Schlussbericht

(zu Nr. 3.1 BNBest-BMBF 98)

Zuwendungsempfänger:

Förderkennzeichen:

Leuphana Universität Lüneburg

16SV7514

Vorhabenbezeichnung:

Sensorische Erfassung von Motivationsindikatoren zur Steuerung von adaptiven Lerninhalten – SensoMot

Laufzeit des Vorhabens:

April 2016 - März 2019

A. Zusammenfassung des Vorhabens

A.1 Aufgabenstellung

Ziel des Projekts "SensoMot" war es, mit Hilfe von Sensordaten kritische motivationale Zustände zu erkennen. Durch die Ableitung passender Adaptionsmechanismen soll der Lernprozess so gesteuert werden, dass die Motivation der Lernenden unterstützt wird. Über sogenannte "Wearables" werden physiologische Daten der Lernenden erhoben, die z. B. auf Stress oder Langeweile hinweisen. Der Algorithmus der Lernsoftware passt daraufhin entsprechende Lernszenarien an. Es werden hierfür prototypische Lernszenarien für die universitäre Lehre für die Ingenieurwissenschaften am Beispiel "Nanotechnologie" sowie für die berufliche Fernlehre für die Technikerweiterbildung am Beispiel Maschinenbau entwickelt und evaluiert. Diese technische Möglichkeit zur Adaption der Lernszenarien sollte durch entsprechende Applikationen unter Berücksichtigung datenschutzrechtlicher Aspekte, möglichst schnell der Bildungspraxis zur Verfügung gestellt werden.

Durch "SensoMot" sollte es erstmalig möglich werden, motivationsbedingte Lernblockaden mit Hilfe von unaufdringlichen Sensoren frühzeitig zu erfassen und Lerninhalte daran anzupassen. Eine so erhöhte Lernmotivation könnte in vielen technologiebasierten Lehr-Lern-Szenarien zu größeren Lernerfolgen und niedrigeren Abbruchquoten führen.

A.2 Voraussetzungen

Das Vorhaben beruhte auf drei zentralen Forschungs- und Entwicklungsbereichen: der Anwendung von "Affective Computing", der Identifikation von Indikatorvariablen durch maschinelles Lernen und der Adaption von Lerninhalten mit Hilfe von Motivationsindikatoren. Die eigentliche Innovationsleistung sollte allerdings durch die direkte, transdisziplinäre Verzahnung der Bereiche zu einem integrierten Forschungs- und Entwicklungsprojekt entstehen.

Im Bereich "Affective Computing" sollte ein neues Verfahren zur Messung von körperlichen Zuständen auf Basis von klassischen "Wearables" berücksichtigt und kombiniert werden, um die nachfolgende Identifikation von Indikatorvariablen zu erleichtern.

Im Bereich "Identifikation von Indikatorvariablen" sollten aus der direkten sensorischen Erfassung von Affekten entsprechende motivationale Indikatoren abgeleitet werden, die eine Adaption der Lerninhalte ermöglichen, ohne dass der Lernende explizites metakognitives Steuerungswissen aufrufen muss und damit die Gefahr einer motivationalen Blockade durch die Aktivierung des linkshemisphärischen Intentionsgedächtnisses entsteht.

Im Bereich "Adaption" sollte ein Konzept für Adaptionsalgorithmen entwickelt und im CBA ItemBuilder System implementiert und validiert werden. Der CBA-ItemBuilder, der von Nagarro in enger Zusammenarbeit mit dem DIPF entwickelt wurde, spielt dabei eine zentrale Rolle für die technische Umsetzung, Validierung und Verwertung. Der CBA-ItemBuilder ist ein grafischer Editor für die Gestaltung von komplexen Lern- und Aufgabeninhalten in wissensintensiven Domänen (Rölke, 2012), gleichzeitig aber auch eine Web-basierte Ablaufumgebung für diese Inhalte.

Das Projektkonsortium aus den 6 Partnern war so aufgestellt, dass sich die Expertise der beteiligten Partner entsprechend ergänzen:

- DIPF Zentrum für technologiebasiertes Assessment (TBA) am Deutschen Institut für Internationale Pädagogische Forschung (DIPF – Leibniz-Institut für Bildungsforschung und Bildungsinformation
 Rostocker Straße 6, 60323 Frankfurt am Main) für die wissenschaftliche
 Projektkoordination und Schulung.
- Eckert-Schulen (Fernlehrinstitut Dr. Robert Eckert GmbH, Dr.-Robert-Eckert-Straße 3,
 93128 Regenstauf) für die Konzeption und Evaluation und Validierung der Prototypen im Bereich der beruflichen Weiterbildung durch Fernlehre.
- Leuphana Universität Lüneburg Fachgebiet Machine Learning (Leuphana Universität Lüneburg, Scharnhorststr. 1, 21335 Lüneburg) für die Mustererkennung auf Basis von statistischem Maschinellen Lernen und Data-Mining sowie der Vorhersage von komplexen Variablenverbünden unter Berücksichtigung der zugrundeliegenden Korrelationsstrukturen.
- Medical School Hamburg Forschungsbereich Kognitions-, Motivations- und Emotionspsychologie an der Medical School Hamburg (MSH Medical School Hamburg GmbH, Am Kaiserkai 1, 20457 Hamburg) für die Ermittlung der Motivationsindikatoren und Ableitung von Adaptionsalgorithmen.
- TU Ilmenau Institut für Medientechnik, Fachgebiet Medienproduktion (Technische Universität Ilmenau, Ehrenbergstraße 29, 98693 Ilmenau) für die Konzeption und Evaluation der Lernszenarien im universitären ingenieurwissenschaftlichen Kontext sowie Medientechnik und Mensch-Technik-Interaktion.
- Nagarro GmbH IT-Dienstleister und Entwickler der "CBA-ItemBuilder" Plattform (Nagarro GmbH. Baierbrunner Straße 15, 80638 München) als Konsortiumsführer verantwortlich für die Projektleitung, Erweiterung und Optimierung des CBA-ItemBuilders.

