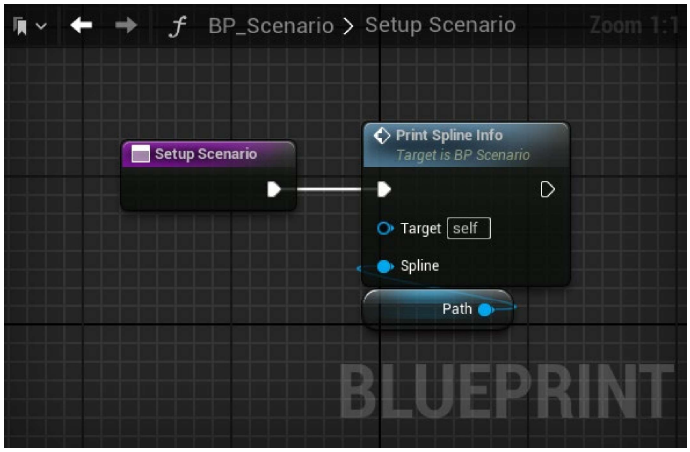
Sibiriakov, Kyrylo. 2016. Industrial Area Hangar. UE Marketplace. 15. Juni. https://unrealengine.com/marketplace/en-US/product/industrial-area-hangar (zugegriffen: 9. Juli 2023).

SilverTm. 2020. City Park Environment Collection. UE Marketplace. 22. September. https://www.unrealengine.com/marketplace/en-US/product/city-park-environment-collection (zugegriffen: 9. Juli 2023).

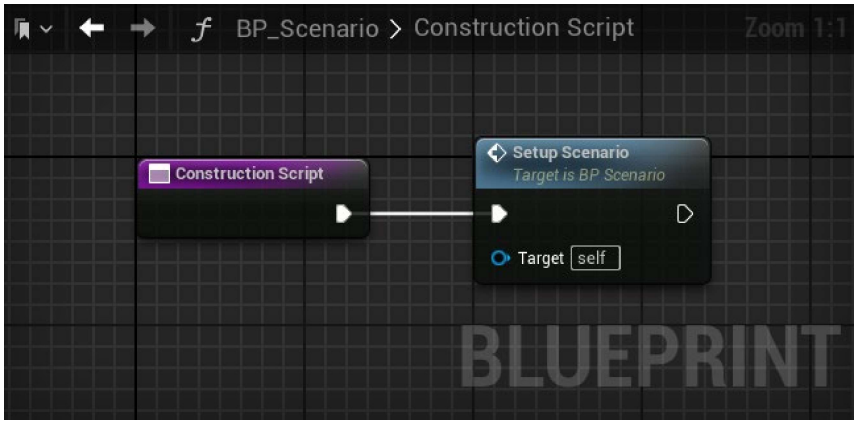
B: Blueprints



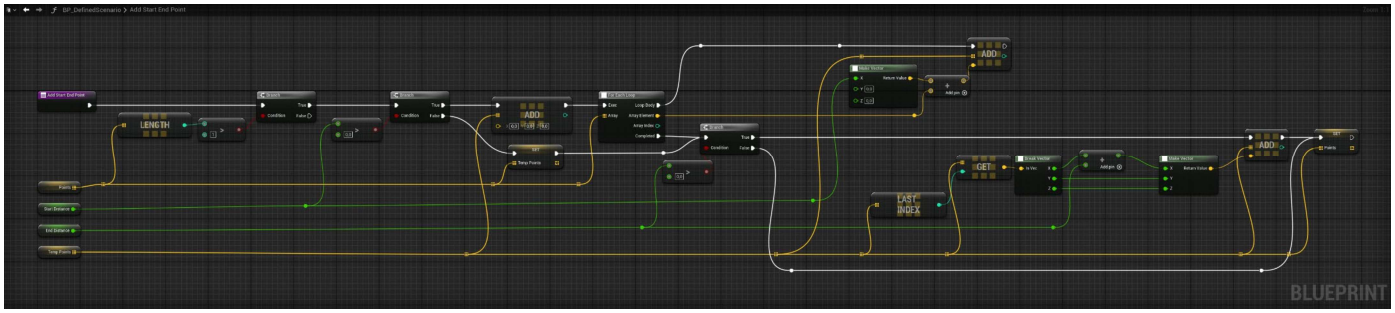
1: BP_Scenario-PrintSplineInfo



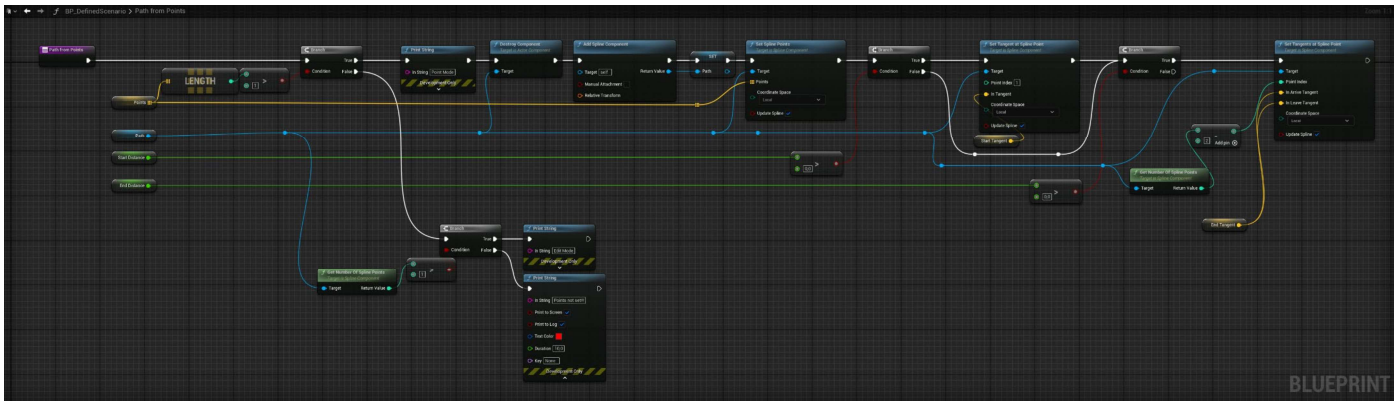
2: BP_Scenario-SetupScenario



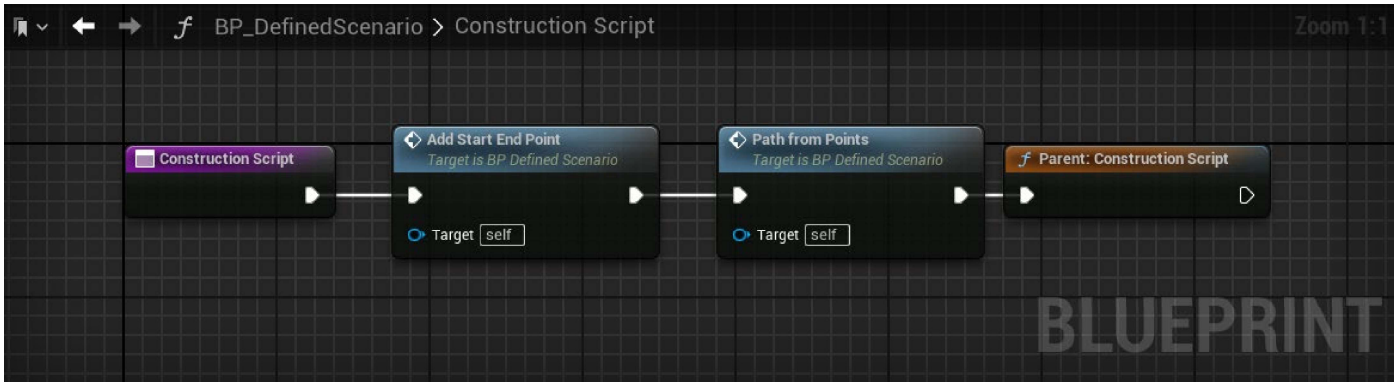
3: BP_Scenario-UserConstructionScript



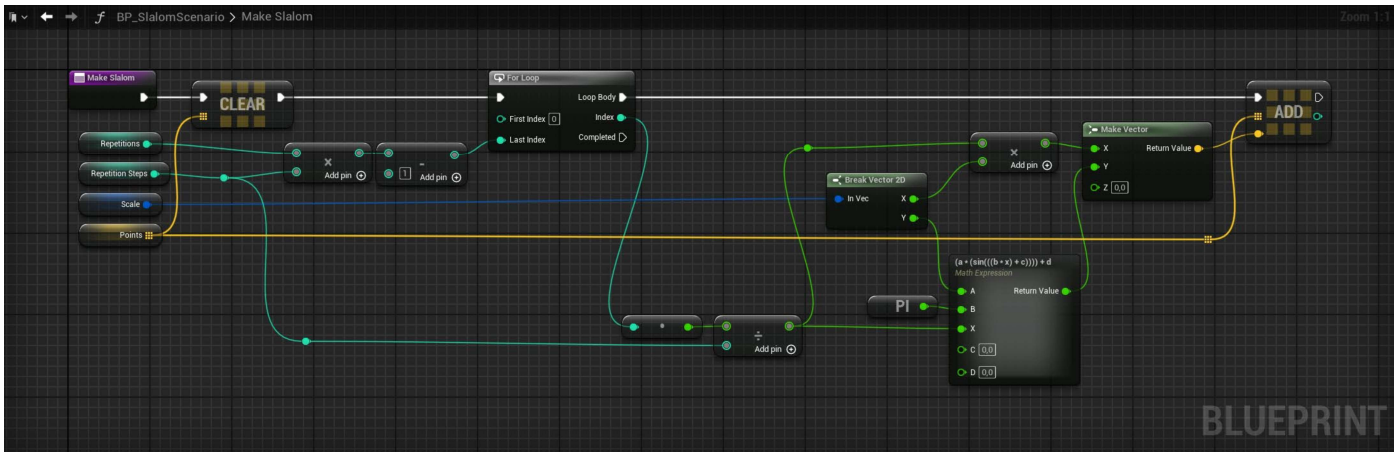
4: BP_DefinedScenario-AddStartEndPoint



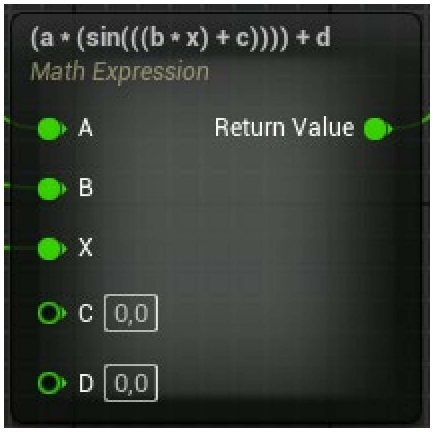
5: BP_DefinedScenario-PathFromPoints



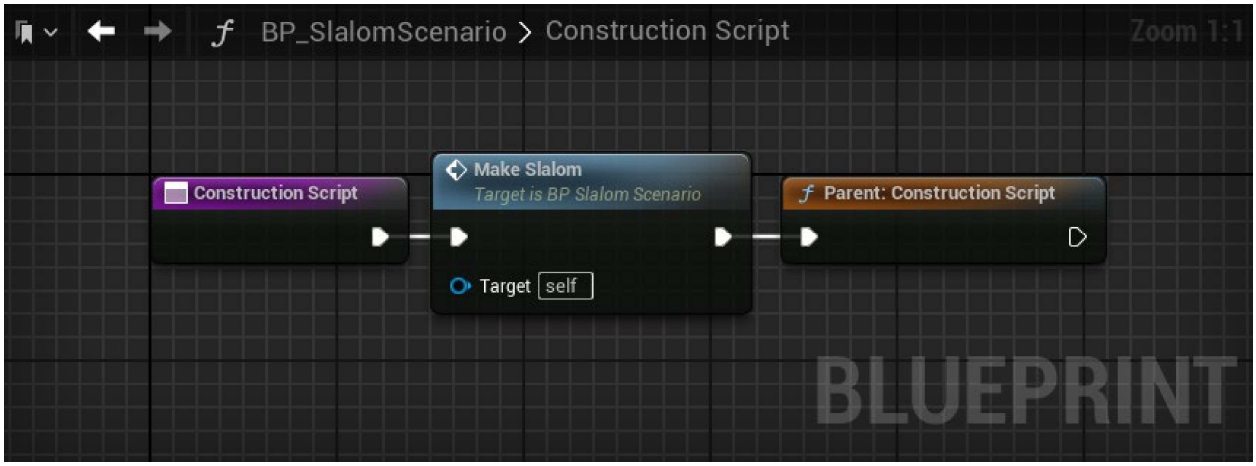
6: BP_DefinedScenario-UserConstructionScript



