Institut für Mathematik
Fakultät II – Mathematik und Naturwissenschaften
Technische Universität Berlin

Praktikumsbericht

Daniel Linus Matteo Döringer
Matrikelnummer: 400352
Studiengang: Wirtschaftsmathematik

Betreuer: Felix Fischer
Unternehmen: Eye Square GmbH

Datum: 18.07.2023

Inhaltsverzeichnis

1 Das Unternehmen **3**

2 Beschreibung meiner Tätigkeiten bei Eye Square **3**

2.1 Arbeit an einem Eye-Tracking-Innovationsprojekt mithilfe von fortgeschrittenen Methoden aus dem Bereich der künstlichen Intelligenz 3

2.2 Aufsetzen einer kleinen Studie zum Zwecke der Prüfung einer prädiktiven Eye-Tracking-KI 5

3 Fazit und Ausblick **7**

1 Das Unternehmen

Die Eye Square GmbH ist ein weltweit führendes, berliner Unternehmen im Bereich der impliziten Marktforschung. Es wurde 1999 gegründet und hat heute ca. 100 Mitarbeiter, sowie Büros in Berlin, New York, London, Tokyo und Hong Kong. Eye Square bietet verschiedene Dienstleistungen an, um die Wirkung von analogen und digitalen Werbungen zu messen, zu erhöhen und zu verstehen. Hierfür bietet das Unternehmen seinen Kunden unter anderem Studien an, welche je nach Art der Studie sowohl in den hauseigenen Laboratorien, als auch bei den Studienteilnehmern zuhause, oder in Supermärkten und anderen öffentlichen oder nicht-öffentlichen Plätzen stattfinden können. Von Eye Square eingesetzte Methoden Werbewirkung zu messen sind vielfältig und umfassen qualitative und quantitative Ansätze. Ein Hauptfokus des Unternehmens liegt bei dem Einsatz des sogenannten „Eye-Trackings“ für die Marktforschung. Hierher stammt auch der Name der Firma. Neben Eye-Tracking werden Messungen der elektrodermalen Aktivität, der Laufwege (z. B. von Kunden in Supermärkten), der Click-Frequenzen von Nutzern im Internet und andere Daten herangezogen, um alles rund um menschliche Aufmerksamkeit zu erfassen.

Aufgrund der kontinuierlichen Erhebung zahlreicher Studiendaten gibt es firmenintern einen Bedarf diese in richtiger Form zu verarbeiten, zu analysieren und zu visualisieren, um den angestellten Beratern des Unternehmens zu ermöglichen den Kunden die Einblicke zu präsentieren und zu erklären, welche gebraucht werden, um informierte Entscheidungen über den Einsatz von Werbungen treffen zu können. Diese Prozesse werden innerhalb der Eye Square weitestgehend von der so benannten „Unit Analyse“ gestaltet und durchgeführt. In dieser Unit habe ich auch mein Praktikum im Data Science-Bereich absolviert.

Da zur Zeit meines Kommens ein Innovationsprojekt in der Entwicklung war, bei dem es um einen geschickten und neuartigen Einsatz von Eye-Tracking geht (genaue Details darf ich nicht geben, da die Entwicklung fortläuft und patentrechtliche und andere Bedenken bestehen) und das relativ kleine Entwicklungsteam stark ausgelastet war, durfte ich bereits in der ersten Woche anfangen das Projekt durch tatkräftiges Anpacken aktiv mitzugestalten. Über den Zeitraum meines Praktikums durfte ich so sehr tiefe Einblicke in die Architektur des geplanten Produktes und die auftretenden Probleme gewinnen und helfen die Entwicklung voranzutreiben. Hierfür habe ich mich eingehend mit Methoden aus der künstlichen Intelligenz und spezifisch neuronalen Netzen sowie aus dem Bereich „Computer Vision“ befasst und diese angewendet. Teilweise geschah dies durch das Anwenden und Beaufsichtigen bereits vorhandener Algorithmen und teils durch das eigene Implementieren von Algorithmen mithilfe von Python.

Neben der Arbeit an diesem Innovationsprojekt, welche überwiegend mit Datenverarbeitung und künstlicher Intelligenz zu tun hatte, habe ich auch die Möglichkeit bekommen eine kleine interne Eye-Tracking-Studie zu planen, durchzuführen und auszuwerten, bei welcher es um den Test einer Dienstleistung eines möglichen Konkurrenten des Unternehmens ging.