A.3 Planung und Ablauf des Vorhabens

Die Planung des Vorhabens erfolgte auf Basis des Meilensteinplans, der kontinuierlich fortgeschrieben wurde. In 2-wöchentlichen Projektmeetings über Web wurde der Projektfortschritt aktualisiert und die Aktivitäten der Partner koordiniert (Projektdokumentation: 76 Protokolle). 1-2 tägige Projekttreffen fanden zweimal im Jahr statt (Projektdokumentation: 7 Protokolle mit Anlagen/Präsentationen).

A.3.1 Auswahl "Wearable " Sensorprodukte und Technologien

In der ersten Projektphase wurden geeignete "Wearables" evaluiert. Die Evaluierung der Sensorprodukte zeigte, dass es auf dem Markt nur wenige Produkte gibt, die von den Kosten her im angestrebten Bereich bleiben und bei brauchbarem Bedienkomfort auch verwertbare Messergebnisse liefern. Die folgenden Einschränkungen waren bei den untersuchten Wearables festzustellen:

- Herstellerspezifische Datenaggregationen, so dass die Primärdatenquellen nicht identifizierbar waren.
- Echtzeit der Messungen war nicht immer gegeben.
- Synchronisation der Daten mit Cloud-Plattformen, die datenschutzrechtlich unbedenklich sind.

Aufgrund der eingeschränkten Auswahl an geeigneten Sensorprodukten wurden bereits 2019 auch EEG-Systeme (Elektroenzephalografie) mit in die Evaluierung aufgenommen. Zudem waren diese inzwischen auch zu erschwinglichen Preisen und guter Qualität auf dem Markt verfügbar.

In den Studien wurde zusammenfassend Folgendes deutlich:

- Die Evaluierung zeigte, dass die Sensordaten von am Handgelenk getragenen klassischen sogenannten "Wearable Devices" (Herzrate, Hauttemperatur, Bewegungsdaten) keine unmittelbar verwertbaren Daten liefern (Studie M1), aus denen sich Motivationsindikatoren ableiten lassen. Bei der Hautleitfähigkeit gibt es Indizien für Zusammenhänge zum Motivationszustand. Die Bewegungsdaten hingegen könnten für andere Zielgruppen (z. B. Kinder) relevant sein.
- Die neue Kategorie der "Wearable Headsets" zur Erfassung der Gehirnaktivität erwies sich im Vergleich zu Wearable am Handgelenk geeigneter. Hier konnten wir in 2017 konkrete Ansatzpunkte finden, die in einer weiteren Studie M3 in 2018 verifiziert werden sollten.

A.3.2 Studien zur Ermittlung von Motivationsindikatoren

In der ersten Studie M1, welche durch die Partner "Medical School Hamburg" (MSH) und "Universität Leuphana" durchgeführt wurde, hat sich zunächst nur beim EEG Headset "Emotiv Insight" (über Elektroenzephalografie) ein schwacher Effekt bei der Ermittlung von einem Motivationsindikator gezeigt. Bei klassischen Wearables am Handgelenk konnten keine Effekte nachgewiesen werden.

Die zweite Studie M2, welche ebenfalls durch die Partner "Medical School Hamburg" (MSH) und "Universität Leuphana" durchgeführt wurde, diesmal mit einem komplexen Problemlöseszenario

konnte keine motivationalen Schwankungen induzieren, weil die Probanden ihre Strategie in der zweiten Hälfte der Problembearbeitung nicht mehr verändert haben. Die hieraus resultierenden Daten waren deshalb nicht geeignet, um Motivationsindikatoren zu validieren.

Nach den Studien M1 und M2 wurde von Juni bis August 2018 die Studie M3 (90 Probanden) durchgeführt, mit dem Ziel, die Ergebnisse der Studie M1 zu validieren und zu erweitern. Die Probanden trugen das klinische EEG-System actiCAP snap active electrode system mit dem Zusatzgerät für die Hautleitfähigkeit BrainAmp ExG amplifier (siehe https://www.brainproducts.com/), um Gehirnaktivitäten und Hautleitfähigkeit zu messen. Dabei wurden mehrere Prozessmaße kombiniert: zum einen die psychologische Beurteilung über Experience Sampling während des Lernprozesses (im 270s Rhythmus); zum anderen die aposteriori Bewertung der eigenen Video-aufgezeichneten Lerneinheit durch den Probanden (in 15s Intervallen) – Retrospective Affect Judgment Protocol (Rosenberg & Ekman, 1994). In der Studie M3 wurden Daten auf drei verschiedenen Zeitebenen mit physiologischen Messinstrumenten und Selbstberichtverfahren gesammelt. Durch die Triangulation der verschiedenen Datenquellen wird eine außergewöhnlich hohe Datenqualität erreicht, insbesondere die statistische Power ist durch die Messwiederholungen sehr groß.

Die Auswertung der M3 Daten konnte aufgrund der Komplexität bis zum Projektende noch nicht vollständig abgeschlossen werden. Es zeigt sich allerdings, dass affektive Zustände durch die EEG-Daten signifikant vorhergesagt werden können und die Beurteilung von Lerneinheiten durch die Hautleitfähigkeit. Diese Ergebnisse markieren einen besonderen Fortschritt in der Bildungsforschung. Bisherige Studien konnten physiologische Daten ins Verhältnis zu besonderen Lernereignissen setzen, die zum Teil experimentell induziert wurden. Aber es gibt bisher kaum Studien, die affektive Lernprozesse mit Hilfe von physiologischen Daten in natürlichen "Lernsettings" abgebildet haben.