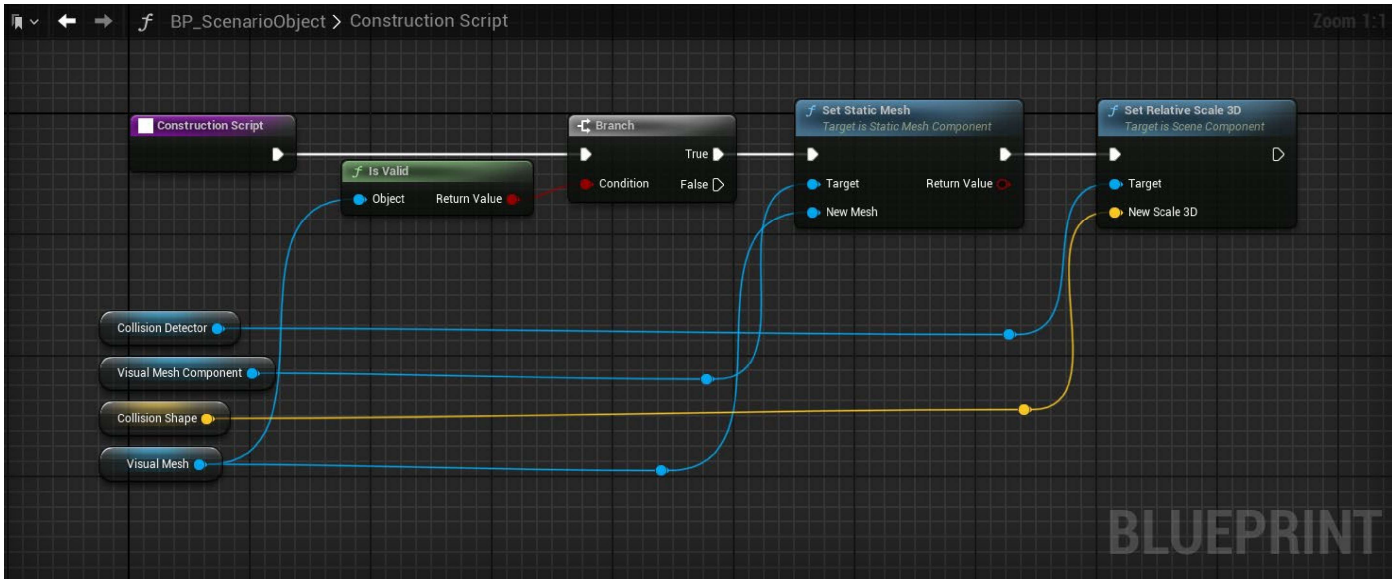
7: BP_SlalomScenario-MakeSlalom



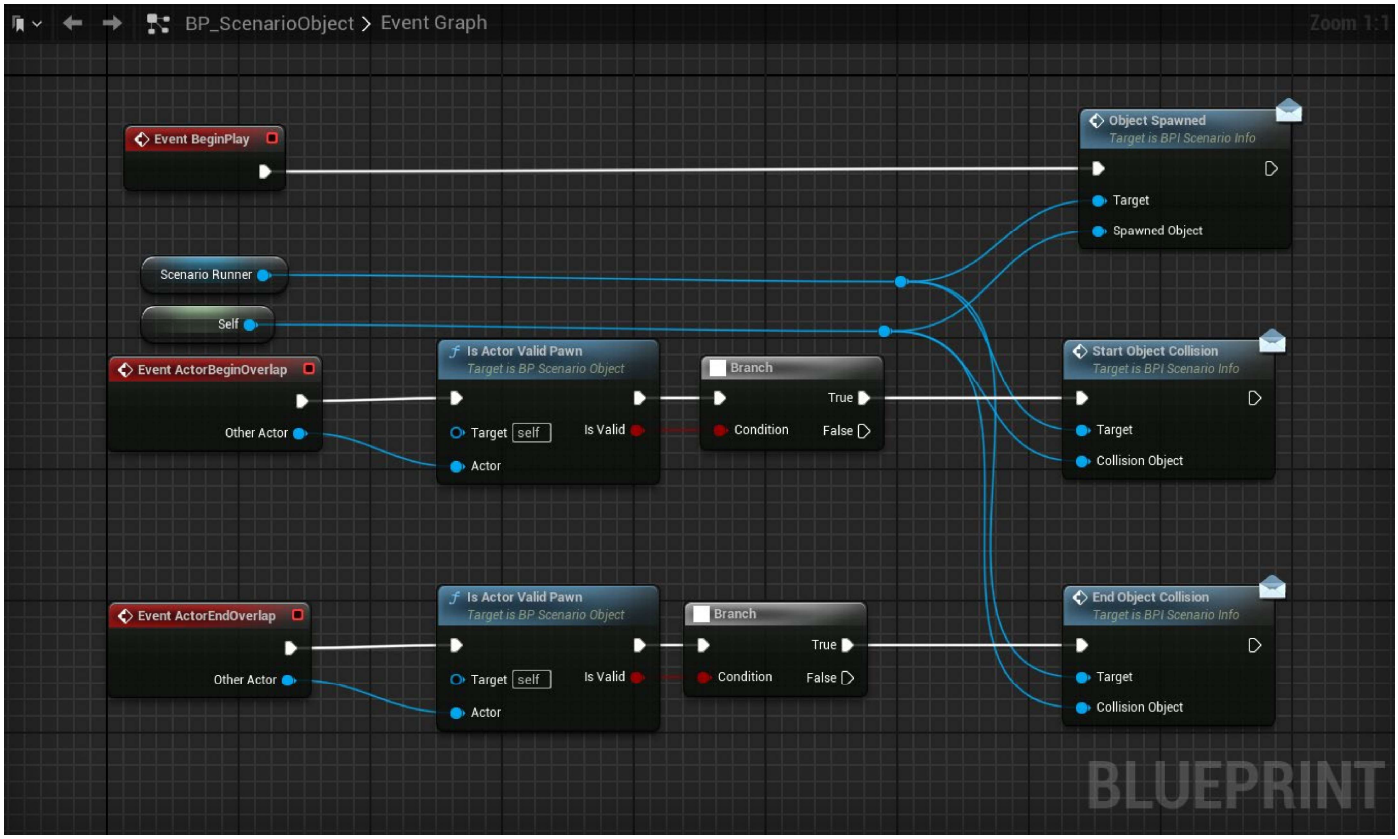
8: BP_SlalomScenario-MakeSlalom-Math



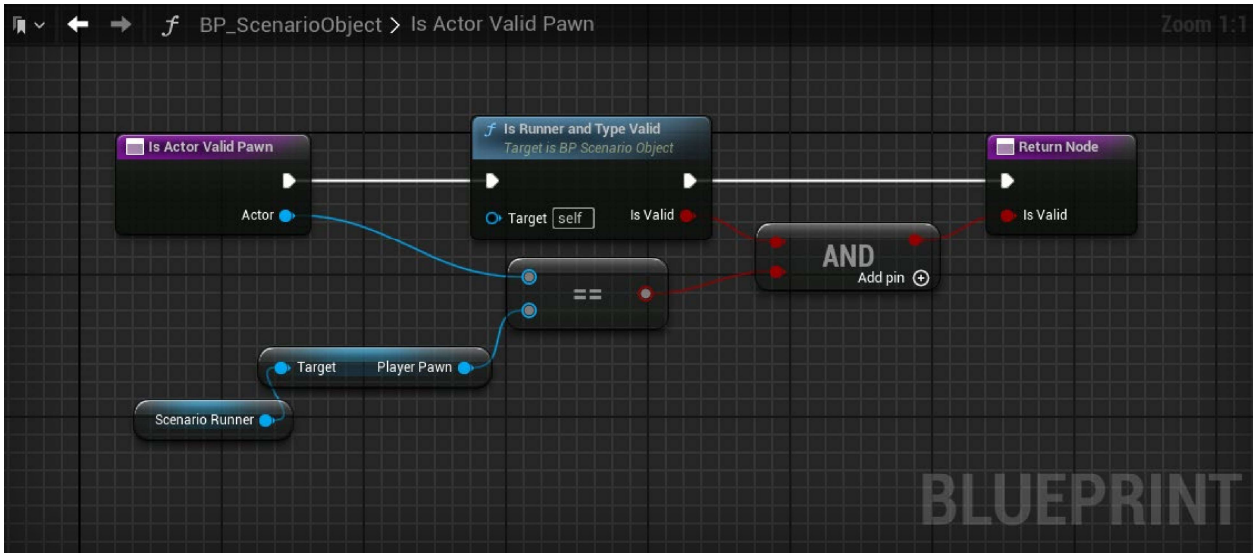
9: BP_SlalomScenario-UserConstructionScript



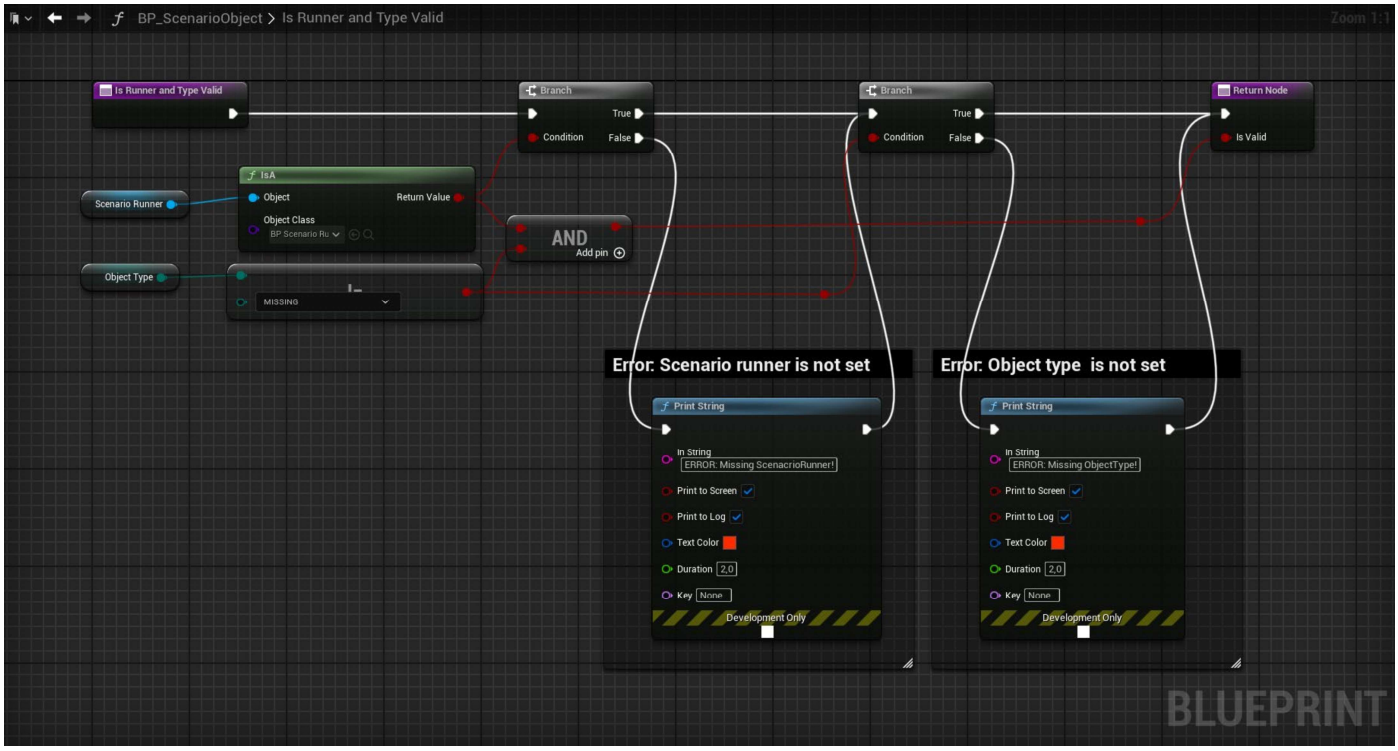
10: BP_ScenarioObject-UserConstructionScript



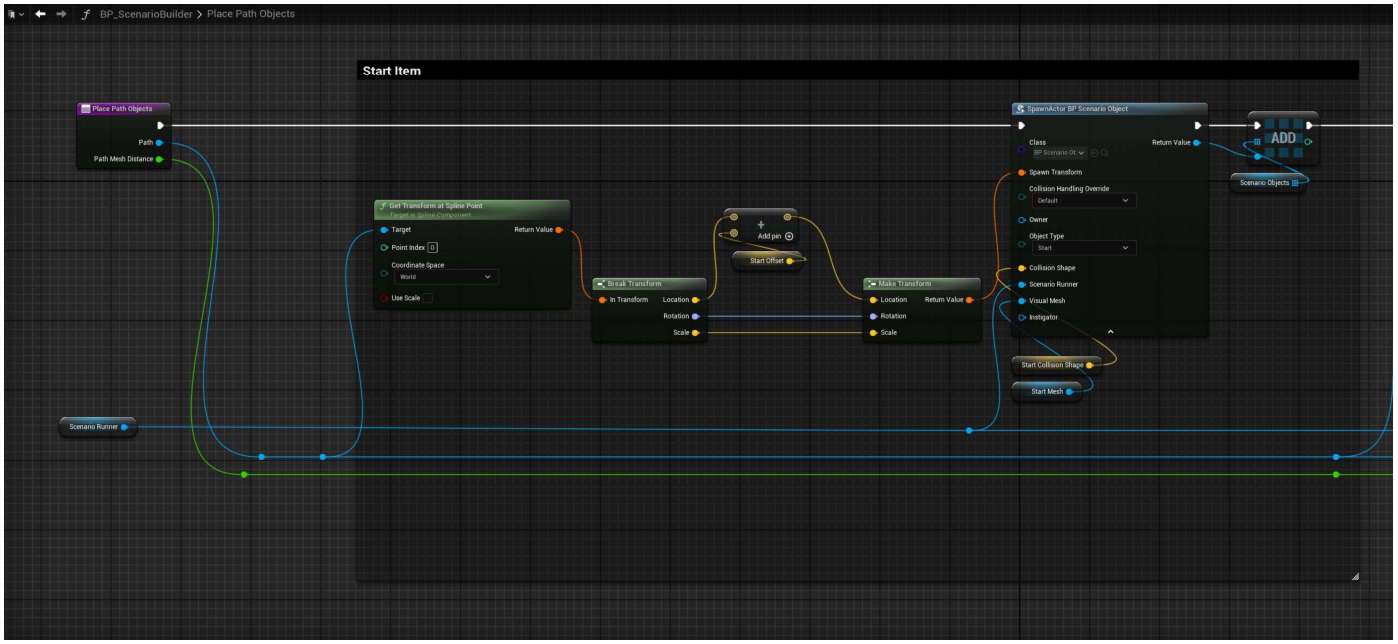
11: BP_ScenarioObject-EventGraph



12: BP_ScenarioObject-IsActorValidPawn

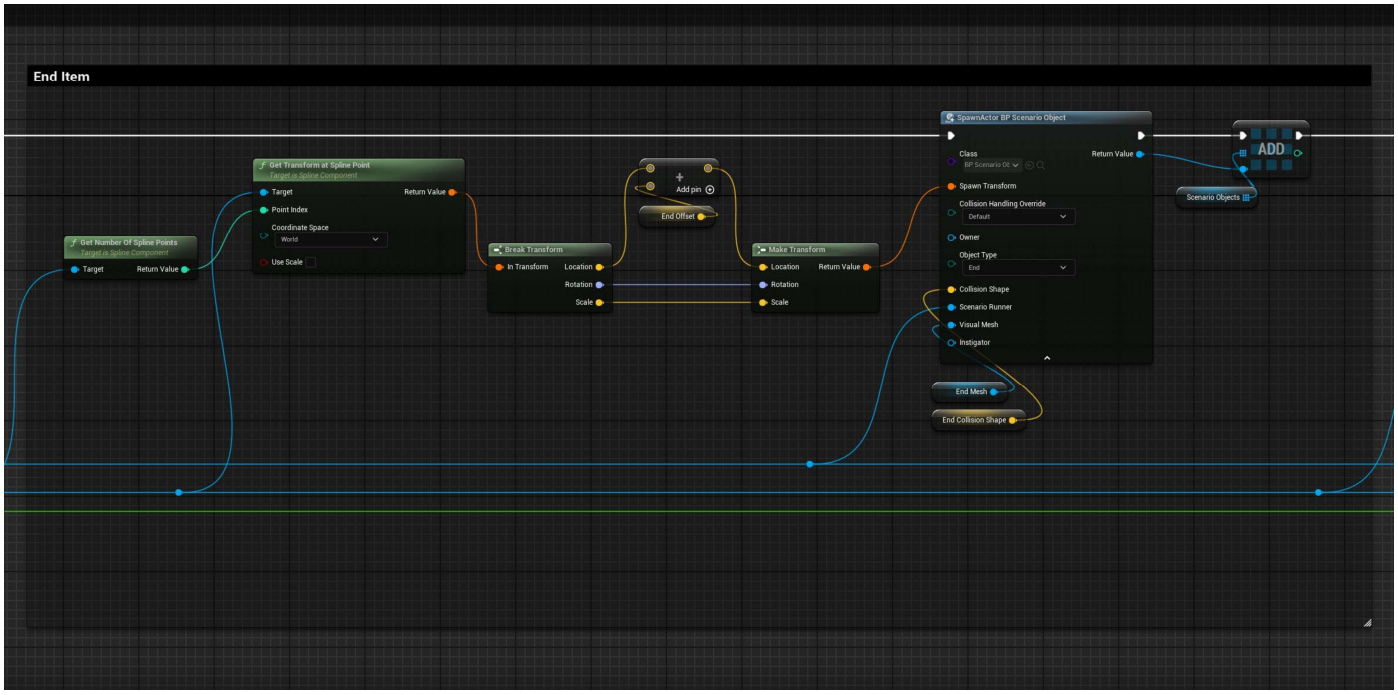


13: BP_ScenarioObject-IsRunnerAndTypeValid

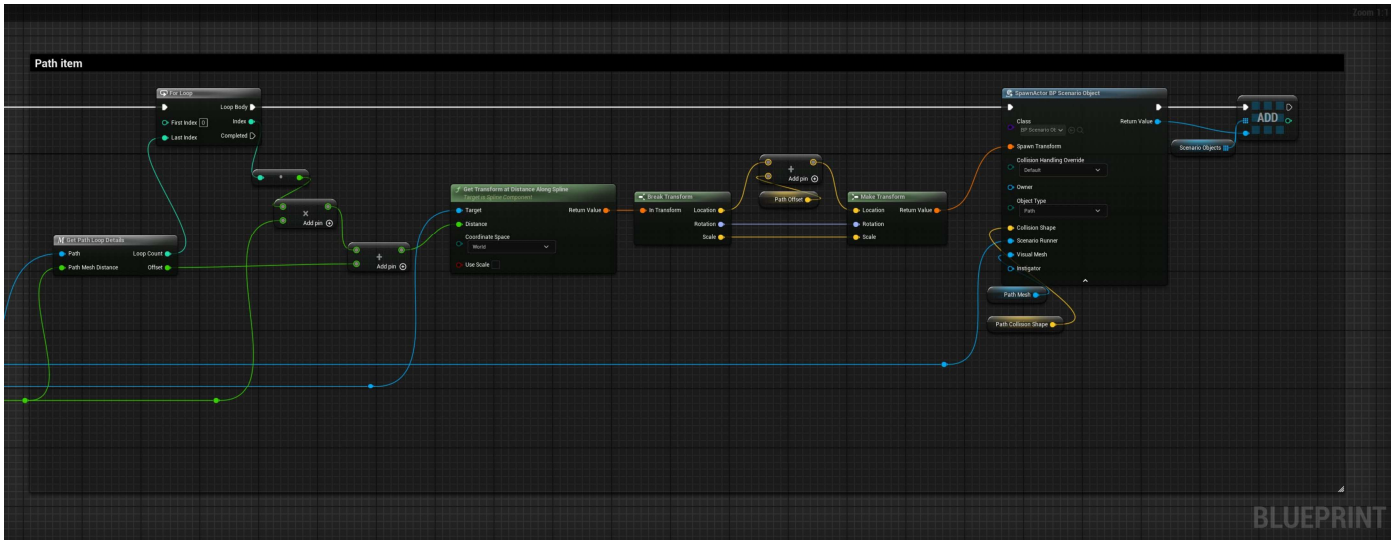


14: BP_ScenarioBuilder-PlacePathObjects-1

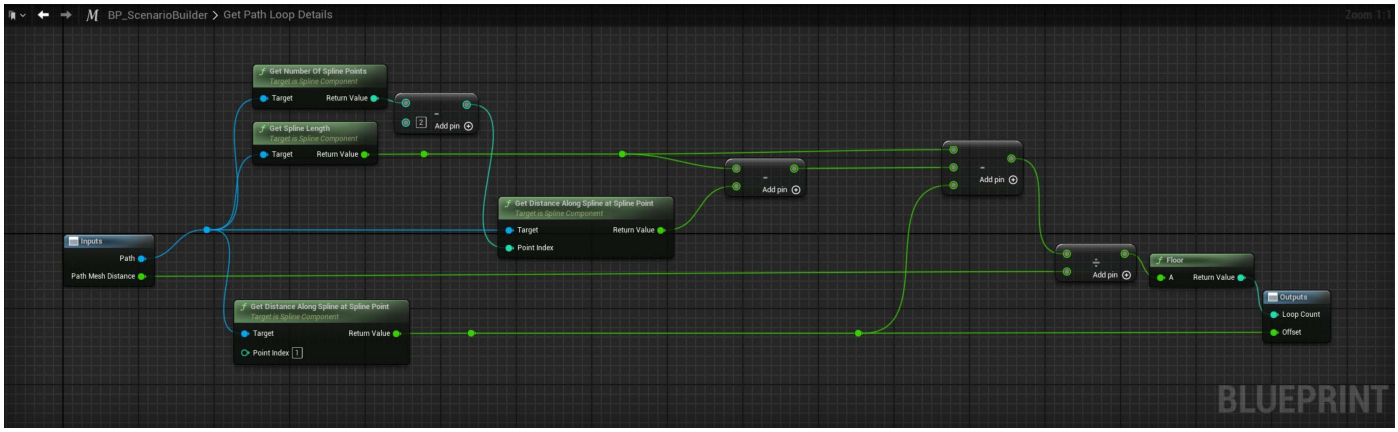
X



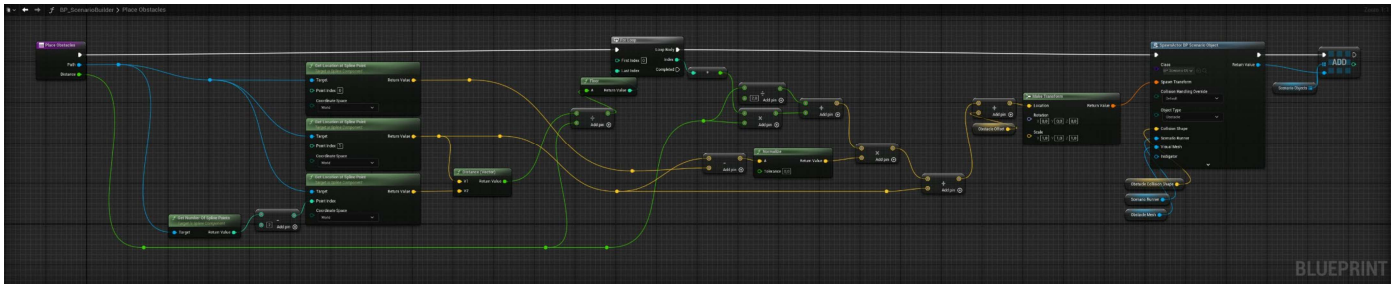
15: BP_ScenarioBuilder-PlacePathObjects-2