2 Beschreibung meiner Tätigkeiten bei Eye Square

2.1 Arbeit an einem Eye-Tracking-Innovationsprojekt mithilfe von fortgeschrittenen Methoden aus dem Bereich der künstlichen Intelligenz

In meiner ersten Tätigkeit, welche den Großteil meiner Zeit bei Eye Square einnahm, wurde ich in ein Innovationsprojekt zu einer neuartigen Eye-Tracking Methode eingearbeitet und durfte dieses aktiv mitgestalten.

Das grobe Ziel dieses Projekts war es, anhand von Bilddaten der menschlichen Augen sowie anderer räumlicher Informationen einzuschätzen, wohin ein gegebener Mensch in einem gegebenen Moment guckt. Dies hat natürlich eine große Relevanz in der Marktforschung, da diese unter anderem daran interessiert ist, wem oder was genau Menschen auf welche Art und Weise für wie lange und wie ergiebig ihre Aufmerksamkeit schenken.

Eye-Tracking kann grundsätzlich mit dafür entwickelten Geräten oder heutzutage auch mithilfe von nicht dafür vorgesehenen Kameras (z. B. Webcams, Smartphone-Kameras etc.) geschehen.
Eine weitere grundlegende Unterscheidung zwischen verschiedenen Eye-Tracking-Methoden ist, ob mit einem geometrischen Ansatz oder einem Machine Learning-Ansatz der Blick des Auges geschätzt wird. Das Produkt, welches ich mitentwickeln durfte, nutzt – ohne zu viel über die Genauigkeiten zu verraten – Kameras, welche nicht primär zum Zweck des Eye-Trackings gebaut wurden und folgt, wie für solche Anwendungsfälle üblich, einem Machine Learning-Ansatz.

Um die Daten fürs Trainieren dieser KI zu erheben wurden verschiedene Methoden eingesetzt. Darunter waren Datenerhebungen von Studienteilnehmern, welche in den hauseigenen Laboratorien dabei gefilmt wurden, wie sie auf verschiedene Punkte im Raum guckten. Die genauen Aufnahmebedingungen dieser Studien zur Datensammlung mussten genau reguliert sein, um einen Datensatz mit gewünschten Eigenschaften zu erzeugen. Die gesammelten Bild-

daten wurden dann mit anderen Daten, welche darauf abzielten das genaue räumliche Verhältnis des Probanden zu dem Blickpunkt zu bestimmen, in einer Datenbank gespeichert. Bei der Sammlung dieser Daten habe ich in der Zeit meines Praktikums nicht aktiv mitgewirkt. Ich war aber durchaus in ständigem Austausch mit den dafür verantwortlichen Kollegen und habe diese durch intensive Inspektion der damals bereits gesammelten Daten und die Ergebnisse und Interpretation dieser von Machine Learning-Experimenten, welche ich eigenständig konzipierte und durchführte, beraten, die Datensammlung künftig vorteilhaft zu gestalten. Konkret fiel mir z. B. beim manuellen Inspizieren von gesammelten Video-Daten auf, dass viele Teilnehmer nach einer gewissen Zeit zu ermüden schienen und den Aufgabenstellungen weniger aufmerksam folgten. Auch konnte ich durch das Vergleichen von Ergebnissen trainierter neuronaler Netze beraten, welche Daten sich besser als Trainings-Daten zu eignen schienen, je nachdem, wie genau die Vorhersage der Modelle für die Blickpunkte von bestimmten Personen war, nachdem diese mit bestimmten Daten trainiert wurden.