A.3.3 Konzeption Adaptionsalgorithmen und adaptiver Lerninhalte

Das Konzept für Adaptionsalgorithmen wurde 2017 gemeinsam entwickelt und basiert auf dem *String of Pearls* Modell (*Majewski*, 2003).

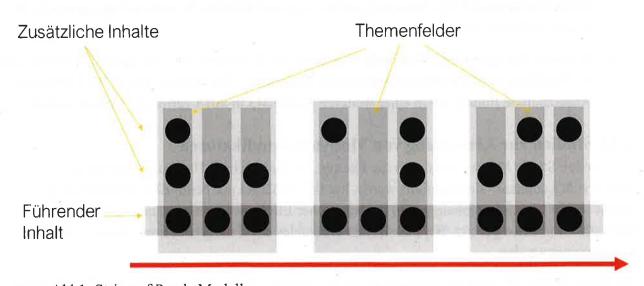


Abb1: String of Pearls Modell

Die konkrete Umsetzung soll Motivation erhalten und steigern. Insbesondere ist das Modell auf ein Absinken der motivationalen Indikatoren "Interesse" und "Kompetenzerwartung" vorbereitet. Es schlägt dann passende Inhaltssegmente vor, die geeignet sind, Interesse und Kompetenzerwartung wieder zu steigern. Die alternativen Inhaltssegmente führen wieder zum Hauptlernpfad zurück.

Das CBA-ItemBuilder System wurde in 2017 auf die Adaption vorbereitet und um Zusatzfunktionalität erweitert, u.a. um spezielle interaktive Lerninhalte (JavaScript) zu unterstützen. Die vorgesehenen Lerninhalte von den Partnern "Eckert-Schulen" und "TU Ilmenau" wurden dafür entsprechend aufbereitet und in 2018 im CBA-ItemBuilder umgesetzt.

In 2018 wurde unter Federführung des DIPF (Leibniz-Institut für Bildungsforschung und Bildungsinformation) das Adaptionsmodell (basierend auf *String of Pearls* Modell) verfeinert und in der Folge als praktisch einsetzbares System in das CBA-ItemBuilder System integriert. Das adaptive e-Learning-System erkennt sinkende Motivation aus Messdaten physiologischer Sensoren und schlägt alternative motivationsförderliche Inhalte vor. Das dazu entwickelte Sensor-Kit ist als eine generische Schnittstelle zwischen den physiologischen Sensoren und der Technologie-unterstützten Lernplattform – hier CBA-ItemBuilder – zu sehen. Exemplarisch wurde das Sensor-Kit für das kommerzielle EEG-Headset "Emotiv Insight" implementiert unter Nutzung des EmotivPro Clients, der die Rohdaten zur Weiterverarbeitung bereitstellt, aber auch vom Emotiv berechnete Leistungsmetriken (Mental Performance Metrics).

Basierend auf dem Adaptionsmodell hat der Partner "TU Ilmenau" Lerninhalte für die universitäre Lehre im Bereich "Mikro- und Nanotechnologie" entwickelt; der Partner "Eckert Schulen" für die berufliche Fernlehre in der Technikerweiterbildung im "Maschinenbau". Dabei wurden motivationsförderliche Inhalte und Darstellungsformen konzipiert und umgesetzt, die den Lernenden bei sinkender Motivation vorgeschlagen werden. Beide Lerninhalte wurden zur besseren Vergleichbarkeit angeglichen und in Vor-Tests validiert (als "thinking aloud" Studie mit Einzelbetreuung). Die finale Systemevaluation und Studien wurde zum Projektende abgeschlossen: bei der TU Ilmenau mit dem Emotiv EPOC+ als EEG-Headset als Laborstudie mit Studierenden, bei den Eckert Schulen ohne EEG-Headset als Klassenverband im Computerraum.

A.3.4 Ergebnisse und Zusammenfassung

Aufgrund der Marktsituation von "Wearables" und der Ergebnisse der ersten Untersuchungen musste das Ziel aufgegeben werden, ausschließlich auf marktübliche "klassische Wearables" zu setzen. Der Fokus wurde deswegen auf EEG Sensoren gelegt, die nicht dem Prädikat "Wearable" genügen. Entsprechende Publikationen sind aktuell in Vorbereitung (Martens, Niemann & Dick, submitted; Niemann, Dick & Martens, in preparation).

Die Ziele des Vorhabens konnten, trotz der Verzögerungen und Schwierigkeiten mit klassischen "Wearables" am Anfang des Projekts, nahezu alle erreicht werden: Konzeption und Finalisierung des Adaptionsmodells, Implementierung der Adaption im CBA-ItemBuilder durch Nagarro, Entwicklung der Beispiel-Lerneinheiten mit Adaption im CBA-ItemBuilder für die TU Ilmenau und die Eckert Schulen, Definition eines generischen Sensor-Kits und prototypische Entwicklung einer Implementierung zum "Anschluss" von Sensoren an die Lernumgebung. Lediglich die Auswertung der Ergebnisse der EEG-Daten ab September 2018 hat aufgrund der Komplexität und Datenmengen mehr Zeit als geplant in Anspruch genommen und ist auch noch nicht abgeschlossen. Die

Berücksichtigung von Motivationszuständen haben wir übergangsweise über "Selbsteinschätzung" vorgenommen.