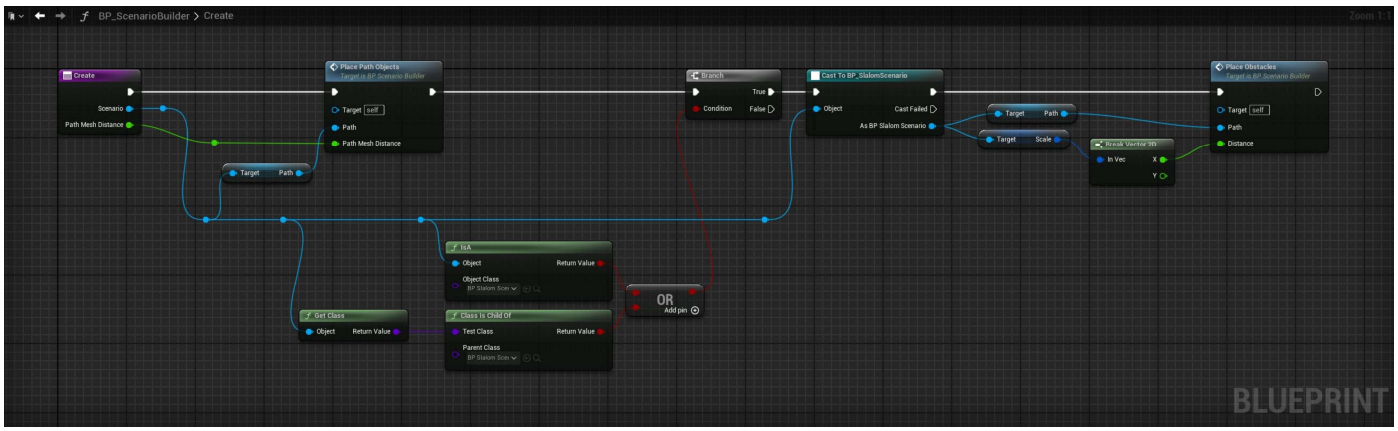
16: BP_ScenarioBuilder-PlacePathObjects-3



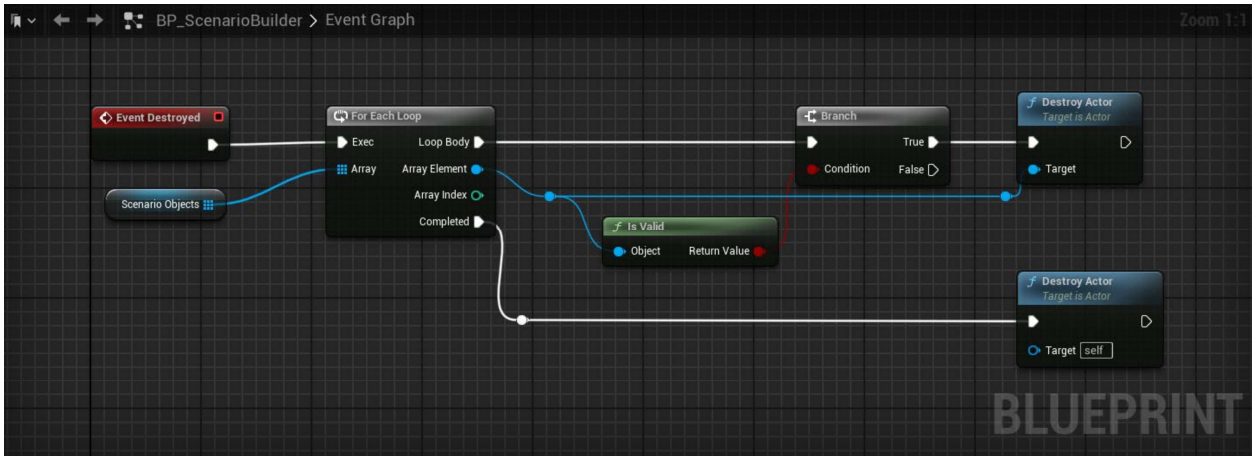
17: BP_ScenarioBuilder-GetPathLoopDetails