In von mir ausgehender Initiative wollte ich beispielsweise testen, ob Bilddaten, welche dem menschlichen Auge nach eine hohe Qualität zu haben scheinen (welche etwa aus Bildern bestehen, bei denen beide Pupillen der Personen deutlich sichtbar sind, anstatt, dass eine oder beide Pupillen verdeckt sind, oder eine Reflexion oder ein anderes Ereignis diese schwer oder gar nicht sichtbar macht) auch in der Praxis unser neuronales Netzwerk besser trainieren, d. h., u. A., zu besseren Genauigkeiten in der Prädiktion der Blickwinkel der Testpersonen führen. Zu diesem Zweck habe ich mit Python ein Programm geschrieben, welches mir einzelne Frames der Videodaten in einer geordneten Weise zur Inspektion präsentierte, sodass ich diese mithilfe von Tasten auf der Tastatur in verschiedene Kategorien zuordnen konnte, welche die unterschiedliche Qualität dieser Daten repräsentieren sollten. Auf diese Weise habe ich über mehrere Arbeitstage zehntausende von Bildern manuell gelabelt und anschließend mithilfe dieser Bilder Modelle trainiert. Beim Training dieser Modelle konnten dann wiederum gewisse Eigenschaften eines vorteilhaften Datensatzes erkannt werden, welche ich mit meinen Kollegen teilte. Eine zentrale Frage war z. B., ob beim Filtern gewisser Bilddaten eine Überanpassung auf die verbliebenen Daten stattfinden könnte, welche dazu führen würde, dass das Modell nicht gut auf die Daten generalisieren könnte, von deren Art es wenige oder keine Daten im Trainings-Datensatz gesehen hat. Es stellte sich durch dieses Experiment heraus, dass diese Sorgen zumindest im Kontext projektspezifischer Fragestellungen weitestgehend unbegründet waren, da Modelle, welche mit gelabelten Daten geringerer Vielfalt trainiert wurden, erstaunlich gut von den eingeschränkten Daten auf ungesehene generalisieren konnten. Diese Erkenntnis diente als Hinweis für weiteres Vorgehen fürs Team, welches sich darauf konzentrierte nach sinnvollen Filtern für Trainingsdaten zu suchen.

Selbstverständlich habe ich auch viele Experimente durchgeführt, welche negative Ergebnisse indizierten und keinen nennenswerten positiven Erkenntnisgewinn brachten. Dies war sogar für die große Mehrheit der Experimente der Fall, welche ich betreute. Es galt an diesen Stellen dann, auch aus negativen Ergebnissen zu lernen und ein besseres Verständnis für mögliche Gründe des ausbleibenden Erfolges zu finden. Oftmals haben sich Ansätze, welche meiner eigenen Intuition und derer meiner Kollegen nach gut hätten ausgehen sollen, als Sackgassen entpuppt, während andere Methoden, welche bereits als verworfen galten und weniger intuitiv waren unter bestimmten Bedingungen doch positive Ergebnisse lieferten. Erstaunlich für uns war z. B., dass die allermeisten gängigen Augmentationen sich negativ auf die Modell-Genauigkeit auswirkten, wohingegen das erwähnte Filtern von selbst halbwegs gut ausschauenden Daten (in welchen aber unserer subjektiven Einschätzung nach die Pupillen weniger gut erkennbar waren) gute Ergebnisse brachte, was die meisten im Team sehr überraschte.

Um die erwähnten Experimente informiert durchzuführen, musste ich mich darüber hinaus fortgehend auf theoretischer Ebene mit dem Trainieren und Auswerten von Modellen beschäftigt, welche mit neuronalen Netzen – in diesem Fall spezifisch mit sogenannten „faltenden neuronalen Netze“ („Convolutional Neural Networks“, „CNN“) beschäftigen. Auch zum Thema Bildverarbeitung musste ich dafür viel lernen, da die Speicherart der verschiedenen Bild-Datei-Typen (jpg, png etc.) und Funktionalitäten der OpenCV Programmbibliothek, welche ich mit Python für zahlreiche kleinere Skripte brauchte, wichtige Puzzle-Stücke darstellten, um spezifische Aufgaben zu erledigen und, um die bestehenden Skripte zu verstehen. Um Bild-Augmentierungs-Verfahren zu testen, habe ich z. B. das Trainieren mit gray-scale Bildern getestet und auch das Trainieren mit Bildern, derer gemeinsamer pixelweise Mittelwert von ihnen subtrahiert wurde, was eine sogenannte „Regularisierungs-Methode“ darstellt. Für die von mir entworfenen Python-Skripte, welche mir diese Trainingsdaten aus den gegebenen Daten generierten, musste ich sowohl der vorliegenden Datenstruktur gerecht werden (hierfür war u. A. das Python OS Package essentiell) als auch mit OpenCV Transformationen von vorliegenden Bilddaten vornehmen, da diese teilweise falsch formatiert waren und andere, mathematische Operationen anwenden.