Die Lernumgebung CBA-ItemBuilder mit Sensor-Kit und EEG Headset "Emotiv Insight" sowie adaptiven Lerninhalten wurden Ende 2018 auf der Informationstour "Erfahrbares Lernen an den drei Standorten (München/LMU Universität, Bremen/Universität Bremen, Leipzig/Hochschule für Technik, Wirtschaft und Kultur) der Öffentlichkeit vorgestellt.

A.4 Wissenschaftlicher und technischer Stand

In einem ähnlichen Ansatz wurde versucht "Stress" mit Hilfe kommerzieller "Wearables", die am Handgelenk getragen werden, zu erkennen (Arriba-Pérez, 2019). Dabei konnte experimentell nachgewiesen werden, dass eine Vorhersage von "Stress" aus Sensorwerten möglich ist, jedoch mit Einschränkungen in der Verfügbarkeit geeigneter Wearables mit relevanten Sensordaten (speziell Hautleitwiderstand, Hauttemperatur) und Einschränkungen im Tragekomfort, da bei lockerer Befestigung die Sensorwerte verfälscht werden.

Eine andere Arbeit (Xu, 2017) hat in einer systematischen Literaturrecherche die Möglichkeiten von portablen EEG-Geräten im Bildungsbereich ausgewertet. Dabei wurden als limitierend signifikante Messfehler und der geringe Tragekomfort festgehalten.

Wir sehen weiterhin einen steigenden Markt für Wearables und Gesundheits-Apps (z.B. Apple Watch Series 3, vermarktet seit 9/2017) und sehen einen starken Trend aus Sensordaten mehr und mehr Rückschlüsse auf Gesundheitszustände abzuleiten.

In der Pädagogischen Psychologie und der Bildungsforschung ist ein deutlicher Trend erkennbar, motivationale und affektive Lernprozesse mit Hilfe von physiologischen Daten (EEG, EDA) sowie Verhaltensdaten (Eye Tracking) zu untersuchen (siehe etwa aktuelle Schwerpunkthefte in "Frontiers of Psychology" sowie "Frontline Learning Research"). Hier sind in Kürze weitere wissenschaftliche Durchbrüche zu erwarten, die dann auch für die Mikroadaptation von Lernumgebungen genutzt werden könnten. Solche Erkenntnisse könnten dann auch im CBA-ItemBuilder sehr einfach zum Einsatz kommen.

A.4.1 Wissenschaftlicher Stand, an den angeknüpft wurde

In theoretischer Hinsicht baute das SensoMot-Projekt in interdisziplinärer Absicht auf drei Entwicklungslinien auf, die hier systematisch zusammengebracht wurden: In der Anwendung von "Affective Computing", der Identifikation von Indikatorvariablen durch maschinelles Lernen und der Adaptation von Lerninhalten mit Hilfe von Motivationsindikatoren.

Im Bereich des Affective Computing gibt es ein besonderes Augenmerk auf die Erfassung von Sensordaten. Per Elektrokardiogramm (EKG) kann aufgrund von Änderungen der Herzfrequenz auf die Stimmung geschlossenen zu können (Van den Broek, 2013). Änderungen der Transpiration können mittels galvanischer Hautreaktion (GHR) bestimmt werden (Handri et al., 2010). Üblich ist auch die Kombination von Verfahren, zum Beispiel GHR mit der Körpertemperatur (Shivakumar, 2011). (Xu, 2017) hat in einer systematischen Literaturrecherche die Möglichkeiten von portablen EEG-Geräten im Bildungsbereich ausgewertet.

Im Bereich der Identifikation der von Indikatorvariablen ermöglichen Modelle aus dem Bereich des maschinellen Lernens eine Reduktion und Kombination vieler, möglicherweise redundanter Merkmale aus Sensordatenströmen. L1-Norm-Regularisierungsverfahren und Multi-Kernel-Lernverfahren ermöglichen eine Reduktion der Merkmale (Bach, Lanckriet, & Jordan, 2004), Gradient Boosting (Mason et al, 1999) und allgemeine Deep Neural Network (Goodfellow et. al. 2016) Methoden ermöglichen beliebige nicht-lineare Kombinationen von Merkmalen, und Sequenzmodelle wie Rekursive Neuronale Netzwerke (Hochreiter & Schmidhuber, 1997) ermöglichen Vorhersagen zeitlich abhängigen Variablen.

Im Bereich des selbstregulierten Lernens wurden motivationale Prozesse in den letzten Jahren stärker in den Fokus gerückt (e.g., Pintrich, 1999; Wolters, 2003) und um motivationale Konzepte erweitert, etwa Emotionen und Selbsteinschätzung. Diese Konzepte werden begleitet von verschiedenen motivationalen Regulationsstrategien wie Steigerung des situativen Interesses (Schwinger, Steinmayr, & Spinath, 2012). Allerdings kann hier angemerkt werden, dass es nur sehr wenige theoretische Ansätze gibt, die motivationale Regulationsstrategien systematisch in eine Theorie des selbstregulierten Lernens integrieren.

A.5 Zusammenarbeit mit anderen Stellen

Eine formale Zusammenarbeit mit anderen Stellen war im Projekt nicht vorgesehen und hat sich auch innerhalb der BMBF-Förderprogramms "Erfahrbares Lernen" mit anderen Projekten – auch im Rahmen von Vernetzungstreffen – nicht ergeben, im Wesentlichen wegen unterschiedlicher Inhalte. Selbst beim ähnlich ausgerichteten LISA-Projekt (Yu, 2016) (Learning Analytics für sensorbasiertes adaptives Lernen) des gleichen Förderprogramms lag der Schwerpunkt auf der Eigenproduktion eines Wearables, mit den folgenden Parametern: Hauttemperatur (TEMP), Hautwiderstand (EDA), Raumluft (TVOC), CO2-Sättigung (CO2), Sauerstoffsättigung (PPG), Puls (HR). Der Lern-Companion (ein Tablet mit freiem Android) nimmt die Daten auf und vergleicht mit Werten vom Vortag. Eine Berechnung von Motivationsindikatoren fand hier nach unserem Verständnis nicht statt. Es gab auch keine Adaption, der Lernbegleiter ist von den Lerninhalten völlig unabhängig.