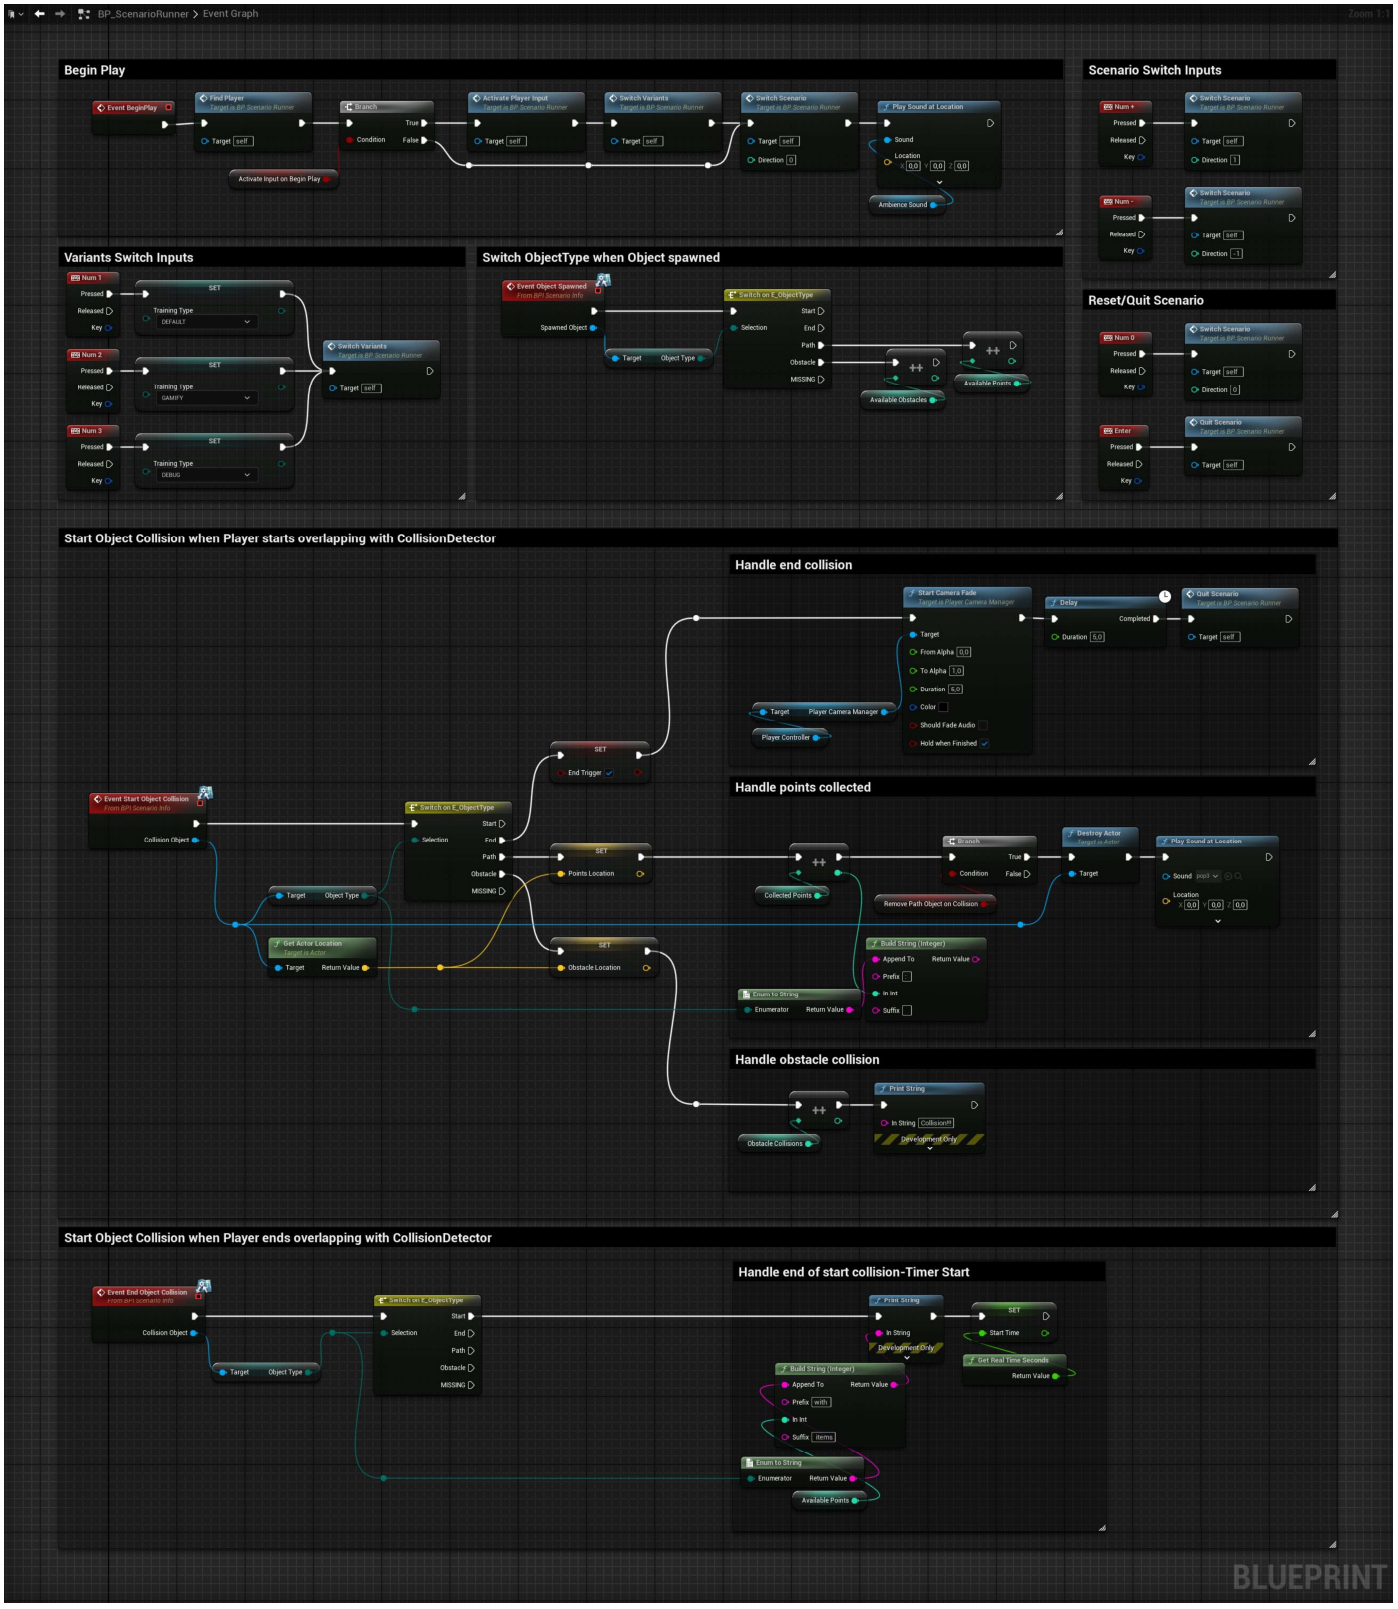
18: BP_ScenarioBuilder-PlaceObstacles



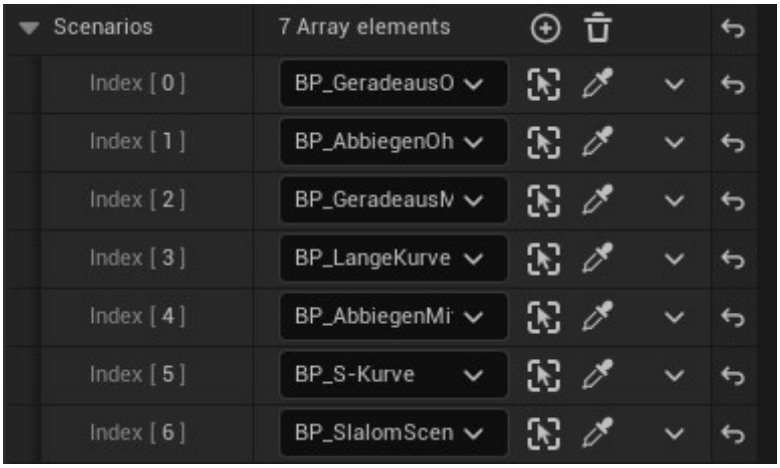
19: BP_ScenarioBuilder-Create



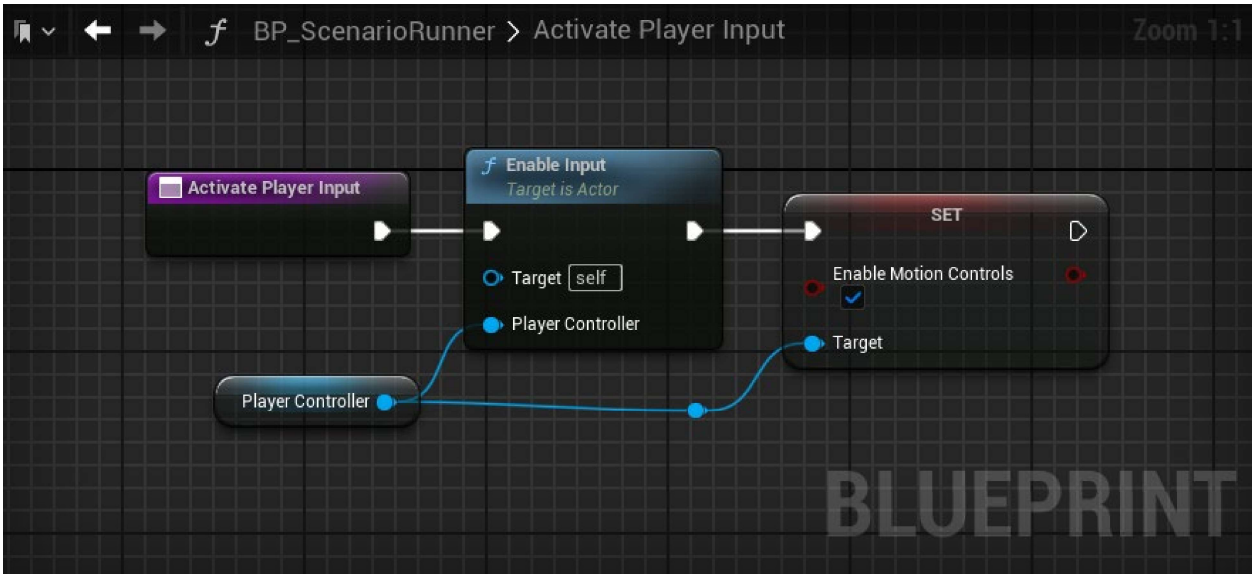
20: BP_ScenarioBuilder-EventGraph



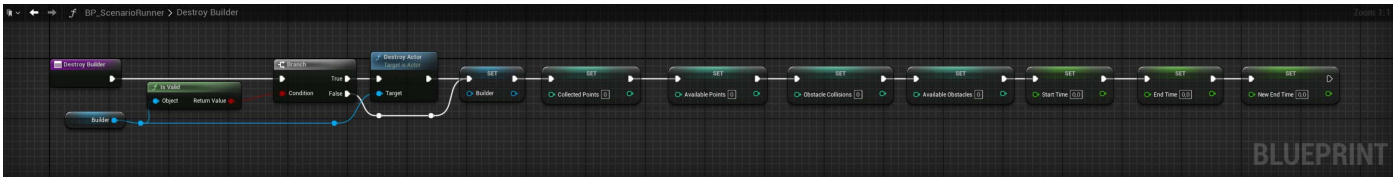
21: BP_ScenarioRunner-EventGraph



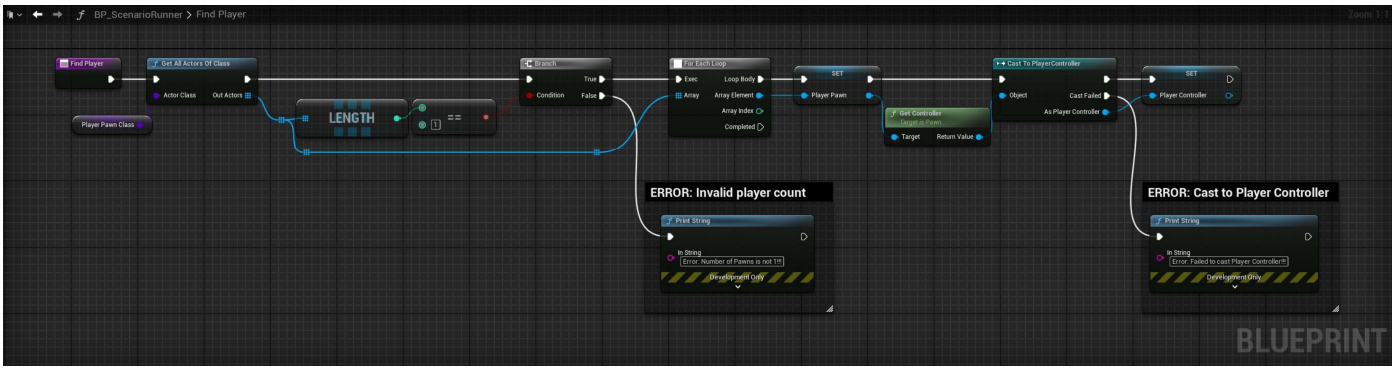
22: Runner-DetailsPenel-Senarios



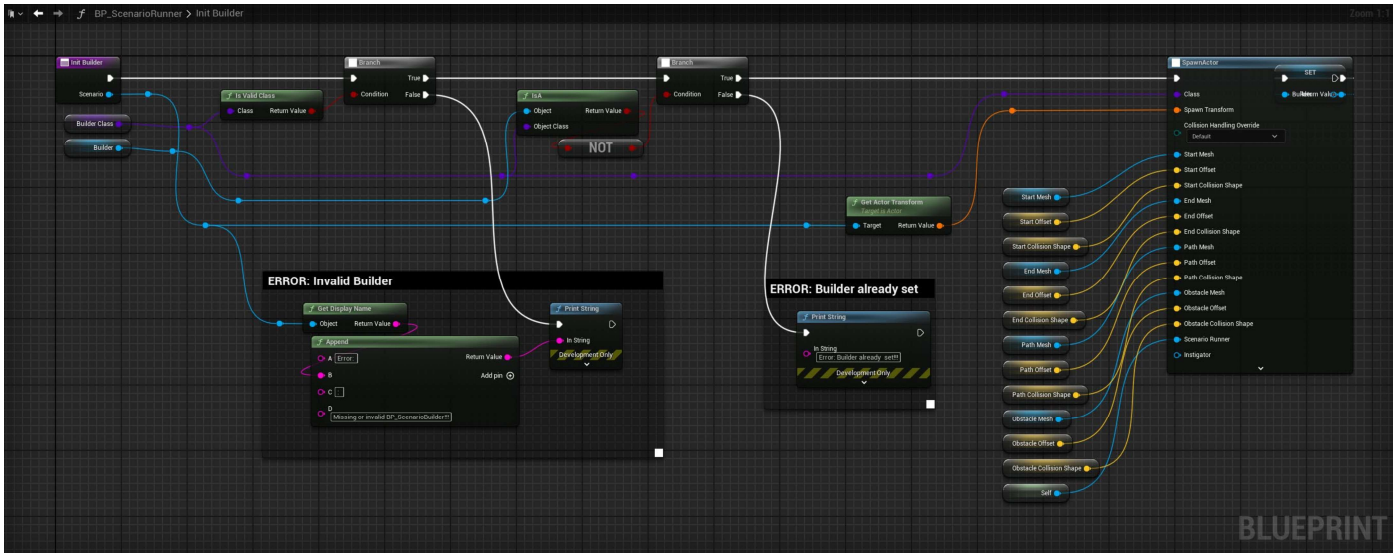
23: BP_ScenarioRunner-ActivatePlayerInput



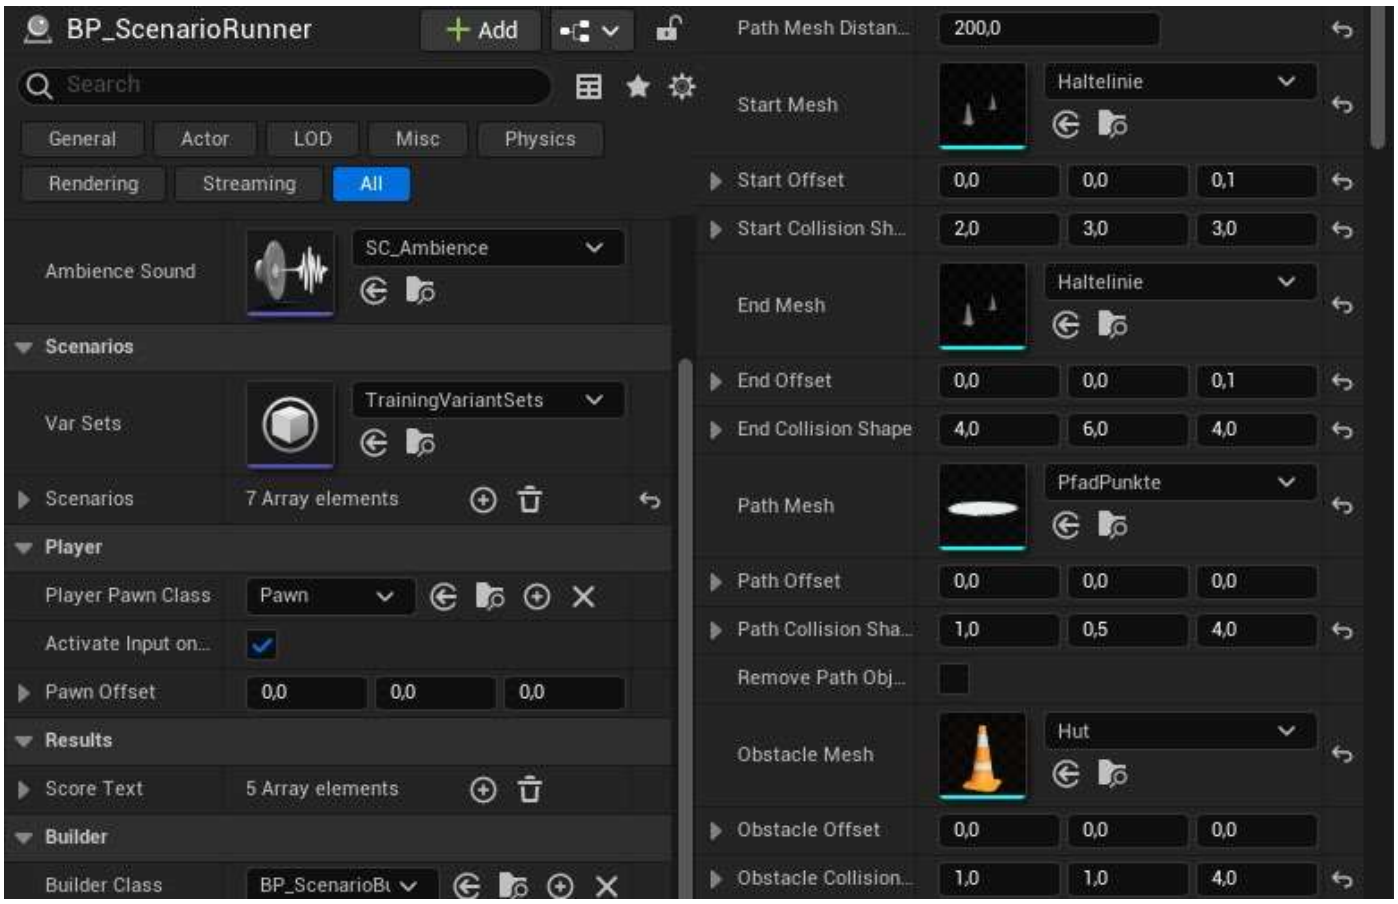
24: BP_ScenarioRunner-DestroyBuilder



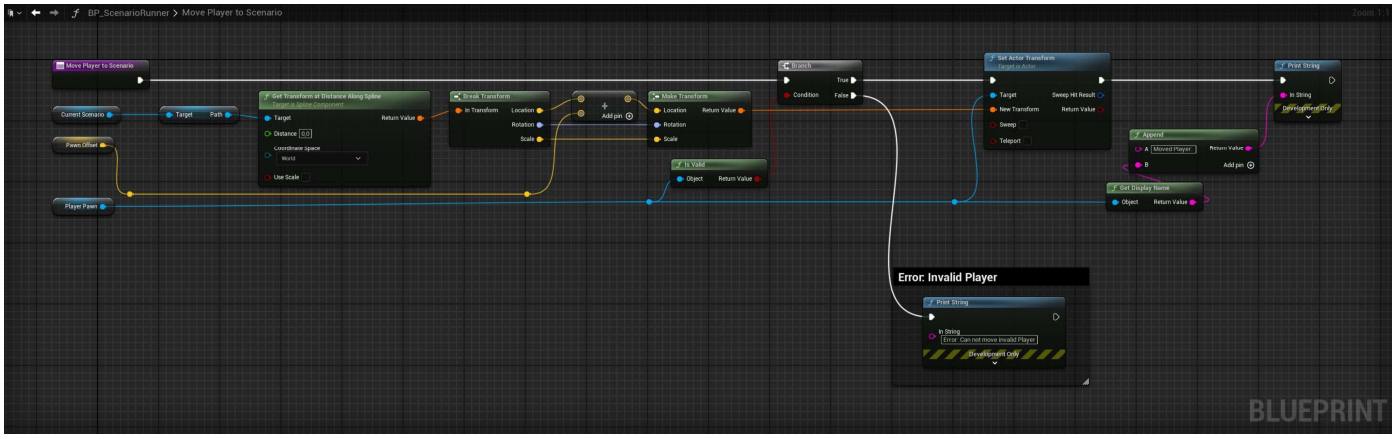
25: BP_ScenarioRunner-FindPlayer



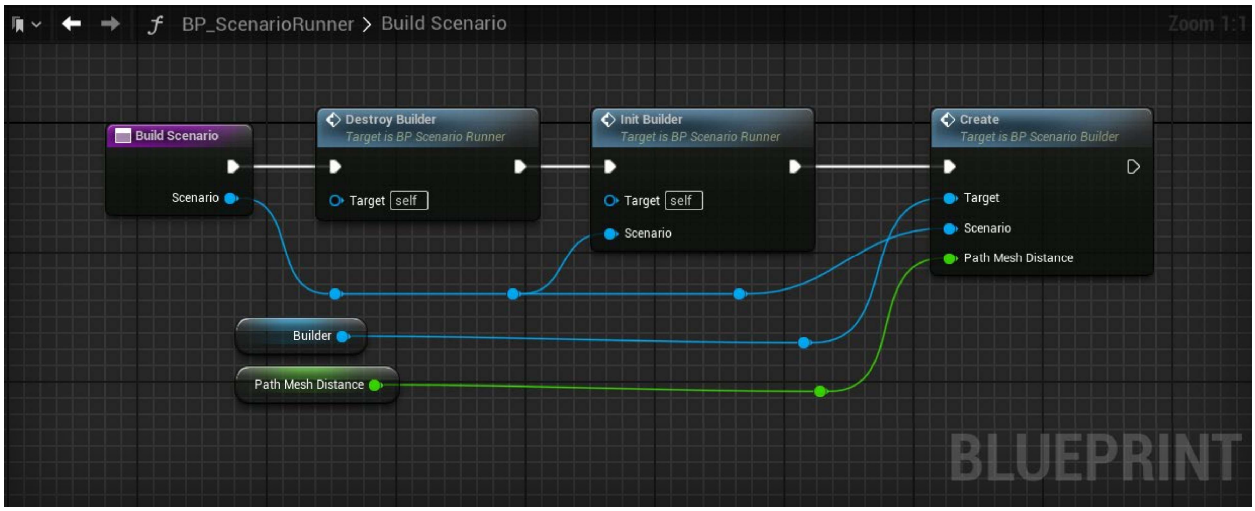
26: BP_ScenarioRunner-InitBuilder



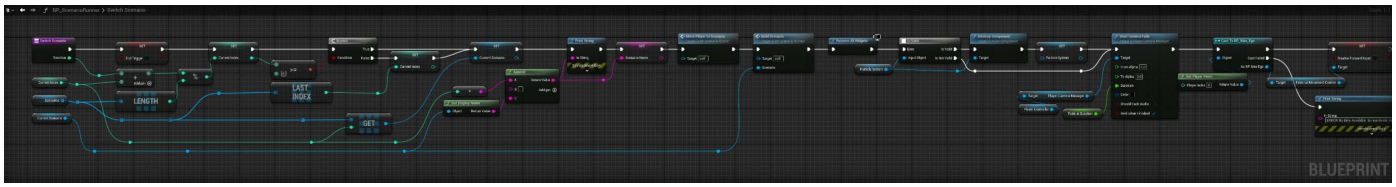
27: Runner-DetailsPenel



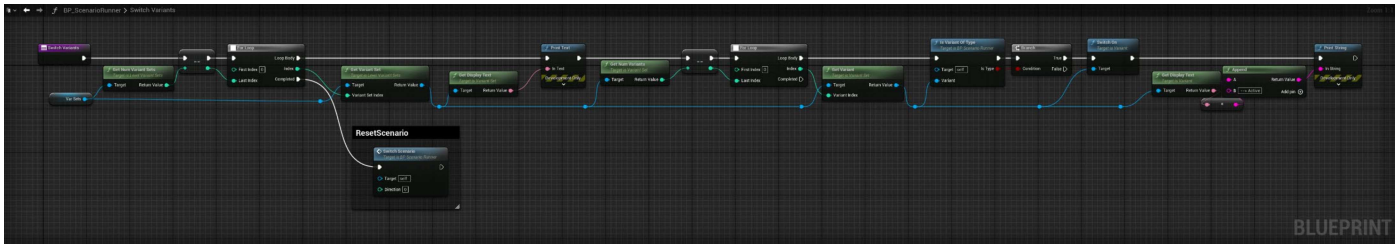
28: BP_ScenarioRunner-MovePlayerToScenario