Spezifisch um die Ergebnisse der Machine Learning-Trainings besser zu verstehen, durfte ich auch viel über gängige Praktiken in diesem Bereich lernen, wie z. B. Methoden zur Bestimmung einer guten Learning Rate und anderer Hyperparameter. Auch Verfahren von Bild-Augmentationen und ihre Rolle in der gezielten Abänderung der Trainingsdaten, um die Größe und Vielfalt des Datensatzes zu erhöhen und Überanpassung des Modells vorzubeugen, waren Teil meiner Interessen, welche ich durch freie Recherche und Experimente auf Eignung für unser Projekt prüfen durfte. Aufgrund der Natur unseres Problems habe ich mich auch über andere Problemstellungen informiert, für welche CNNs erfolgreich zum Einsatz kommen – wie z. B. Bildklassifizierungsprobleme – und Methoden, welche für diese Probleme gut funktionieren können auf unser Problem angewendet (wie z. B. die erwähnte Augmentation, bei welcher

der pixelweise Mittelwert aller Trainingsbilder von allen Trainingsbildern subtrahiert wird).

Parallel zum eigenständigen Lernen über diese Themen war aber gerade das Erdenken und Durchführen von Experimenten das, was mein Verständnis für Themen des maschinellen Lernens enorm gestärkt hat. Bereits am letzten Tag der ersten Praktikumswoche, habe ich das erste Trainingsexperiment entworfen und gestartet (welches auch aufgrund der hohen Auslastung des Teams das erste Experiment überhaupt war, welches wir in diesem Projekt durchführten). Übers Wochenende konnte eine leistungsstarke Grafikkarte, welche ich an meinem Arbeitsplatz zur Verfügung hatte und in einem Gaming-Laptop verbaut war, die nötigen Berechnungen ausführen, deren Ergebnisse ich dann am nächsten Montag auswerten konnte. Von da an bis zum Ende des Praktikums habe ich ca. 30 solcher Experimente durchführen können, welche teilweise mehrere Tage (oftmals übers Wochenende), teilweise aber nur wenige Minuten dauerten, da ein unvorteilhaftes Verhalten des Trainings- und/oder Validierungs-Verlustes absehbar schien. Auch eine hohe CPU-Temperatur von kurzzeitig deutlich über 90 Grad Celsius führte bei mir einmal zu Sorge und veranlasste ein Unterbrechen des Experiments. Dieses Problem konnte schlussendlich größtenteils durch eine bessere Positionierung des Laptops und einfache Performance-Einstellungen behoben werden. Eine Migration der Trainings zu einem Cloudanbieter war zwar von Anfang geplant, blieb aber aus vielseitigen Gründen vorerst aus.

Beim Entwerfen der Experimente und Machine Learning-Trainings habe ich unter Anderem mit variierten Hyperparametern wie der Learning Rate, unterschiedlichen Netzwerkarchitekturen (z. B. Tiefe des Netzwerkes), verschiedenen Trainings- und Validierungs-Datensätzen (z. B. mit oder ohne Augmentationen und verschiedenen Kreuzvalidierungen) und abgeänderten vorgegebenen Modell-Gewichten gearbeitet und diese Experimente ausgewertet und darauf aufbauend Entscheidungen getroffen, wie ich selber weitere Trainings ansetzen sollte, um möglichst gute Modell-Performance mit weiteren gewollten Eigenschaften zu erreichen (z. B. gute Generalisierung) und beratend Empfehlungen an meine Kollegen gegeben, wie diese in offenen Fragen entscheiden sollten, um eine fürs Projekt vorteilhafte, fortlaufende Datensammlung- und Auswertung sicherzustellen.

Obwohl ich größtenteils eigenständig arbeitete, stand mir mein mich betreuender Kollege stets zur Seite. Nur, da er mich vom ersten Tag an sehr intensiv einarbeitete und mir bis in kleinste Details den damaligen bereits sehr komplexen Projektstand über mehrere Wochen nahebrachte, konnte ich zunehmend hilfreichere Experimente gestalten.

2.2 Aufsetzen einer kleinen Studie zum Zwecke der Prüfung einer prädiktiven Eye-Tracking-KI

Meine zweite Tätigkeit wurde mir von einer der Führungskräfte des Unternehmens aufgetragen, welche Material für eine Präsentation für Konferenzen und interne Zwecke anforderte. Da ein Verständnis darüber bestand, dass meine Mithilfe am Entwicklungsprojekt Vorrang hatte, durfte ich mich nach eigenem Ermessen immer wieder in meiner neben den Hauptaufgaben verbleibenden Zeit dieser Tätigkeit widmen und konnte bis zum Ende des Praktikums das geforderte Material bereitstellen.