Informell haben wir auf verschiedenen Ebenen Erfahrungen von anderen Gruppen und Partnern in unsere Arbeiten mit einfließen lassen.

B. Eingehende Darstellung des Vorhabens

B.1 Ergebnisse

Die Leuphana Universität war im Projekt SensoMot zuständig für das Arbeitspaket 4: Mustererkennung.

In einer durch die Medical School Hamburg durchgeführten Laborstudie (M1) sollten Studierende Inhalte aus ihrem Studium lernen und ihre motivationalen Zustände währenddessen mit dem Fragebogen via Experience Sampling erfassen. Außerdem wurde ein Kurzfragebogen erfasst. Die physiologischen Messwerte wurden in der M1 mit Hilfe von Wearables erhoben, wobei bei auf dem Kopf getragenen Wearables nach mangelhaften Datenqualitäten eines anderen Produkts das Emotiv Insight verwendet wurde. Zur Auswertung der Daten der M1 wurde eine Datenpipeline implementiert, die u.a. die Erkennung von verrauschten bzw. artefaktbehafteten Daten beinhaltet

und eine große Menge von Merkmalen aus den Datenströmen der verwendeten Sensoren erstellt. Dafür wurde u.a. ein Sliding-Window-Ansatz gewählt, der Merkmale in zeitlichen lokalen Umgebungen von Vorhersagezeitpunkten berechnet. Mithilfe dieser Merkmale wurden mehrere lineare und nicht-lineare Machine-Learning-Modelle zur Indikatorvorhersage implementiert und kreuzvalidiert evaluiert. Eine automatisierte Merkmalsselektion wurde für lineare Modelle durch eine 11-Regularisierung durchgeführt. Unter den nicht-linearen Vorhersagemodellen hat sich der Gradient-Boosting-Ansatz (Mason et. al., 1999) als am zielführendsten erwiesen, wodurch auf eine weitere Verwendung etwa von Multi-Kernel-Learning-Methoden (Bach et. al., 2004) verzichtet wurde. Die Auswertung der Daten der M1 mit diesen Modellen lieferte erste positive Ergebnisse, so konnte ein Item des Fragebogens mit EEG-Daten vorhergesagt werden. Der Vergleich mit einer uninformierten Baseline bestätigt die Güte der Vorhersage auf den verfügbaren Daten, allerdings konnte bezüglich der Generalisierbarkeit der Vorhersage aufgrund der mangelhaften Datenqualität des Wearables keine verlässliche Aussage getroffen werden (Bei einem beträchtlichen Teil der Proband innen kam es zu Datenausfällen). Eine gemeinsame Vorhersage mehrerer Indikatoren durch strukturierte Vorhersagemodelle (Tsochantaridis et. al., 2005) brachte ebenfalls keine Verbesserung.

In der von der MSH durchgeführten Studie M2 wurde versucht, diese Ergebnisse auf einen anderen Lernkontext zu erweitern. Hierfür wurde als Lerninhalt eine Lernumgebung konstruiert, die komplexes Problemlösen nach Dörner erforderte. Die bei der M1 beobachteten Ergebnisse ließen sich in diesem Kontext nicht replizieren.

Abweichend vom ursprünglichen Plan für die Studie M3 wurde daraufhin von der Medical School Hamburg eine aufwändige Laborstudie mit einem professionellen Laborgerät für die Messung von EEG und Hautleitfähigkeit (EDA) durchgeführt. Es sollten dabei Erkenntnisse mit qualitativ hochwertigeren Geräten gewonnen werden, die damit prinzipiell auch auf qualitativ niedrigwertigere Geräte übertragen werden können. Hier kam zusätzlich zum Experience Sampling das Retrospective Affect Judgment Protocol (RAJP) zum Einsatz, welches es ermöglichte, eine bedeutend größere Anzahl von Motivationsindikator-Labels zu sammeln. Die Datenauswertung der Studie M3 konnte aufgrund der zeitlichen Verzögerung der Erhebung und der erhöhten Komplexität der Datenströme aus dem klinischen EEG nicht vollständig abgeschlossen werden. Aufgrund der besseren Datenlage durch höhere Erhebungsfrequenzen wurde die Vorhersage der Zielvariablen aus dem RAJP-Protokoll priorisiert untersucht. Es wurde eine an die deutlich komplexeren Datenströme des professionellen Laborgeräts angepasste Datenpipeline erstellt, die eine diverse Menge von Merkmalsvektoren erstellt und untersucht. Die entwickelten kreuzvalidierten Vorhersagemodelle konnten die Zielvariablen aus EEG-Daten mit hoher Genauigkeit vorhersagen und es wurde gezeigt, dass die erzielten Genauigkeiten signifikant besser sind als uninformierte Baselinemethoden. Damit konnte gezeigt werden, dass der motivational-emotionale Zustand von Menschen während des Lernens mit einem prädiktiven Machine Learning Modell vorhersagbar ist. Eine weitere Verbesserung dieser Ergebnisse mit einem rekursiven Deep Learning Modell (Hochreiter & Schmidhuber, 1997) konnte dagegen nicht erzielt werden.