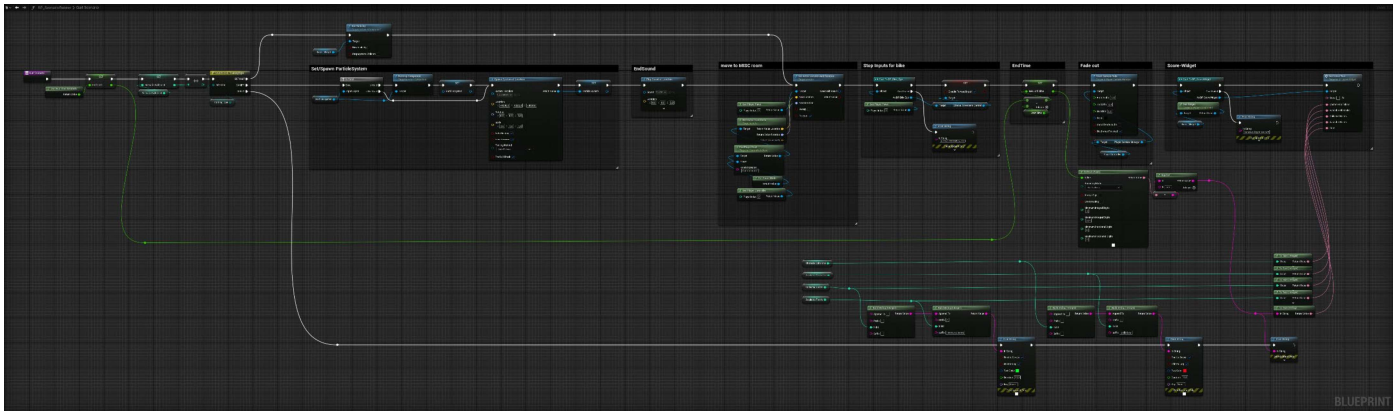
29: BP_ScenarioRunner-BuildScenario



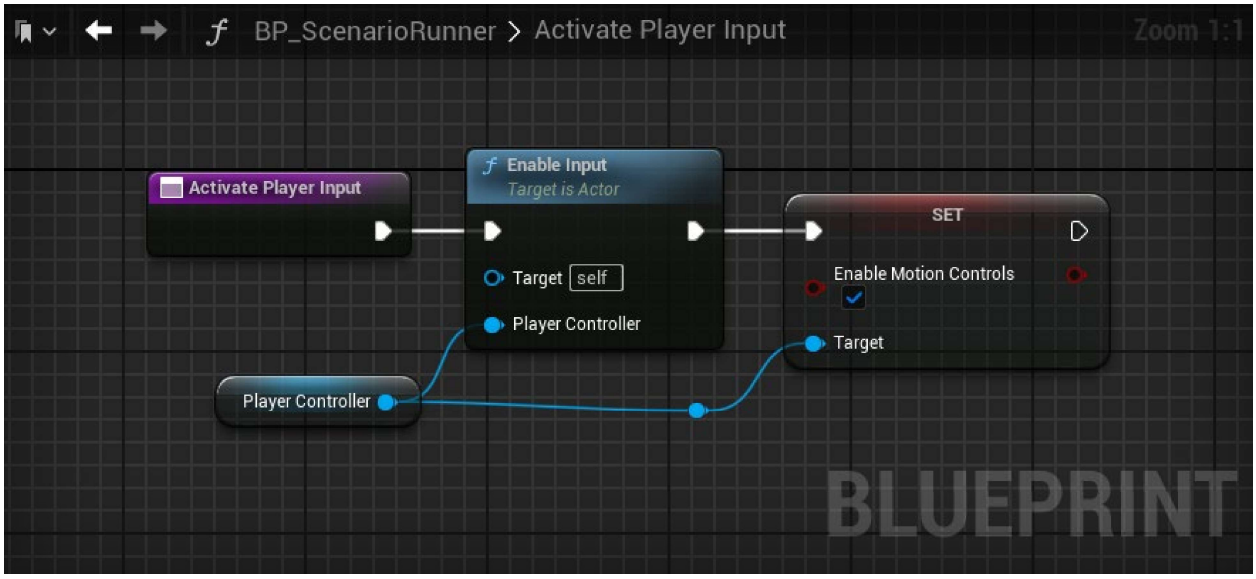
30: BP_ScenarioRunner-SwitchScenario



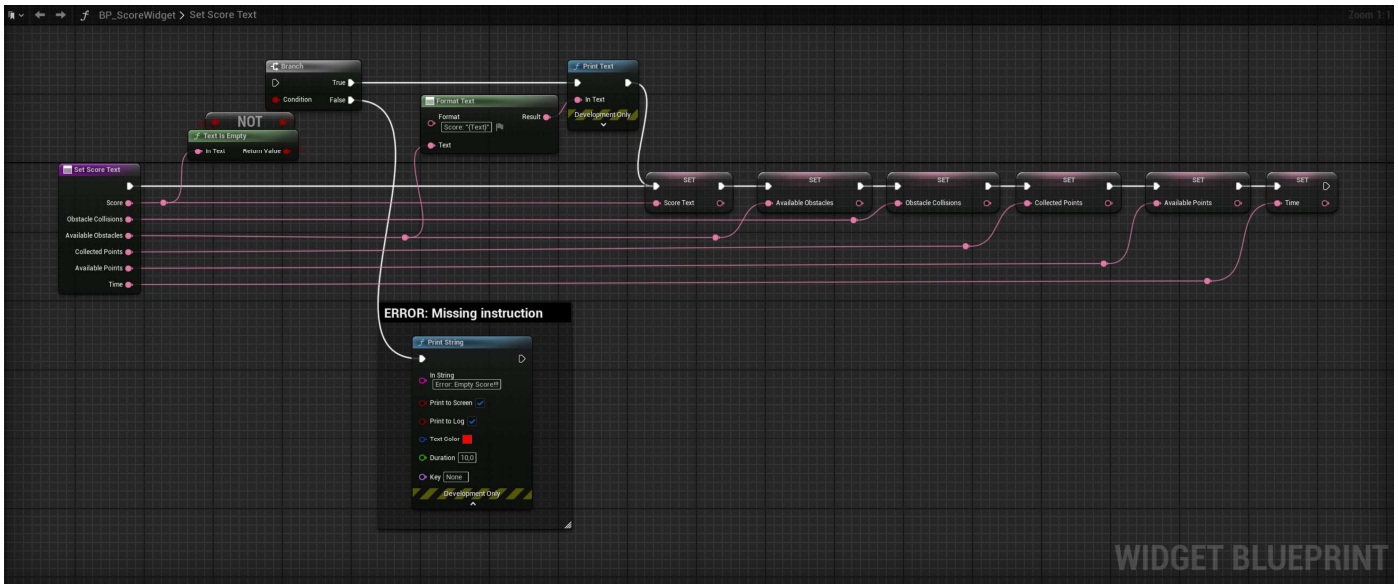
31: BP_ScenarioRunner-Switch Variants



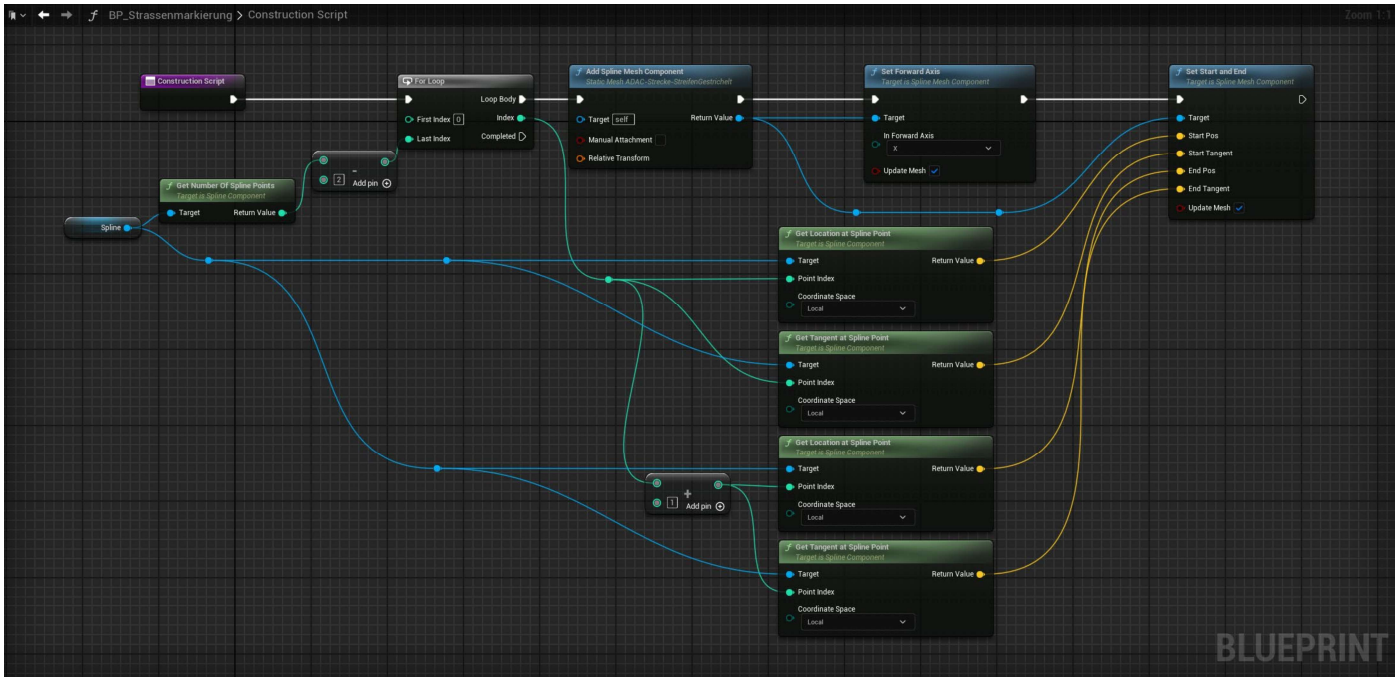
32: BP_ScenarioRunner-QuitScenario



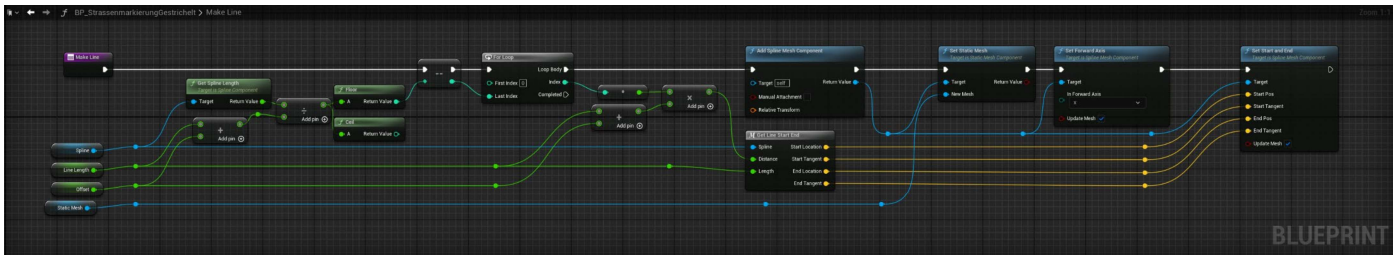
33: BP_ScenarioRunner-ActivatePlayerInput



34: BP_ScoreWidget-SetScoreText



35: BP_Strassenmarkierung-UserConstructionScript



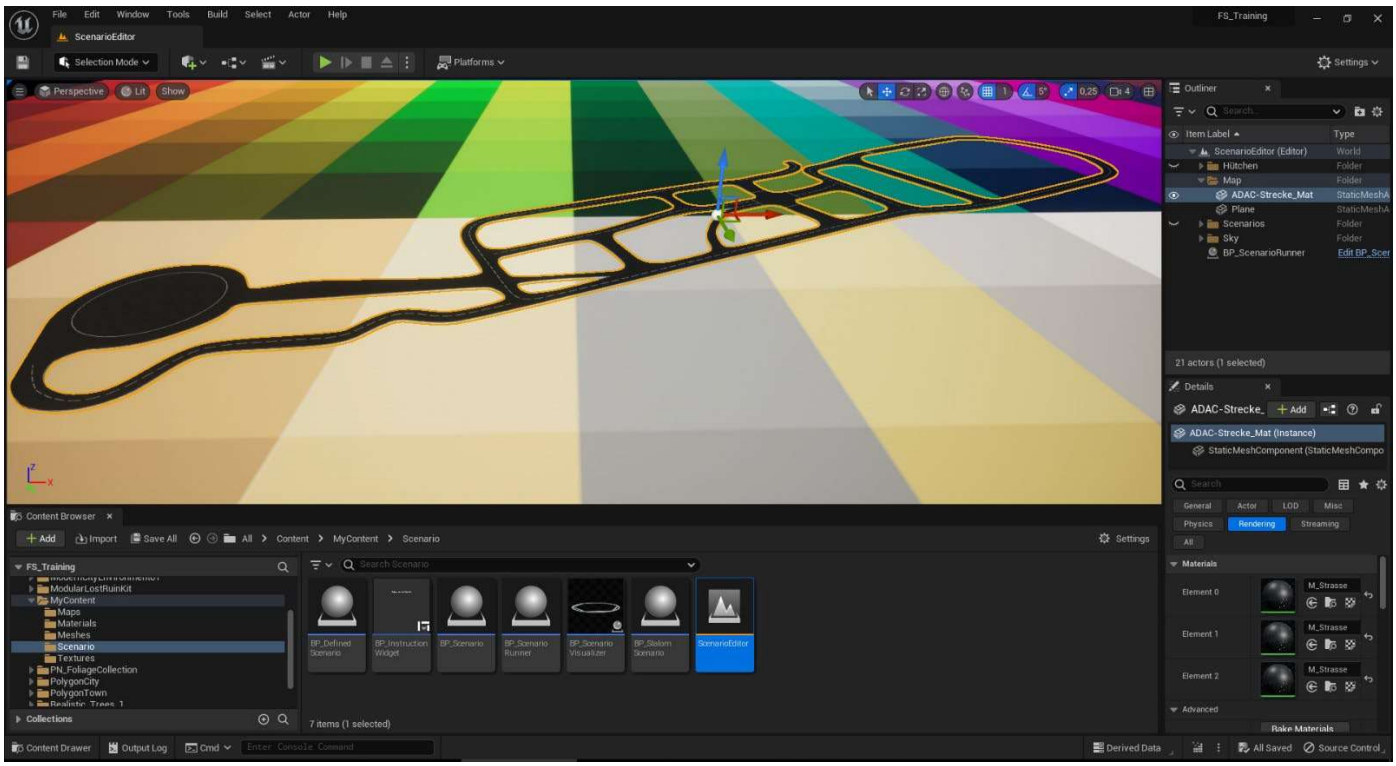
36: BP_StrassenmarkierungGestrichelt-MakeLine

C: Anleitung

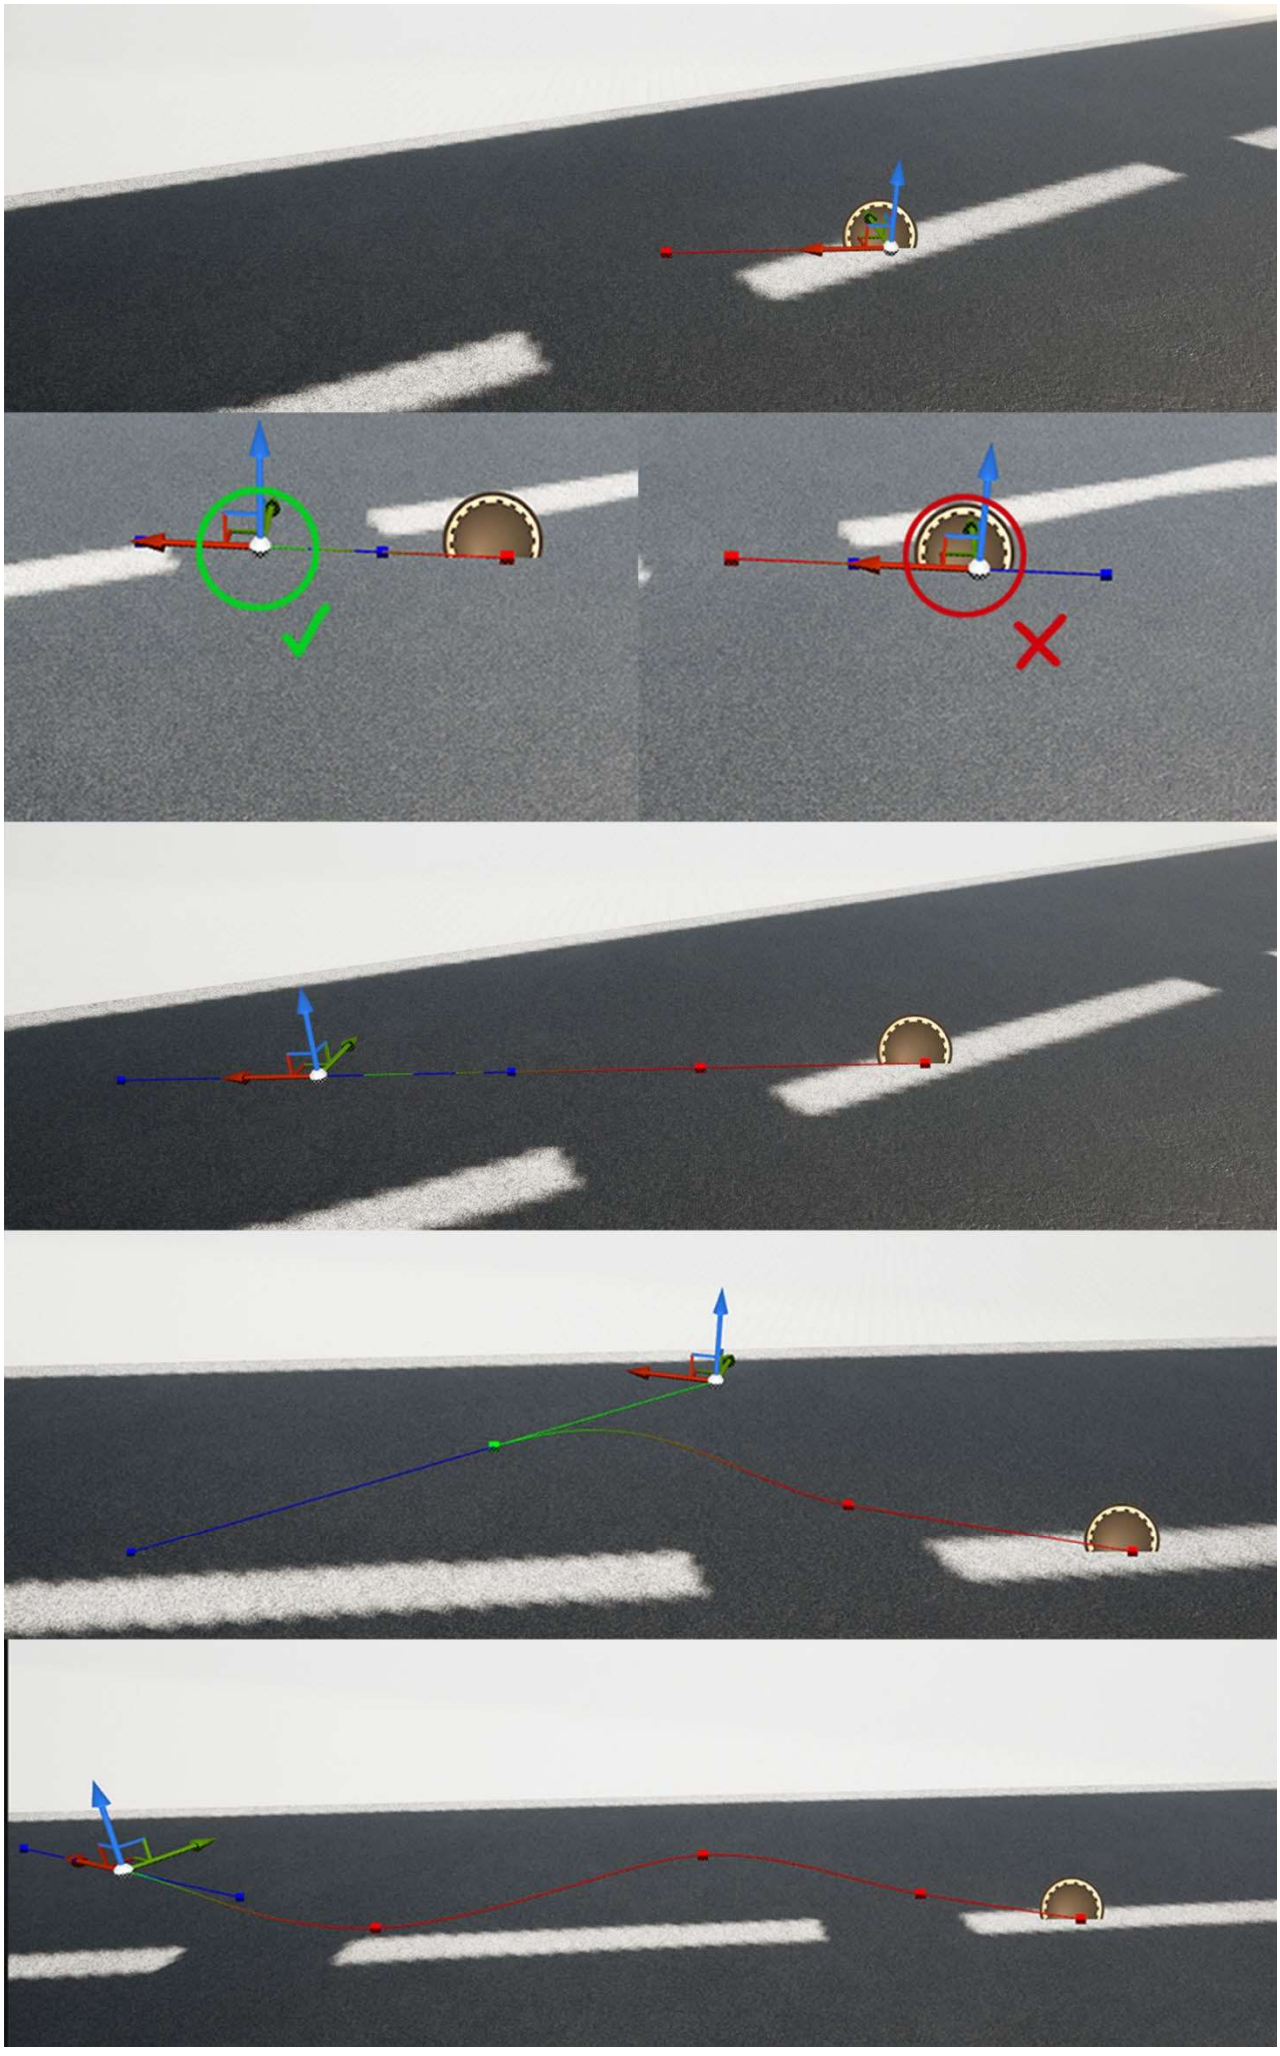
Erstellen und Anpassen der Szenarios für das Fahrradsimulator Training