Konkret ging es um einen möglichen Konkurrenten, welcher behauptete, Eye-Tracking akkurat prädizieren zu können. Hierfür ist es hilfreich zu verstehen, in welcher Form Eye-Tracking-Daten anfallen und was im Allgemeinen unter Prädiktionen dieser verstanden wird. Bei einem Eye-Tracking entstehen in aller Regel Raum-Koordinaten-Daten mit Zeitstempeln. Diese entsprechen normalerweise zwei räumlichen Dimensionen und versuchen zu dokumentieren, wo auf einem Bildschirm ein Nutzer wann hingeguckt hat. Da Daten in dieser Form aber von sehr vielen Faktoren – vor allem auch vom vorliegendem Stimulus – stark beeinflusst werden und sich bei Veränderungen der Versuchsbedingungen ändern, ist es eine offene Frage, ob dieses Problem überhaupt geeignet ist, um mit Hilfe von maschinellem Lernen genaue Prädiktionen vornehmen zu können. Ob bei gängigen Ansätzen der künstlichen Intelligenz beispielsweise kulturelle, soziale und biologische Einflüsse in die Wahrnehmung des Menschen angemessen einfließen können, ist eine dieser Fragen.

Der Hauptantrieb, aus dem dennoch mehrere Unternehmen versuchen menschliche Wahrnehmung auf diese Weise vorherzusagen, ist, dass Eye-Tracking-Studien wesentlich teurer in der Durchführung sind, als Stimuli von einem Algorithmus auf das vermeintliche Ergebnis einer Eye-Tracking-Studie untersuchen zu lassen.

Um trotz der schwierigen Herausforderungen eine gute Prädiktion menschlichen Sehens zu bewerkstelligen, versuchen diese Unternehmen in der Regel Paare von je einem Stimulus und einer „Ground-Truth“ bestehend aus jeweils einer sogenannten „Heatmap“ eines echten Eye-Trackings auf geeignete Weise als Trainingsdaten in ein geeignetes neuronales Netzwerk zu füttern, sodass dieses irgendwann – so die Theorie – lernt anhand von künftig präsentierten Stimuli deren bei einer repräsentativen Studiengruppe von (entsprechend sozialisierten) Menschen ausgelöste Fixpunkte ihrer Blicke auf dem Stimulus in Form von Heatmaps akkurat zu prädizieren. Diese Heatmaps sind nichts anderes als die zugrundeliegenden Stimuli, denen jeweils die tatsächlichen oder prädizierten Fixpunkte der Studienprobanden auf eine aggregierte Weise, d. h. in einem Bild, visuell überlagert sind. Stellen auf dem Stimulus, denen viel Aufmerksamkeit geschenkt wurde (oder dies nur vorhergesagt wurde) erscheinen so gerötet, während andere Stellen mit abnehmender

Aktivität entsprechend gelb, grün oder ohne Überlagerung erscheinen.
Da bereits die Länge des Betrachtens der Probanden die aus echten Eye-Trackings resultierenden Heatmaps entscheidend beeinflusst, beschränken sich Unternehmen, die prädizierende Ansätze verfolgen oftmals auf eine bestimmte Zeit, in welcher ein Stimulus sichtbar war – z. B. 500 ms.
Dies ist aber bei weitem nicht die einzige Quelle für Probleme beim Trainieren solcher Algorithmen. Kulturelle, soziale, biologische und andere Einflüsse, assoziieren gewisse Bildelemente wie z. B. Texte, Symbole, berühmte Personen oder Gebäude und selbst völlig gewöhnliche Gegenstände, Tiere und andere Eindrücke mit ganz bestimmten Reaktionen, welche durch die möglichen Kombinationen von Text- und Bildelementen quasi unendliche Feinheiten zulassen.

Ein Algorithmus, welcher eine akkurate Prädiktion menschlicher Wahrnehmung zulässt, käme aus diesem Grund – so habe ich in dem Material für die Präsentationen argumentiert – einer perfekten Kopie eines Menschen gleich. Alleine um nur die Möglichkeiten von Textelementen in Werbung genüge zu tun, müsste die KI in der Lage sein zu wissen, was die Reaktion (in Form von Fixpunkten ihrer Blicke auf dem Stimulus) einer repräsentativen Menschengruppe auf Sätze wie: „Schauen Sie nicht nach links oben im Bild, außer sie könnten sich vorstellen vegan zu leben und sind Brillenträger.“, welcher mit ganz bestimmtem Font, bestimmter Größe und Position auf dem Stimulus und mit bestimmten anderen Elementen präsentiert wird, sein wird.