Die für das Teilprojekt Mustererkennung vorgesehenen Ziele konnten also zum großen Teil erreicht werden. Es wurden aus Datenströmen physiologischer Messgeräte Merkmale und Modelle

entwickelt, die motivationale Zustände von Menschen in einer Lernumgebung vorhersagen können. Es konnten also Zusammenhänge zwischen gesammelten Sensordaten und den gewünschten Zielgrößen (Motivationsindikatoren) identifiziert werden.

Die dazu verwendeten Sensordaten wurden mit einem professionellen klinischen Messgerät erhoben. Aufgrund der unzureichenden Güte der Vorhersagen mit den Wearables aus den Studien M1 und M2 wurde auf Integration der Algorithmen in den Itembuilder in Zusammenarbeit mit Nagarro allerdings verzichtet, da eine direkte Anwendbarkeit auf die Steuerung von adaptiven Lerninhalten so nicht gegeben ist.

B.2 Aktivitäten

Position 812: Beschäftigte E12-E14, Ist-Betrag 133.728€. Der wissenschaftliche Mitarbeiter Dr. Uwe Dick war für den Förderzeitraum für die Datenaufbereitung und Datenauswertung des Projekts zuständig.

Position 846: Dienstreisen. Ist-Betrag 1119,16€. Halbjährliche Treffen der Projektpartner, außerdem Beteiligung an der Informationstour "Erfahrbares Lernen" in Bremen.

B.3 Nutzen und Verwertbarkeit

Die Vorhersage von motivational-emotionalen Zuständen beim Lernen durch EEG-Daten markieren einen besonderen Fortschritt in der Bildungsforschung. Bei bisher bekannten Arbeiten wird die Vorhersage durch von außen manipulierte Lernereignisse systematisch verbessert. Eine solches wissenschaftliches Vorgehen verhindert allerdings die Übertragbarkeit auf unbeeinflusste Lernsituationen. Mit den hier erzielten Vorhersagen wird es in absehbarer Zukunft möglich sein, Mikroadaptivität in Lernumgebungen durch die automatische Erfassung motivational-emotionaler Zustände herzustellen und systematisch zu verbessern. Für den praktischen Einsatz in Schule und Hochschule muss dafür aber die Datenqualität von finanzierbaren und mobilen Wearables weiter verbessert werden. Die Vorhersagekraft kann durch den Einbezug von Verhaltensbeobachtungen (z.B. Tastatureingaben, Gesichtsausdrücke, Augenbewegung) weiter verbessert werden.

Ergebnisse zu den durchgeführten Studien werden veröffentlicht. Die entwickelten Merkmalsextraktoren und Modell-Lern-Protokolle sollen im Zuge der wissenschaftlichen Veröffentlichungen ebenfalls der Öffentlichkeit zugänglich gemacht werden. Nachfolgende Studien können so auf gewonnenen Erkenntnissen im Bereich der Datenauswertung und Ableitbarkeit von Indikatoren aufbauen und entwickelten Programmcode direkt verwenden

B.4 Bekannt gewordener Fortschritt

In einem ähnlichen Ansatz wurde versucht "Stress" mit Hilfe kommerzieller "Wearables", die am Handgelenk getragen werden, zu erkennen (Arriba-Pérez, 2019). Dabei konnte experimentell nachgewiesen werden, dass eine Vorhersage von "Stress" aus Sensorwerten möglich ist, jedoch mit Einschränkungen in der Verfügbarkeit geeigneter Wearables mit relevanten Sensordaten (speziell Hautleitwiderstand, Hauttemperatur) und Einschränkungen im Tragekomfort, da bei lockerer Befestigung die Sensorwerte verfälscht werden.

B.5 Geplante Veröffentlichungen und Konferenzbeiträge

Teilergebnisse der durchgeführten Studien werden veröffentlicht. Eine erste Veröffentlichung zur M1 ist bereits eingereicht (Martens, Niemann & Dick, submitted). Eine weitere Veröffentlichung zur M3 ist kurz vor der Einreichung (Niemann, Dick & Martens, in preparation).

Ergebnisse des Teilprojekts wurden auf den folgenden Konferenzen vorgestellt:

Oliver Schneider, Thomas Martens, Mathias Bauer, Alexandra Ott-Kroner, Uwe Dick, Michel Dorochevsky: SensoMot - Sensorische Erfassung von Motivationsindikatoren zur Steuerung adaptiver Lerninhalte. In: Christoph Igel, Carsten Ullrich, Martin Wessner (Hrsg.): Bildungsräume 2017: Gesellschaft für Informatik, Bonn, S. 267-272.

Moritz Niemann, Thomas Martens & Uwe Dick; Exploring the potential of wearable devices to measure motivation during self-regulated learning; Antwerpen; 2. – 6. 7. 2018; JURE 2018

Moritz Niemann, Thomas Martens & Uwe Dick; Physiological Data as Unobtrusive Measures for Motivation and Self-Regulated Learning; Warschau; 15. – 17.6. 2018; 6th Polish Eye Tracking Conference and 2nd Earli SIG 27 Conference

C Referenzen

Arriba-Pérez, de, Francisco de Juan, Santos-Gago, M., Caeiro-Rodríguez, Manuel, Ramos-Merino, Mateo (2019). Study of stress detection and proposal of stress-related features using commercial-off-the-shelf wrist wearables. Journal of Ambient Intelligence and Humanized Computing, Springer

Bach, Francis R.; Lanckriet, Gert RG; and Jordan, Michael I. (2004). *Multiple kernel learning, conic duality, and the SMO algorithm.* Proceedings of the twenty-first international conference on Machine learning. ACM.