Anlegen eines Szenarios im Editor

- Map Scenario Editor öffnen



- Es gibt 3 verschiedene Varianten ein Scenario zu erstellen (Scenario, DefinedScenario und SlalomScenario)
- Scenario: Für ein selbstdefiniertes und per Hand anpassbares Scenario
  1. ein BP_Scenario in die Scene ziehen und umbenennen
  2. Spline mit zwei Punkten wird gesetzt zweiten Punkt auswählen mit alt und dem Translate Werkzeug einen neuen Punkt rausziehen. WICHTIG: Es muss der zweite Punkt sein, ansonsten wird die Root verändert.
  3. mit dem Handel die Kurve wie gewünscht anpassen. Für weiter Punkte wie beschrieben fortfahren.



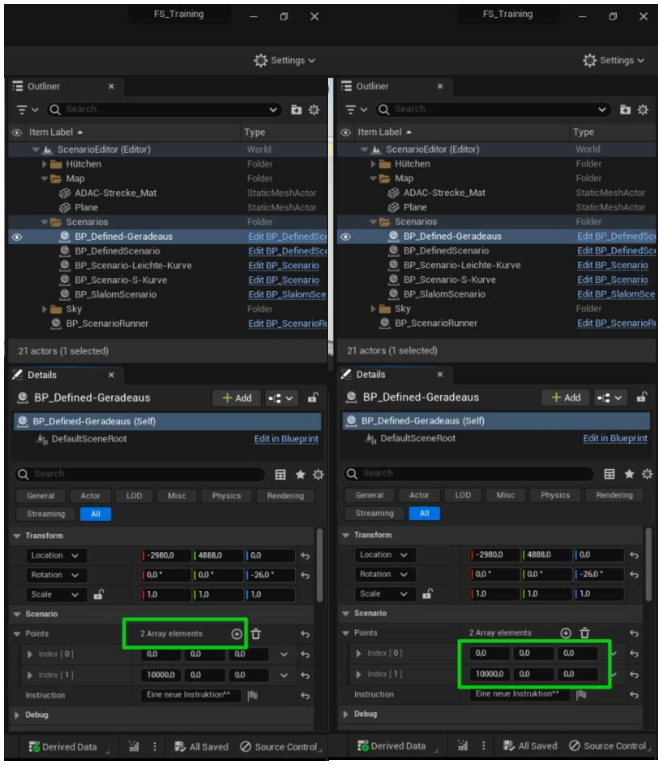
XX

- **DefinedScenario:**

  1. BP_DefinedScenario in Scene ziehen

  2. in den Einstellungen unter Points mit + neue Points hinzufügen

  3. Über die Eingabe von Werten die Punkte positionieren



- **SlalomScenario**

  1. BP_SlalomScenario in die Scene ziehen

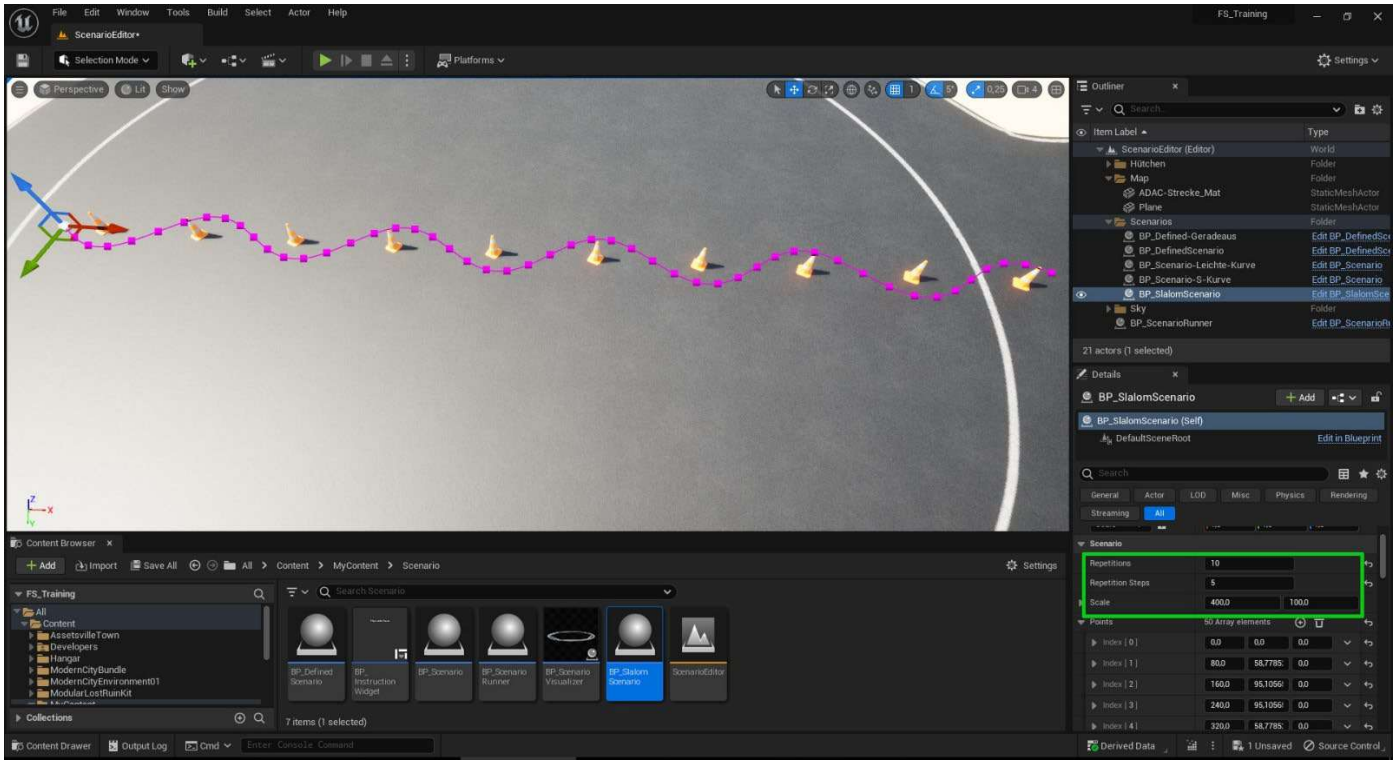
  2. In den Einstellungen können verschiedene Parameter eingestellt werden:

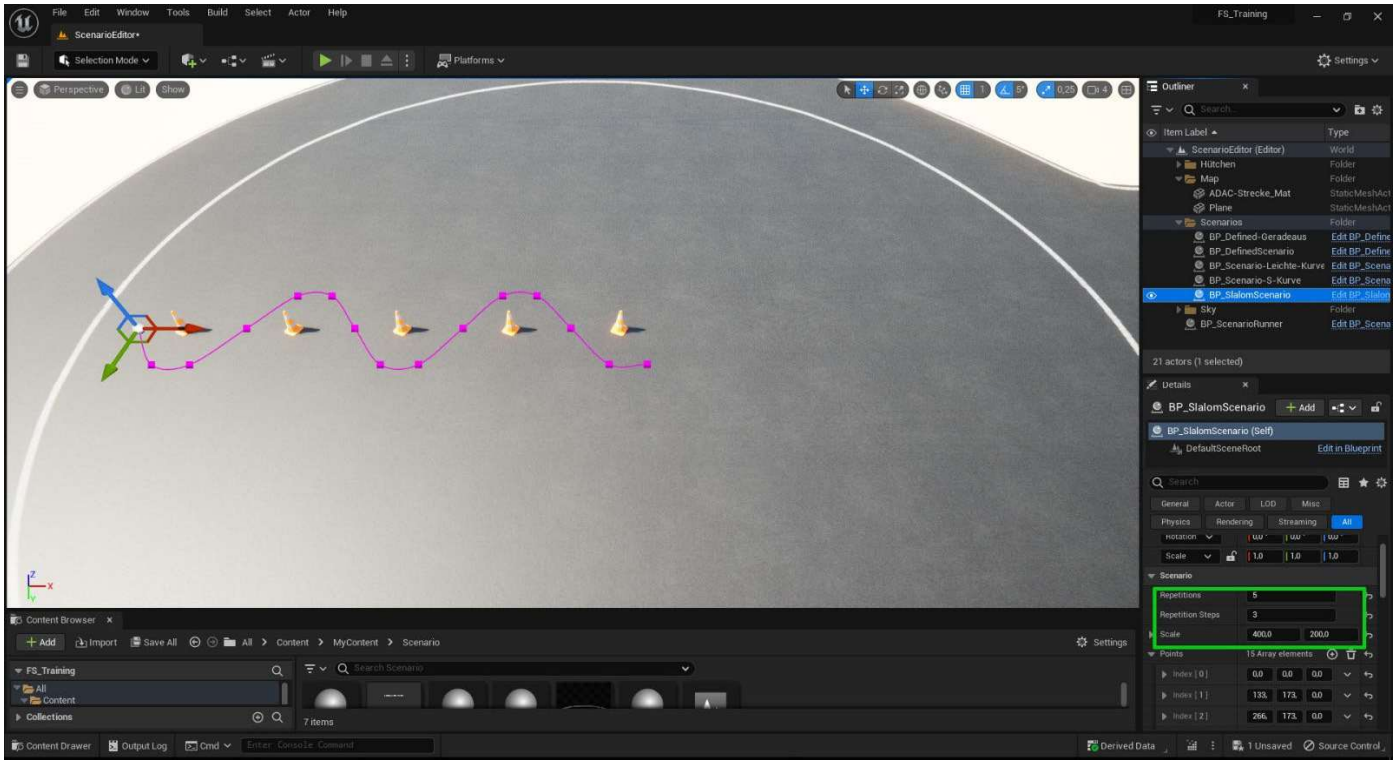
     Repetitiones: Eine Wiederholung bezieht sich auf die Anzahl an

     Kuvenausschlägen (1. Beispiel:10, 2. Beispiel: 5)

     RepititionSteps: Bestimmt wie viele Punkte für einen Abschnitt gesetzt werden (Kurve wird feiner durch mehr punkte -> für Mesh interessant)

     Scale: x-Wert bestimmt den Abstand zwischen den Kurven und der y-Wert bestimmt die Breite des Ausschlags

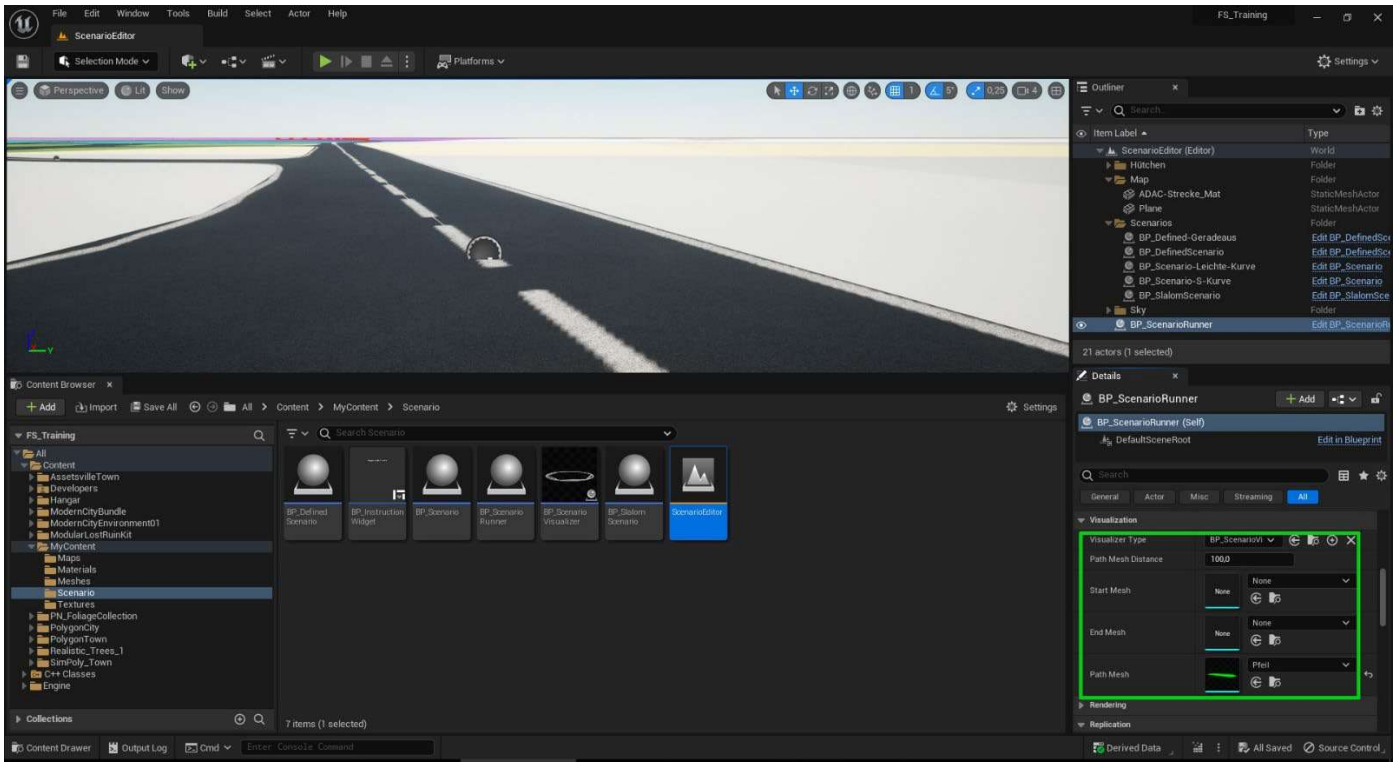




Anpassen der Szenarios

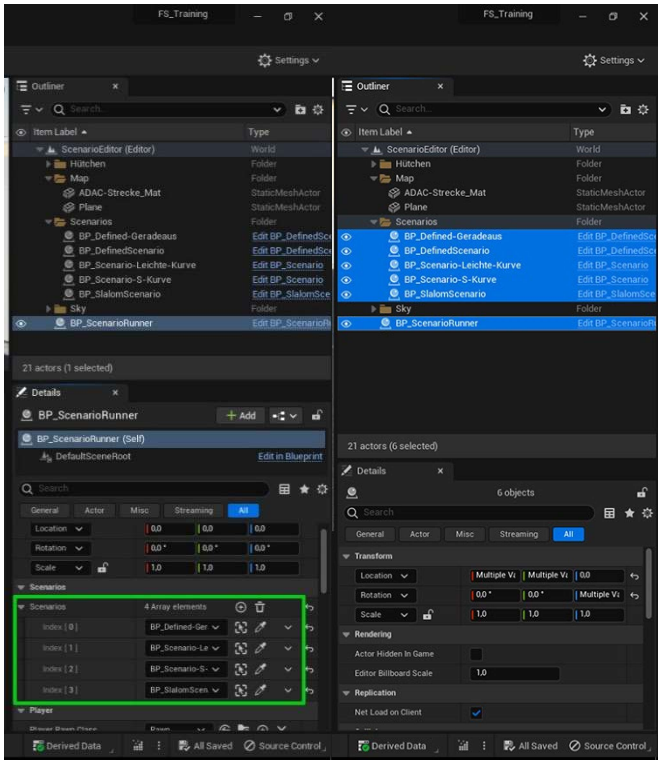
Meshes: ScenarioRunner auswählen und in den Einstellungen StartMesh, EndMesh und PathMesh für alle gesetzten Scenarien gleichzeitig anpassen PathMeshDistance: bestimmt den Abstand für die Wiederholung des PathMesh. Alternativ kann der Variant Manager (siehe