Natürlich könnte man argumentieren – und diese Unternehmen tun dies auch – dass solche Beispiele konstruiert sind und Werbungen diese schier unendliche Kapazität an potentieller Komplexität in den meisten Fällen keineswegs ausreizen, sodass dennoch für viele Stimuli akkurate Prädiktionen abgegeben werden können. Aus intensiven Tests zumindest des mir vorgelegten Produkts konnte ich diese Behauptungen zumindest teilweise für das konkrete Produkt in Frage stellen.

Hierfür benutzte ich Eye Squares Premium-Account (welcher jährlich tausende Euros kostet, also als Enterprise-Lösung vermarktet wird) bei diesem Unternehmen, um dutzende Stimuli prädizieren zu lassen und verglich diese Ergebnisse mit echten Eye-Trackings, welche ich mit einer kleinen Studiengruppe von ca. $n = 10$ intern mit Mitarbeitern in einem der Laboratorien erhob. Verwendete Stimuli bestanden sowohl aus Videos als auch aus Bildern. Ein Muster, welches mir bei den prädizierten Heatmaps nach kurzer Zeit auffiel, war, dass fast immer der Kamera-Fokus des Bildes rot überlagert war, also vorhergesagt wurde, dass Menschen hierhin ihre Aufmerksamkeit richten würden. Des Weiteren war ein starker Bias hin zu Gesichtern – ob menschlich oder von Tieren – zu erkennen. Auch Schriftzüge konnten von diesem Algorithmus ab einer bestimmten Größe und Deutlichkeit zuverlässig erkannt und es konnte ihnen prädizierte Aufmerksamkeit zugewiesen werden.

Im theoretischen Teil meiner Abgabe habe ich argumentiert (viel davon geschah im direkten Gespräch mit der Führungsperson), dass diese Bias höchstwahrscheinlich daher rührten, dass in den Trainingsdaten, welche dem neuronalen Netzwerk, welches trainiert wurde, um dieses Modell zu erhalten, Texte, Bildabschnitte im Kamerafokus und Gesichter mit einer Heatmap rot markiert wurden, da Menschen tendieren sich diese Dinge anzusehen.

Dies führt zu einem paradox wirkenden Phänomen: auf den ersten Blick sind prädizierte Heatmaps auf Stimuli von typischen Werbungen selbst fürs durch echte Eye-Tracking-Heatmaps geschulte Auge unmittelbar glaubwürdig. Dies liegt aber gerade daran, dass die meisten Werbungen – zumindest die meisten statischen Werbebilder – einen oder mehrere klare Fokuspunkte enthalten, welche natürlich auch angeguckt werden. Das neuronale Netz lernt bei solchen Trainings von Heatmaps also scheinbar eher typische, einfach zu lernende Muster, als ein Imitieren menschlicher Wahrnehmung.

Um diese Vermutung zu untermauern, prüfte ich in meiner kleinen Studie bewusst Bilder, bei denen für eine akkurate Heatmap-Prädiktion mehr gebraucht wird, als einer kleinen Zahl von grundlegenden Mustern zu folgen. Von mir den Studienteilnehmern präsentierte Stimuli enthielten deshalb z. B. Bilder der Skyline von Kairo, in welcher typischerweise die Pyramiden von Gizeh im Hintergrund thronen. Die Pyramiden sind in der Regel sehr prägnant abgebildet, aber quasi nie im Bildfokus oder der Bild-Mitte, da sie im Horizont auftauchen und entsprechend weit entfernt sind. Erschwerend kommt hinzu, dass die Pyramiden sich meist nicht besonders stark farblich vom Hintergrund abheben und keine besonderen Texturen haben, welche die KI als interessant wahrnehmen würde. Dies resultierte in einer Gegenüberstellung der KI-generierten Heatmaps, auf welchen die Prädiktion menschlicher Wahrnehmung auf Kairos Plattenbauten im Bildmittelpunkt lag, während die Ground-Truth, d. h. die Eye-Tracking-Heatmaps, wenig überraschend einen Großteil der Aufmerksamkeit auf den Pyramiden sah.

Durch ähnlich plakative und auch subtilere andere Beispiele konnte ich meine Argumente zur Unzulänglichkeit der prädiktiven KI des Konkurrenz-Unternehmens untermauern und Material für künftige Präsentationen liefern.