Hochreiter, Sepp, and Jürgen Schmidhuber. *Long short-term memory*. Neural computation 9.8 (1997): 1735-1780.

Majewski, Jakub (2003). *Theorising Video Game Narratives*. Bond University Robina, Australia: Centre for Film, Television & Interactive Media

Mason, L.; Baxter, J.; Bartlett, P. L.; Frean, Marcus (1999). *Boosting Algorithms as Gradient Descent*. In S.A. Solla and T.K. Leen and K. Müller (ed.). Advances in Neural Information Processing Systems 12.

Jiahui Xu, Baichang Zhong (2017). Review on portable EEG technology in educational research. Computers in Human Behavior. Elsevier

Martens, T., Niemann, M. & Dick, U. (submitted). Sensor Measures of Affective Learning

Niemann, M., Dick, U. & Martens, T. (in preparation). *Predicting Affective Dynamics During Learning Using EEG*.

Rölke, H. (2012). The itembuilder: A graphical authoring system for complex item development. Paper presented at the World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education.

Rosenberg, E. L. & Ekman, P. (1994). *Coherence between expressive and experiential systems in emotion*. Cognition & Emotion, 8(3), 201-229.

Tsochantaridis, I., Joachims, T., Hofmann, T., & Altun, Y. (2005). Large margin methods for structured and interdependent output variables. Journal of machine learning research, 6(Sep), 1453-1484.

Yun, Haeseon, Domanska, Monika, Fortenbacher Albrecht, Ghomi, Mina, Pinkwart, Niels (2016). Sensor Data for Learning Support: Achievements, Open Questions and Opportunities. Paper presented at the DeLFI Workshops 2016 co-located with 14th e-Learning Conference of the German Computer Society

Berichtsblatt

1. ISBN oder ISSN	Berichtsart (Schlussbericht oder Veröf Schlussbericht	Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht	
3. Titel Schlussbericht des Teilvor Erfassung von Motivations	habens "Mustererkennung" im Verb indikatoren zur Steuerung von adar	undprojekt "Sensorische otiven Lerninhalten" (SensoMot)	
	148 V		
Brefeld, Ulf Dick, Uwe		5. Abschlussdatum des Vorhabens März 2019	
		6. Veröffentlichungsdatum	
	* ×	7. Form der Publikation	
8. Durchführende Institution(en) (Nar Leuphana Universität Lüne	me, Adresse) eburg; Scharnhorststr. 1, 21335	9. Ber. Nr. Durchführende Institution	
Lüneburg		10. Förderkennzeichen 16SV7514	
		11. Seitenzahl	
12. Fördernde Institution (Name, Adr	resse)	13. Literaturangaben	
Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn		14. Tabellen	
		15. Abbildungen 1	
16. Zusätzliche Angaben			
17. Vorlage auf Konferenzen (Titel, A	Autoren, Ort, Datum, Konferenz)		
Oliver Schneider, Thomas Dorochevsky: SensoMot - 3 adaptiver Lerninhalte. In: O Bildungsräume 2017: Gese	Martens, Mathias Bauer, Alexandra Sensorische Erfassung von Motivat Christoph Igel, Carsten Ullrich, Marti ellschaft für Informatik, Bonn, S. 267	ionsindikatoren zur Steuerung n Wessner (Hrsg.): 7-272.	
Moritz Niemann, Thomas N measure motivation during	Martens & Uwe Dick; Exploring the page self-regulated learning; Antwerpen	potential of wearable devices to 2. – 6. 7. 2018; JURE 2018	
for Motivation and Self-Reg	Martens & Uwe Dick; Physiological [gulated Learning; Warschau; 15. – 1 2nd Earli SIG 27 Conference	Data as Unobtrusive Measures 7.6. 2018; 6th Polish Eye	

18. Kurzfassung

1. Derzeitiger Stand von Wissenschaft und Technik

Das SensoMot-Projekt baut in interdisziplinärer Absicht auf drei Entwicklungslinien auf, die im Projekt zusammengeführt werden. Im Bereich von "Affective Computing" werden Wearables und andere Sensoren eingesetzt, um affektive Variablen abzuleiten. Methoden des maschinellen Lernens sind in der Lage, aus Merkmalen von Sensordaten automatisiert Zielvariablen vorherzusagen und im Bereich des selbstregulierten Lernens werden motivationale Prozesse modelliert und per Adaptionsalgorithmen reguliert.

2. Begründung/Zielsetzung der Untersuchung

Ziel des Projekts "SensoMot" war es, mit Hilfe von Sensordaten kritische motivationale Zustände zu erkennen und durch die Ableitung passender Adaptionsmechanismen Lernprozess so zu steuern, dass die Motivation der Lernenden unterstützt wird. Über sogenannte "Wearables" werden physiologische Daten der Lernenden erhoben, die z.B. auf Stress oder Langeweile hinweisen. Der Algorithmus der Lernsoftware passt daraufhin entsprechende Lernszenarien an, die hier prototypisch für die universitäre Lehre sowie berufliche Fernlehre entwickelt und evaluiert werden. Durch "SensoMot" sollte es erstmalig möglich werden, motivationsbedingte Lernblockaden mit Hilfe von unaufdringlichen Sensoren frühzeitig zu erfassen und Lerninhalte daran anzupassen.

Die Leuphana Universität Lüneburg war zuständig für das Teilprojekt Mustererkennung, in dem aus Sensordaten motivational-emotionale Zustände von Lernenden abgeleitet werden sollten.