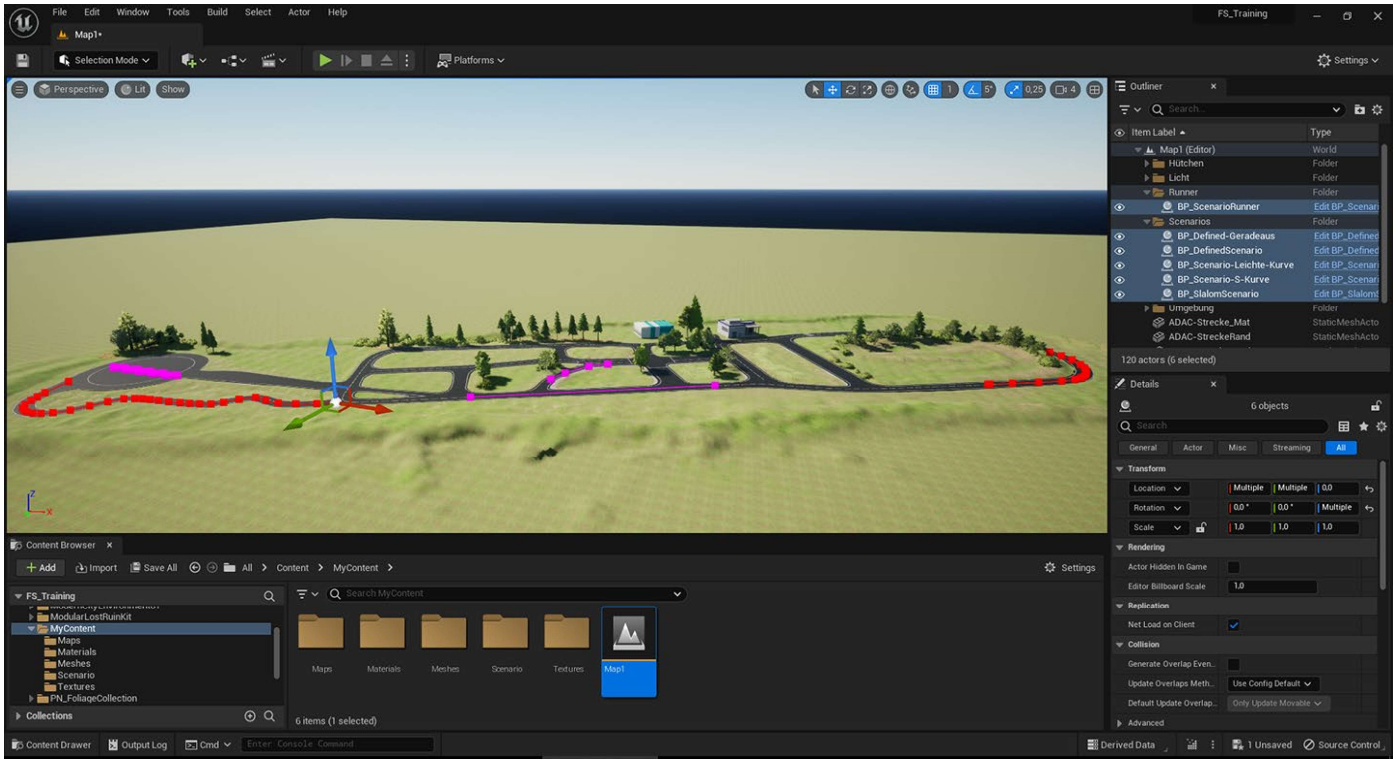
Variant Manager) zum Anpassen der Szenarios nach Modus benutzt werden - Dazu muss erst die Gewünschte Map angelegt werden



- Hinzufügen eines Szenarios und festlegen der Reihenfolge im ScenarioRunner
  1. Runner auswählen
  2. In den Einstellungen mit + ein Scenario hinzufügen
  3. Gewünschtes Scenario auswählen
  4. Ebenso für alle Scenarios die zum Training hinzugefügt werden sollen

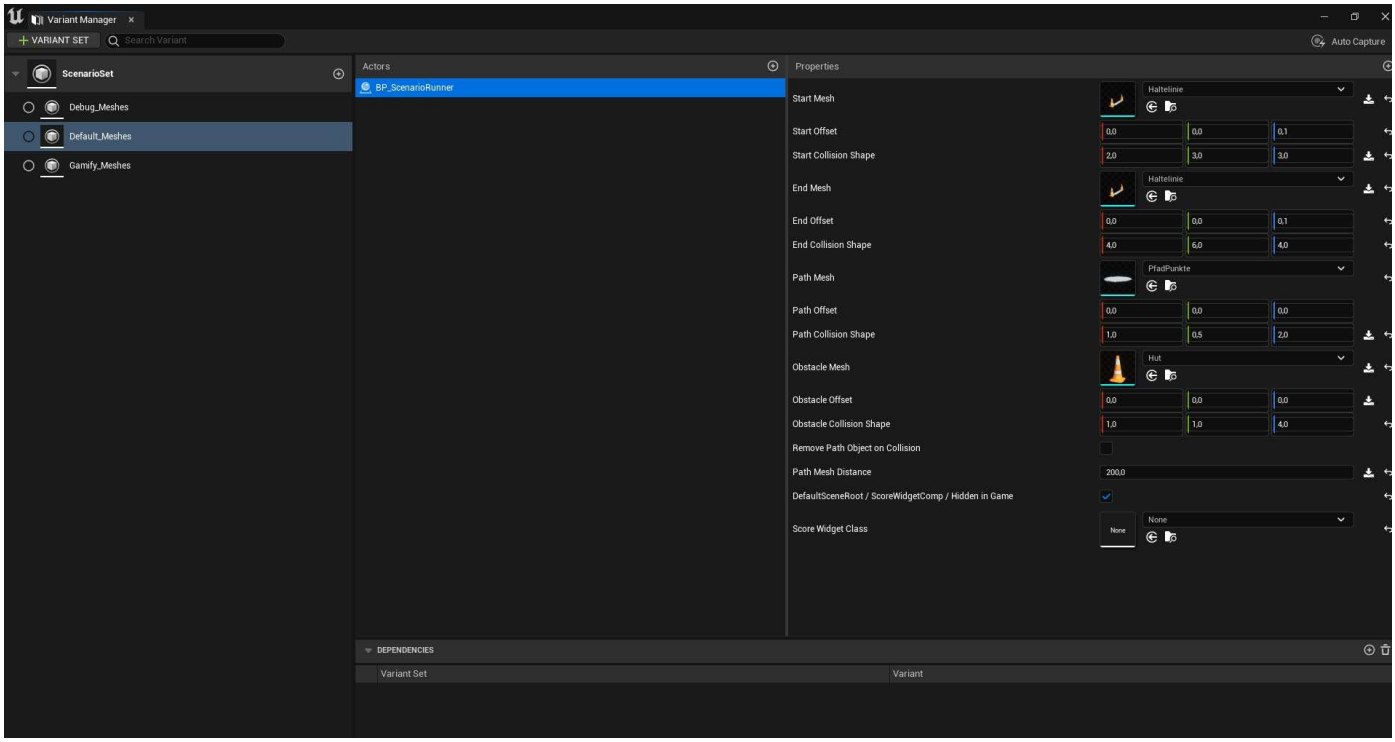
- Übertragung in gewünschte Map
  1. Alle gesetzten Scenarios und ScenarioRunner auswählen und kopieren
  2. Neue Map öffnen
  3. In Scene einfügen

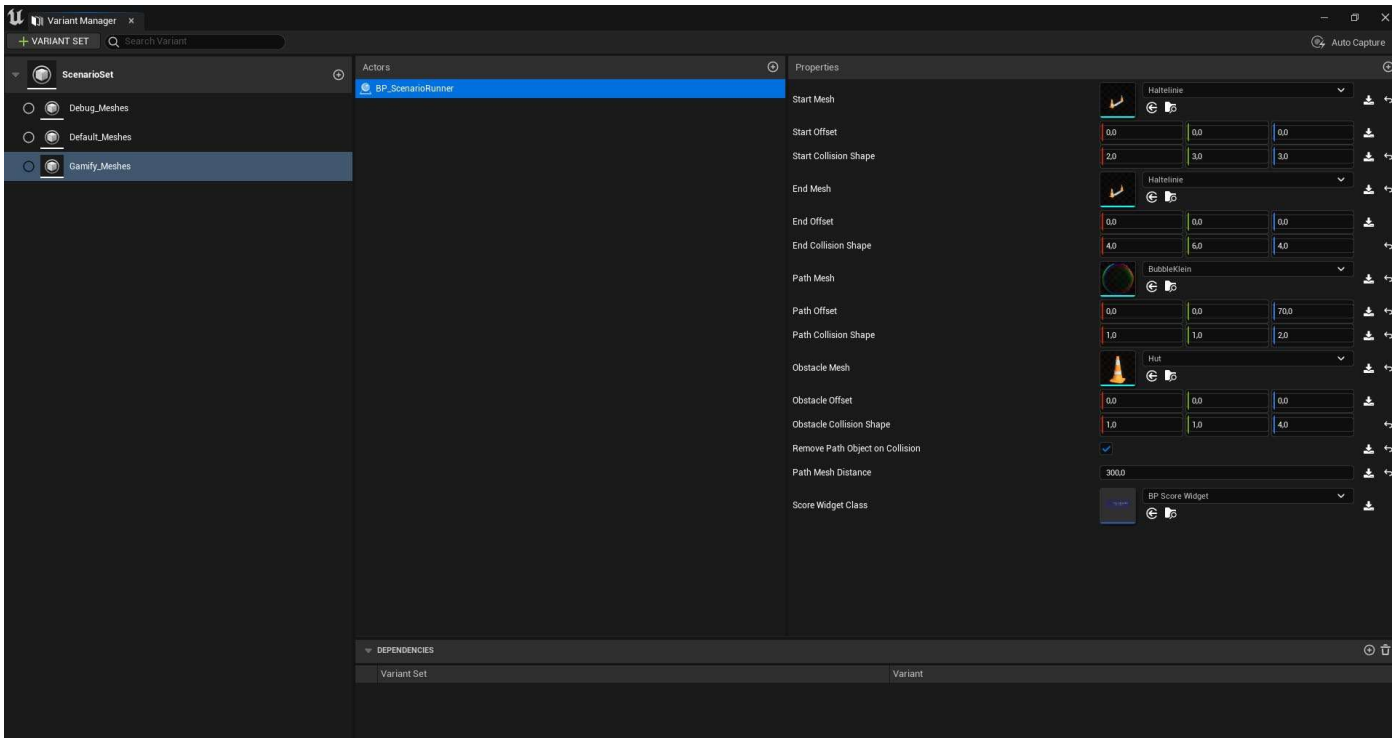




Variant Manager

Im Variant Manager können verschiedene Einstellungen für den jeweiligen Modus festgelegt werden (Meshes, Distanz zwischen Items).





Eingaben für VL

Eingabe	Funktion
+	Nächstes Szenario
-	Vorheriges Szenario
0	Szenarios zurücksetzen
Enter	Szenario beenden

Num 1	**Default Mode**
Num 2	**Game Mode**
Num 3	**Debug Mode**

D: Loggindaten

Name	Typ	Beschreibung
DLR-Plugins:		
Counter	int	Eintragsnummer
TimeStamp_DateTime	str	Format: %Y.%m.%d-%H.%M.%S
TimeStamp_Unix	int	Aktuelle Unixzeit
TimeStamp_MS	int	Millisekunden
002_bike_acceleration_x	float	Beschleunigung x-Achse
002_bike_acceleration_y	float	Beschleunigung y-Achse
002_bike_acceleration_z	float	Beschleunigung z-Achse
002_bike_forward_acceleration	float	Vorwärtsbeschleunigung
002_bike_forward_velocity	float	Vorwärtsgeschwindigkeit
002_bike_lean	float	Lehnwinkel
002_bike_pos_x	float	Fahrradposition x-Achse
002_bike_pos_y	float	Fahrradposition y-Achse
002_bike_pos_z	float	Fahrradposition z-Achse
002_bike_rot_x	float	Fahrradrotation x-Achse
002_bike_rot_y	float	Fahrradrotation y-Achse
002_bike_rot_z	float	Fahrradrotation z-Achse
002_bike_steering	float	Lenkwinkel
002_bike_velocity_x	float	Geschwindigkeit x-Achse
002_bike_velocity_y	float	Geschwindigkeit y-Achse
002_bike_velocity_z	float	Geschwindigkeit z-Achse
002_head_pos_x	float	Kopfposition x-Achse
002_head_pos_y	float	Kopfposition y-Achse
002_head_pos_z	float	Kopfposition z-Achse
002_head_rot_x	float	Kopfrotation x-Achse
002_head_rot_y	float	Kopfrotation y-Achse
002_head_rot_z	float	Kopfrotation z-Achse
BiTS:		
003_AvailableObstacles	int	Anzahl der m Szenario platzierten Hindernisse
003_AvailablePoints	int	Anzahl der m Szenario platzierten Pfadobjekte
003_CollectedPoints	int	Im Szenario gesammelte Pfadobjekte
003_CurrentScenario	str	Aktuelles Szenario
003_EndTrigger	bool	Wird auf Wahr gesetzt, wenn das Ziel erreicht, wird
003_ObstacleCollisions	int	Während des Szenarios berührte Hindernisse
003_ObstacleLocX	float	Hindernisposition x-Achse

003_ObstacleLocY	float	Hindernisposition y-Achse
003_ObstacleLocZ	float	Hindernisposition z-Achse
003_PointsLocX	float	Pfadobjektposition x-Achse
003_PointsLocY	float	Pfadobjektposition y-Achse
003_PointsLocZ	float	Pfadobjektposition z-Achse
003_ScenarioTime	float	Benötigte Zeit für das aktuelle Szenario
003_TrainingType	enum	Die gefahrene Variante (Default oder Gamify)

E: Instruktion

Default

Liebe Teilnehmer*innen,

vielen Dank, dass Sie uns bei dieser Studie unterstützen! Bitte lesen Sie die folgenden Instruktionen aufmerksam durch.

<u>Ihre Aufgabe</u>

In dieser Studie fahren Sie auf einem Fahrradsimulator, die Umgebung ist dem Braunschweiger Verkehrsübungsplatz des ADAC nachempfunden. Ihre Aufgabe besteht darin, den Markierungen auf der Straße zu folgen. Das „Simulator-Fahrrad“ dient dazu, Ihre Steuermanöver wie das Lenken, Lehnen, Beschleunigen und Bremsen auf die Simulation zu übertragen.



***Abbildung:**. Links: Markierungen; Rechts: Haltelinie*

Sie werden verschiedene Szenarien fahren. Über die Kopfhörer der VR-Brille werden sie Umgebungsgeräusche aus der Simulation wahrnehmen können. Jedes Szenario startet erst wenn Sie losfahren, also lassen Sie sich ruhig einen Moment Zeit um sich an die neue Umgebung zu gewöhnen. Versuchen Sie so gut wie möglich auf der vorgegebenen Markierung zu fahren. **Beim Erreichen der Haltelinie bremsen Sie bitte vollständig ab**. Ihre Sicht wird sich daraufhin verdunkeln und eine Grafik wird eingeblendet. Sie sollen für uns anhand einer Skala einschätzen wie Ihr Wohlbefinden zu den jeweiligen Zeitpunkten ist. Danach werden Sie an den Start des nächsten Szenarios gesetzt.

Das Ende der Fahrt wird Ihnen durch die Versuchsleitung mitgeteilt. Bleiben Sie bitte so lange sitzen, bis die Versuchsleitung Sie zum Aufstehen auffordert. Das Ende der Fahrt wird Ihnen durch die Versuchsleitung mitgeteilt. **Bitte ziehen Sie erst die VR-Brille ab** und stehen Sie dann langsam auf. Bitte springen Sie nicht vom Simulator herunter!