Es ist auch erwähnenswert, dass sich die Meinungen über die Güte solcher KIs spalten. Ich habe in dem Material und hier erneut meine mit der Zeit gebildete ablehnende Meinung zum jetzigen Stand dieser Technologie dargelegt und begründet. Würde es nicht andere Meinungen geben, würde es nicht mehrere Unternehmen mit solchen Ansätzen geben. Auch möchte ich betonen, dass prädiktives Eye-Tracking oft nicht das einzige ist, was von solchen Anbietern

versprochen wird. Vermeintliche Schätzungen abstrakter Konzepte wie visueller Prägnanz oder Komplexität eines Bildes werden auch teilweise in diesem Kontext angeboten und diesen stehe ich weniger skeptisch gegenüber.

3 Fazit und Ausblick

Während meiner Praktikumszeit durfte ich weit gefächerte Einblicke in die Operationen der Eye Square gewinnen. Von theoretischen psychologischen Konzepten, welche innerhalb des Unternehmens als Leitfäden dienen, menschliche Aufmerksamkeit zu interpretieren, bis hin zu praktischen Anwendungen wie dem Trainieren von CNNs und Computer Vision-Algorithmen habe ich sehr viel in diversen Disziplinen lernen dürfen.

Von allen Aufgaben, denen ich mich widmen durfte, gefiel mir mit Abstand meine Arbeit an dem Innovationsprojekt und spezifisch alle Teile des Trainierens der neuronalen Netze – von der Datensammlung und -Aufbereitung bis hin zum Monitoring und dem Auswerten der Trainings – am meisten. Auch die beratende Funktion, welche ich zunehmend innerhalb unseres Teams und mit und für andere Stakeholder des Projektes einnehmen durfte, gab mir den Eindruck, mich sinnvoll an der Entwicklung des Produkts beteiligen zu können.

Da mir meine Praktikumszeit tatsächlich sehr viel Freude bereitet hat und ich mir darüber hinaus einen erfolgreichen Ausgang der Entwicklung des Produktes wünschte, welchen ich zu erreichen mithelfen können meinte und, da ich auch am Ende meiner Praktikumszeit das einzige Team-Mitglied war, welches sich intensiv mit den Prozessen der Trainingsdaten-Aufbereitung und des Trainings von Modellen mit diesen Daten befasst hatte, war ich sehr froh darüber von Eye Square als regulärer Mitarbeiter übernommen worden zu sein.
Die Entwicklung des Produktes ist Stand heute (18.07.2023) noch nicht vollkommen abgeschlossen. Es konnten aber große Fortschritte gemacht werden und sowohl unser Team, als auch das Management ist sehr zuversichtlich, dass wir in den nächsten Monaten einen marktfertigen Prototypen präsentieren werden können.

Bzgl. der Bereitstellung der Materialien für Vorträge der Führungsperson – meiner zweiten Aufgabe während der Praktikumszeit – war ich ebenso erfreut, dass diese Inhalte von der entsprechenden Person gut aufgenommen wurden und kurz nach Ende meines Praktikumsvertrages zum ersten Einsatz in einem Webinar kamen.

Über meine Erfahrungen mit Eye Square kann ich weitestgehend Positives berichten. Meine Kollegen standen mir stets hilfsbereit zur Seite. Das Arbeitsklima insgesamt ist sehr angenehm. Die Mitarbeiter werden vom Management gefordert, aber in der Regel nicht überfordert (was ich an der Handhabung mit Deadlines in dem Entwicklungsprojekt erleben durfte. Diese werden konsequent angestrebt. Es gibt aber auch stets Verständnis und Offenheit des Management, wenn neue Herausforderungen alte Pläne unpraktikabel machen). Die Work-Life-Balance ist ebenso hervorzuheben. Mehrere freie Extra-Tage im Jahr, sowie großzügiges Entgegenkommen des Arbeitgebers bei Home-Office oder Teilzeit-Regelungen bestärken die insgesamt offene Unternehmenskultur.

Abschließend bin ich sehr dankbar, dieses Praktikum gemacht zu haben und würde Eye Square als Arbeitgeber für Menschen, denen eine Work-Life-Balance wichtig ist und die gerne an spannenden technischen Aufgaben in einer überwiegend familiären, Start-Up ähnlichen Atmosphäre arbeiten wollen, weiterempfehlen.