3. Methode

Das Teilprojekt "Mustererkennung" entwickelt und evaluiert mithilfe der aus dem Teilvorhaben "Motivationsindikatoren und Adaptationsalgorithmen" erhobenen Sensordaten aus Laborstudien überwachte Methoden des maschinelles Lernens. Dazu werden Merkmale aus den Sensordatenströmen entwickelt und Vorhersagemodelle implementiert, die Motivationsindikatoren vorhersagen. Diese Modelle werden kreuzvalidiert evaluiert um die Generalisierbarkeit zu gewährleisten.

4. Ergebnis

Mit einem klinischem EEG konnte im Zusammenspiel der Bereiche Mustererkennung und Motivationsindikatoren gezeigt werden, dass aus EEG-Daten motivationale Indikatoren signifikant vorhersagt werden können. Studien mit Daten aus Wearables konnten lediglich vereinzelte positive Ergebnisse liefern, die mangelnde Qualität der Daten erlaubte allerdings keine verlässlichen Vorhersagemodelle.

5. Schlussfolgerung/Anwendungsmöglichkeiten

Die Studie mit klinischem EEG hat gezeigt, dass bei ausreichender Datenqualität eine Vorhersage von Motivationsindikatoren aus physiologischen Daten möglich ist. Aktuelle kommerzielle Wearables konnten diese Ergebnisse allerdings nur unzureichend validieren. Bei Verfügbarkeit verbesserter Wearables wäre eine Einbettung der Vorhersageergebnisse in adaptive Lernplattformen wie dem CBA-Itembuilder möglich. Mithilfe des entwickelten Adaptionsmodells kann der Lernprozess dann so gesteuert werden, dass die Motivation der Lernenden unterstützt wird

19. Schlagwörter		
Vorhersagemodelle, Maschinelles Lernen, Mustererkennung, Motivation, Emotion, Lernen,		
Lernprozesse, EEG, Adaptation, Selbstregulation, selbstreguliertes Lernen		
20. Verlag	21. Preis	
	8	

Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publicati	ion)
3. title Schlussbericht des Teilvorhabe Erfassung von Motivationsindik	ens "Mustererkennung" im Verb katoren zur Steuerung von adap	oundprojekt "Sensorische otiven Lerninhalten" (SensoMot)
4. author(s) (family name, first name(s))		5, end of project
Brefeld, Ulf		March 2019
Dick, Uwe		6. publication date
		7. form of publication
8. performing organization(s) (name, address) Leuphana Universität Lüneburg; Scharnhorststr. 1, 21335		9. originator's report no.
Lüneburg	,	10. reference.no. 16SV7514
	*	11. no. of pages
12. sponsoring agency (name, address)		13. no. of references
Bundesministerium für		
Bildung und Forschung (BMBF) 53170 Bonn		14. no. of tables
		15. no. of figures
16. supplementary notes		
	4	41
Dorochevsky: SensoMot - Senso adaptiver Lerninhalte. In: Chris	tens, Mathias Bauer, Alexandra sorische Erfassung von Motivati stoph Igel, Carsten Ullrich, Martir haft für Informatik, Bonn, S. 267	ionsindikatoren zur Steuerung n Wessner (Hrsg.):
Moritz Niemann, Thomas Marte measure motivation during self	ens & Uwe Dick; Exploring the pre- regulated learning; Antwerpen;	ootential of wearable devices to 2. – 6. 7. 2018; JURE 2018
Moritz Niemann, Thomas Marte for Motivation and Self-Regulat Tracking Conference and 2nd E	ens & Uwe Dick; Physiological D ted Learning; Warschau; 15. – 1 Earli SIG 27 Conference	Oata as Unobtrusive Measures 7.6. 2018; 6th Polish Eye

18. abstract

1. Current State of Science and Technology

The SensoMot project is based on three interdisciplinary lines of development, which are brought together in this project. In the area of "Affective Computing" wearables and other sensors are used to derive affective variables. Machine learning methods are capable of automatically predicting target variables from sensor data characteristics, and in the field of self-regulated learning motivational processes are modeled and regulated by adaptation algorithms.

2. Justification/Objective of the Study

The aim of the "SensoMot" project was to use sensor data to identify critical motivational states and, by deriving appropriate adaptation mechanisms, to steer the learning process in such a way that the motivation to learn of the learner is supported. So-called "wearables" are used to collect physiological data of the learners that indicate stress or boredom, for example. The algorithm of the learning software then adapts corresponding learning scenarios, which are developed and evaluated here in a prototypical fashion for the areas of university and distance learning. SensoMot" aims at detecting motivational learning blockades at an early stage with the help of unobtrusive sensors and to adapt learning content to them for the first time.

Leuphana University Lüneburg was responsible for the pattern recognition subproject, in which motivational-emotional states of learners were to be derived from sensor data.

3. Methods

The subproject "Pattern Recognition" develops and evaluates supervised machine learning methods that use sensor data from laboratory studies collected from the subproject "Motivational Indicators and Adaptation Algorithms". For this purpose, features are developed from the sensor data streams and prediction models are implemented that predict motivational indicators. These models are evaluated via cross-validation to ensure generalizability.

4. Results

With a professional EEG, it was shown that motivational indicators can be predicted from EEG data. Studies with data from wearables only provided isolated positive results, but poor quality of the data did not allow reliable prediction models.

5. Conclusion/Applications

The study using professional EEG showed that with sufficient data quality it is possible to predict motivational indicators from physiological data. Current commercial wearables, however, were only partly able to validate these results. Given availability of improved wearables, it would be possible to embed the prediction results in adaptive learning platforms such as the CBA-Itembuilder. With the help of the developed adaptive model, the learning process can then be guided in a way that supports the motivation of the learner.

19. keywords Prediction models, machine learning, pattern recognition, motive learning processes, EEG, adaptation, self-regulation, self-regulation.	
	21. price