Im Anschluss werden Ihnen Fragen zu Ihrem Fahrverhalten und -erleben gestellt. Diese Fragen füllen Sie an einem Tablet aus.

Sollte es Ihnen im Verlauf der Untersuchung nicht gut gehen oder sollten Sie sich unwohl fühlen, bitten wir Sie, dies sofort der Versuchsleitung mitzuteilen. Sie haben jederzeit die Möglichkeit, den Versuch zu beenden.

Haben Sie noch Fragen?

Liebe Teilnehmer*innen,

vielen Dank, dass Sie uns bei dieser Studie unterstützen! Bitte lesen Sie die folgenden Instruktionen aufmerksam durch.

Ihre Aufgabe

In dieser Studie fahren Sie auf einem Fahrradsimulator, die Umgebung ist dem Braunschweiger Verkehrsübungsplatz des ADAC nachempfunden. Ihre Aufgabe besteht darin, den Markierungen auf der Straße zu folgen. Das „Simulator-Fahrrad“ dient dazu, Ihre Steuermanöver wie das Lenken, Lehnen, Beschleunigen und Bremsen auf die Simulation zu übertragen.



***Abbildung:**. Links: Markierungen; Rechts: Haltelinie*

Sie werden verschiedene Szenarien fahren. Über die Kopfhörer der VR-Brille werden sie Umgebungsgeräusche aus der Simulation wahrnehmen können. Jedes Szenario startet erst wenn Sie losfahren, also lassen Sie sich ruhig einen Moment Zeit um sich an die neue Umgebung zu gewöhnen. Sammeln Sie so viele Seifenblasen wie möglich ein, indem sie dagegen fahren. Fahren sie bitte **nicht** zurück um verpasste Blasen einzusammeln. **Beim Erreichen der Haltelinie bremsen Sie bitte vollständig ab**. Ihre Sicht wird sich daraufhin verdunkeln. Eine Punkteskala und eine Grafik werden eingeblendet. Sie sollen für uns anhand einer Skala einschätzen wie Ihr Wohlbefinden zu den jeweiligen Zeitpunkten ist. Danach werden Sie an den Start des nächsten Szenarios gesetzt.

Das Ende der Fahrt wird Ihnen durch die Versuchsleitung mitgeteilt. Bleiben Sie bitte so lange sitzen, bis die Versuchsleitung Sie zum Aufstehen auffordert. Das Ende der Fahrt wird Ihnen durch die Versuchsleitung mitgeteilt. **Bitte ziehen Sie erst die VR-Brille ab** und stehen Sie dann langsam auf. Bitte springen Sie nicht vom Simulator herunter!

Im Anschluss werden Ihnen Fragen zu Ihrem Fahrverhalten und -erleben gestellt. Diese Fragen füllen Sie an einem Tablet aus.

Sollte es Ihnen im Verlauf der Untersuchung nicht gut gehen oder sollten Sie sich unwohl fühlen, bitten wir Sie, dies sofort der Versuchsleitung mitzuteilen. Sie haben jederzeit die Möglichkeit, den Versuch zu beenden.

Haben Sie noch Fragen?

F: Datenerhebung

Demografie

ID	Abb.	Mode	Alter	03	04	05	06	06	06	06	06	08	09	10	11	11	12	13	14	14	14	14	14	14
1	x	D	23	1	2	1	1	2	1	1	1	3	8	7	50	20	18	3	1	1	2	1	1	1
8	x	D	38	2	1	1	2	2	2	1	1	1	4	7	5	0	20	3	1	1	1	2	1	1
14	x	G	28	1	1	1	1	2	1	1	1	3	7	8	360	0	22	3	2	1	2	2	1	1
2		D	29	2	2	1	1	2	1	1	1	8	5	5	30	1500	22	3	2	2	2	1	1	1
4		D	32	1	1	1	1	2	1	1	1	5	6	8	30	50	26	3	1	1	2	1	1	1
6		D	34	1	1	1	1	2	1	1	1	4	8	7	150	20	29	3	2	2	2	1	1	1
9		D	34	2	1	1	1	2	1	1	1	6	8	6	40	600	30	3	1	1	2	1	1	1
11		D	46	2	2	1	1	2	1	1	1	8	6	6	200	800	40	3	2	1	2	2	1	1
13		D	25	2	1	1	3	2	2	2	1	7	3	7	2	1300	15	1	2	2	1	2	1	1
3		G	30	2	1	1	1	2	1	1	1	8	7	6	750	1500	23	2	3	2	2	2	1	1
5		G	28	2	1	1	1	2	1	1	1	7	3	7	50	10000	20	1	2	2	1	2	1	1
7		G	41	2	1	1	1	2	1	1	1	8	8	8	300	100	35	2	2	2	2	1	1	1
10		G	30	2	1	1	1	2	1	1	1	6	7	7	100	30	25	1	1	1	2	1	1	1
12		G	32	2	2	1	1	2	1	1	1	3	7	6	250	50	27	3	2	2	2	1	1	1
15		G	30	2	2	1	1	2	1	1	1	8	6	8	15	1200	24	1	3	2	2	2	1	1

FS

ID	Ab-bruch	Modus	FS01	FS04	FS05	FS06	FS07	FS08
1	x	D	5	7	7	5	7	7
8	x	D	5	4	4	4	6	5
14	x	G	4	4	5	6	6	5
2		D	6	6	4	6	7	7
4		D	6	6	4	6	5	7
6		D	4	3	5	6	7	5
9		D	7	6	7	6	6	7
11		D	5	5	7	4	7	4
13		D	4	6	6	2	5	6
3		G	7	7	4	7	7	5
5		G	7	7	7	5	7	7
7		G	5	4	3	3	5	2
10		G	6	6	7	6	7	7
12		G	6	7	7	6	7	7
15		G	7	6	6	6	5	7
		Default	**5,33**	**5,33**	**5,50**	**5,00**	**6,17**	**6,00**
		Gamify	**6,33**	**6,17**	**5,67**	**5,50**	**6,33**	**5,83**

ID	Abbruch	Modus	FS02_01
			Was gut:
1	x	D	wenig Interaktionen und Störfaktoren. Ungestörtes Fahren gut möglich
8	x	D	The route are looks natural with sufficient space
14	x	G	erst gerade Strecken, dann Kurven cooles Trainingskonzept mit den Seifenblasen (vgl Mariokart)
2		D	Abwechslung, nicht immer der gleiche Abschnitt
4		D	Simulationsumgebung, Auswahl der Szenarien
6		D	langezogene Kurven
9		D	Die Landstraße mit der Langezogenen Kurve. Der Slalom
11		D	Gut markiert
13		D	Umgebung war gut, Fahrsicherheitsplatz gab einem eine Gewisse Sicherheit das man dort ungestört fahren kann ohne Angst zu habne vor "wilden" Autofahrern
3		G	- Steigerung der Schwierigkeit des Fahrens - Seifenblasen fangen als Challenge - Sound-Feedback bei Einfangen der Seifenblase sehr befriedigend - Feedback am Ende wie gut man abgeschnitten hat
5		G	Kurvenreicher, bisherige gradlinige Versuche schienen da etwas zu kurz
7		G	/
10		G	ein bisschen abwechslungsreich Kurven etc. klar erkennbar wo man hin sollte
12		G	Übersichtlichkeit, Fahrkomfort, geringes Verkehrsaufkommen
15		G	Realismus der Umgebung. Auswahl der Szenarien
ID	**Abbruch**	**Modus**	**FS03_01**
			Was schlecht:
1	x	D	scharfe Kurven schwierig zu fahren
8	x	D	not at all
14	x	G	Sichtbarkeit der Seifenblasen im Schatten oder bei Kurven -> weniger "durchsichtig" würde helfen
2		D	/
4		D	/
6		D	enge Kurven
9		D	Bei der Kreuzung der schnelle Richtungswechsel
11		D	Relativ künstlich
13		D	Die Darstellungen der "Welt" könnt qualitativ besser sein
3		G	- Großer Schwierigkeitssprung beim letzten Szenario (Slalom) - Sehr hoher Widerstand beim Anfahren (zu hoch) - Bremse unrealistisch stark
5		G	Die Strecke könnte noch länger sein um sich besser hineindenken zu können
7		G	war künstlich, schlechte Farben
10		G	sehr einfach gehalten
12		G	/
15		G	Zu viele Kurven. Slalom war etwas zu eng.

TAS

ID	Abb.	Mode	01	02	03	04	05	06	07	08	09
1	x	D	-2	2	0	-2	0	1	-2	1	-1
8	x	D	0	-1	-2	-1	-1	-1	1	-1	-1
14	x	G	-2	2	-2	-2	-2	-2	-2	-2	-1
2		D	-2	-2	-1	-2	-1	-2	-2	-2	-2
4		D	-2	-2	-2	-2	-2	-2	-2	-2	-2
6		D	-1	1	-1	-2	-1	0	-2	-1	-1
9		D	-2	0	-1	0	0	0	-1	-1	-2
11		D	-2	-1	-2	-2	0	0	-1	-1	0
13		D	-2	1	1	0	-1	-1	-1	0	-1
3		G	-2	-1	-2	-2	-2	-1	-2	-2	-2
5		G	-1	-2	-2	-2	-2	-2	-2	-2	-2
7		G	-2	-1	-1	-1	-1	-1	-1	-1	-2
10		G	0	-1	-2	-2	-1	-2	-1	-2	1
12		G	-2	-1	-2	-2	-1	-2	-1	0	-2
15		G	-1	0	-2	-1	-1	-1	-2	-2	-2
			u	s	u	s	u	s	u	s	u
		Default	1,83	0,5	1	1,33	0,83	0,83	1,5	1,17	1,33
		Gamify	1,33	1	1,83	1,67	1,33	1,5	1,5	1,5	1,4

MISC

ID	**Abb.**	**Mode**	**1.**	**2.**	**3.**	**4.**	**5.**	**6.**	**7.**
1	x	D	0	1	1	3	6	6	6
8	x	D	0	1	6	6	6	6	6
14	x	G	0	2	2	5	6	6	6
2		D	0	0	0	0	0	0	1
4		D	0	0	0	0	0	0	0
6		D	1	1	2	2	3	3	3
9		D	0	0	0	0	0	0	0
11		D	0	1	0	0	1	0	2
13		D	0	0	0	1	1	1	1
3		G	0	0	0	0	0	0	0
5		G	0	0	0	0	0	0	0
7		G	0	1	0	0	1	1	1
10		G	0	0	0	0	0	0	1
12		G	0	0	0	0	0	0	0
15		G	0	0	0	1	0	0	1
Avg									
		Default	**-0,67**	**-0,33**	**-0,50**	**-0,17**	**0,33**	**0,00**	**0,83**
		Gamify	**-1,00**	**-0,67**	**-1,00**	**-0,67**	**-0,67**	**-0,67**	**0,00**
Avg Mode Abbruch									
		Default	**-0,75**	**0,00**	**0,50**	**1,00**	**1,75**	**1,50**	**2,13**
		Gamify	**-1,00**	**-0,29**	**-0,57**	**0,14**	**0,29**	**0,29**	**0,86**

PQ

ID	1	8	14	2	4	6	9	11	13	3	5	7	10	12	15		
ABB.	x	x	x														
Mode	D	D	G	D	D	D	D	D	D	G	G	G	G	G	G	Default	Gamify
PQ01	5	4	5	7	6	5	5	6	6	6	7	5	6	6	5	5,60	6,00
PQ02	5	4	5	4	5	6	5	6	4	1	7	6	4	7	6	5,00	4,67
PQ03	2	3	2	6	5	5	4	6	3	5	6	2	5	4	6	4,40	4,50
PQ04	5	5	6	5	6	6	4	6	5	7	7	6	5	6	4	5,40	6,00
PQ05	6	4	5	5	4	5	4	3	4	7	6	4	4	2	6	4,60	4,67
PQ06	2	4	2	6	5	5	6	5	3	5	6	1	5	3	5	4,80	4,17
PQ07	5	5	3	6	5	6	6	5	5	7	7	6	6	4	4	5,20	6,00
PQ08	3	4	2	6	5	5	5	5	2	5	5	4	6	3	6	4,60	4,50
PQ09	5	4	4	7	5	6	6	6	5	5	6	5	5	5	6	5,60	5,33
PQ10	7	4	6	7	6	7	7	5	5	7	7	5	6	6	4	6,60	5,83
PQ11	6	4	3	7	5	7	7	3	5	7	5	6	4	2	6	5,80	5,00
PQ12	5	4	4	1	3	2	4	1	3	7	4	6	4	2	6	2,80	4,17
PQ13	2	4	4	6	1	3	1	1	4	1	4	7	4	1	1	3,00	3,50
PQ14	3	4	3	7	5	6	6	7	4	7	7	7	5	6	5	5,40	6,17
PQ15	4	4	4	5	1	3	3	1	3	4	4	5	4	5	5	3,20	3,50
PQ16	4	4	3	4	1	3	2	1	4	4	4	4	6	1	4	2,60	3,83
PQ17	4	4	3	5	1	3	1	5	5	5	4	4	5	5	4	2,60	4,67
PQ18	6	4	5	6	6	5	4	5	5	7	7	6	6	7	5	5,20	6,00
PQ19	4	6	4	7	3	7	7	6	6	7	6	7	4	6	7	5,60	6,00
PQ20	4	5	1	7	6	5	6	6	4	7	7	7	7	6	7	5,00	6,33
PQ21	2	4	1	7	4	6	7	5	1	4	7	3	7	6	6	5,00	4,50
PQ22	7	4	4	5	7	7	7	6	7	7	7	4	6	6	6	6,00	6,17
PQ23	1	4	3	7	4	4	6	4	4	2	7	1	6	6	5	4,80	4,00
PQ24	3	4	2	6	4	5	6	5	3	4	7	3	6	7	6	4,60	4,67
PQ25	4	4	4	7	6	7	7	4	5	4	7	4	6	6	5	6,20	5,00
PQ26	2	4	2	1	5	1	1	5	1	1	1	1	1	1	1	2,00	1,67
PQ27	1	4	5	1	5	4	2	5	3	4	2	5	2	2	2	3,40	3,50
PQ28	5	4	2	1	1	6	6	4	1	5	5	3	5	6	5	3,20	3,83
PQ29	4	4	4	1	1	7	4	1	1	5	7	7	4	1	6	3,40	4,17
PQ30	7	4	4	6	4	6	7	4	4	7	7	3	7	6	6	5,40	5,33
PQ31	3	4	2	4	5	5	7	5	2	5	7	4	5	7	7	4,60	4,67
PQ32	7	4	2	4	5	6	7	7	5	7	7	7	6	6	5	4,80	6,50

	INV	SF	AI	IQ
Default	67,27	43,81	74,64	80,95
Gamify	75,54	61,90	83,33	79,37

SSQ

ID	Abb.	Mode	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16
1	x	D	2	1	0	0	0	0	0	1	0	0	1	1	0	1	2	0
8	x	D	3	1	2	2	3	3	2	3	3	2	3	2	2	2	3	3
14	x	G	3	0	1	0	1	0	2	3	1	0	1	0	0	3	3	0
2		D	0	0	0	1	0	0	1	0	0	1	0	0	0	1	0	0
4		D	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0
6		D	1	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0
9		D	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
11		D	1	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0
13		D	1	0	0	1	1	0	3	0	0	0	1	0	0	1	2	0

3		G	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5		G	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7		G	1	0	0	0	0	0	1	1	0	0	0	0	0	1	0	0
10		G	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
12		G	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
15		G	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	0

	Übelkeit	Okulomotorik	Desorientierung	Total Score
Default	**20,67**	**11,37**	**16,24**	**8,03**
Gamify	**7,95**	**1,26**	**9,28**	**3,49**

Hinweis zum Urheberrecht

Diese Arbeit einschließlich aller ihrer Teile ist urheberrechtlich geschützt und wird aus-schließlich zu Prüfungszwecken im Studiengang Computervisualistik und Design an der Hoch-schule Hamm-Lippstadt vorgelegt. Jede Verwertung außerhalb der engen Grenzen des Urheberrechtsgesetzes ist ohne Zustimmung des Verfassers/der Verfasserin unzulässig. Insbesondere enthält sie betriebsinterne Daten des Unternehmens DLR. Eine Weitergabe an Dritte sowie die Veröffentlichung oder Verwendung der betriebsinternen Daten ist nur mit ausdrücklicher vorheriger Zustimmung des DLR gestattet.

Eidesstattliche Erklärung

Name: Schiffers

Vorname: Jasmin

Matrikel-Nr.: [redacted]

Studiengang: Computervisualistik und Design

Ich versichere hiermit, dass ich die vorliegende Arbeit selbstständig und nur unter Benutzung der angegebenen Literatur und Hilfsmittel angefertigt habe. Wörtlich übernommene Sätze und Satzteile sind als Zitate belegt, andere Anlehnungen hinsichtlich Aussage und Umfang unter Quellenangabe kenntlich gemacht.

Die Arbeit hat in gleicher oder ähnlicher Form noch keiner Prüfungsbehörde vorgelegen und ist auch noch nicht veröffentlicht.

[redacted] [redacted]

Ort, Datum Unterschrift