

Hoe kan Artificial Intelligence het leerproces van de student bevorderen?

Masha Boosten, Ronald Ferket, Marcel Meesters, Carlijn Moed, Bartosz Paszkowski,
Gerard Schouten.

Fontys Hogescholen

Over de auteurs:

Marcel Meesters, M.R.J. MSc, PDEng (m.meesters@fontys.nl) is werkzaam bij Fontys Hogeschool voor ICT, Eindhoven

Masha Boosten, Msc, is werkzaam bij Fontys Hogescholen Eindhoven bij de centrale dienst Onderwijs en Onderzoek

Carlijn Moed, MSc, is werkzaam bij Fontys Hogeschool voor ICT, Eindhoven

Bartosz Paszkowski, Msc, werkt bij Fontys Hogescholen voor ICT, Eindhoven

Lector Gerard Schouten, Dr. is werkzaam bij het lectoraat Artificial Intelligence aan de Fontys Hogeschool voor ICT in Eindhoven

Ronald Ferket is werkzaam bij adviesbureau CINOP te Den Bosch

Samenvatting (Nederlands en Engels)

Hoe kan Artificial Intelligence het leerproces van de student bevorderen?

De arbeidsmarkt is continu in ontwikkeling, leidend tot een steeds veranderende vraag naar competenties en banen. Dit vraagt naast beroepsgerichte vaardigheden en kennis over veerkracht en wendbaarheid van professionals. Van de student wordt daarom verwacht dat die zich ontwikkelt in zelfgereguleerd (ZGL) leren. ZGL gaat over regie van het eigen leerproces: studenten bepalen zelf hoe tot leerresultaten te komen, deze te evalueren en sturen het leerproces zelf bij. Voor opleidingen is het de vraag hoe ze ZGL kunnen begeleiden en bevorderen. Dit behoeft inzicht in leergedrag, patronen hierin en bewustzijn over hoe deze inzichten gebruikt kunnen worden om ZGL te ondersteunen en het leerproces te begeleiden. In dit onderzoek is geïnventariseerd of de data die studenten in de elektronische leeromgeving (ELO) achterlaten een indicatie kan geven over het leerproces en ZGL van de student.

Om de ingewikkelde patronen uit de data te halen, zijn de data uit de ELO met behulp van AI-technieken geanalyseerd. Hiermee kon het leerproces van studenten in verschillende categorieën worden onderverdeeld. De categorieën geven een eerste indicatie over het ZGL van de student. Verder onderzoek is benodigd, ook om te onderzoeken wat dit betekent voor de ondersteuning van studenten in hun leerproces.

How could Artificial Intelligence foster the student's learning process?

The labor market is constantly evolving, leading to an ever-changing demand for skills and jobs. Next to professional skills and knowledge, this requires resilience, flexibility and the skill to learn new skills outside a school environment. In other words, the student is expected to develop in self-regulated (SRL) learning. SRL is about directing their own learning process: students themselves determine how to achieve learning results, evaluate them and adjust the learning process themselves. The question for education-institutes is how they can guide and promote SRL. This requires insight into learning behavior, patterns and awareness how to use these insights to support SRL and guide the learning process. In this study, an inventory was made of whether the data that students leave in the electronic learning environment (ELE) can provide an indication of the student's learning process and SRL.

In order to extract the complicated patterns from the data, the data from the ELE has been analyzed using AI techniques. This made it possible to split student clusters into different learning processes. The clusters provide an initial indication of the student's SRL. Further research is required, also to investigate what this means for the support of students in their learning process.

Trefwoorden

Zelfgereguleerd leren, artificiële intelligentie (AI), leerproces, hoger onderwijs

Trefwoorden (Engels)

Self-regulated learning, artificial intelligence (AI), learning process, higher education

Veranderende eisen samenleving

Door digitalisering, automatisering, robotisering, energie- en klimaattransities groeit de dynamiek op de arbeidsmarkt en veranderen banen en organisaties. Hierdoor zullen mensen steeds nieuwe, aangepaste en andere vaardigheden moeten (bij)leren waarbij ICT een belangrijke rol speelt. Studenten -de professionals van morgen- zullen naast relevante, beroepsgerichte vaardigheden en kennis, ook moeten beschikken over veerkracht, wendbaarheid en het vermogen om kennis en vaardigheden actueel te houden (Schloemer & Brennan, 2006). Om dit te ontwikkelen, is een open en flexibele opleiding nodig waarbij de student bewuste keuzes maakt en de regie neemt over zijn eigen leerproces en zich ontwikkelt in zelfgereguleerd leren (ZGL). In dit artikel gaan we in op hoe dit bij Fontys Hogeschool ICT (FHICT) wordt gedaan. Hieronder wordt eerst kort beschreven wat we verstaan onder flexibel en zelfgereguleerd leren en hoe we dat vormgeven in het onderwijs. Daarna wordt de onderzoeksopzet toegelicht dat gevolgd wordt door een uiteenzetting van de resultaten. Tot slot wordt de conclusie weergegeven en een blik op de toekomst gegeven.

Flexibele opleiding

Flexibel onderwijs is in staat zich aan te passen aan de veranderende omstandigheden (veranderende behoeften van beroepenveld en student) en kan verschillende mogelijkheden bieden in het hoe, wat, waar, en wanneer er geleerd wordt. Bij FHICT is het doel om flexibel onderwijs aan te bieden in een vorm die past bij elk type student. Vanuit dit startpunt is een curriculumarchitectuur ontwikkeld die bestaat uit drie leervormen. Deze vormen variëren in mate van sturing door de docent. De student kan per semester van leervorm wisselen. In de tabel hierna zijn deze leervormen opgenomen met de belangrijkste karakteristieken.

Tabel 1 Karakteristieken per leervorm

Leervorm	Leeruitkomsten	Leerroute	Mate van sturing
Course-based	Vast	Vast	Hoog
Demand-based	Vast	Vrij	Matig
Open	Vrij binnen raamwerk	Vrij	Laag

Zelfgereguleerd leren


Zelfgereguleerd leren gaat over regie van het eigen leerproces: studenten bepalen zelf hoe tot leerresultaten te komen, deze te evalueren en sturen het leerproces zelf bij (Zimmerman, 2008). Het ontwikkelen van een hoge mate van ZGL is van belang voor studenten, omdat ze als professionals moeten kunnen omgaan met veranderende omstandigheden en ICT-ontwikkelingen. Een student die verantwoordelijkheid neemt over zijn leerproces, bereidt zich voor op een leven lang leren (Zimmerman, 2008). Om ZGL te bevorderen, is een flexibele leeromgeving van belang: afhankelijk van waar de student in zijn leerproces aan toe is, is de onderwijsvorm meer of minder prescriptief. Docenten hebben binnen deze student-gecentreerde leeromgeving een belangrijke rol als coach en facilitator van het leren van studenten (Land, Hannafin, & Oliver, 2009). Sinds september 2019 biedt FHICT de studenten de keuze uit drie leervormen variërend in mate van vrijheid waarmee de student zijn leeruitkomsten kan aantonen. De vraag van opleidingen daarbij is hoe ze het zelfgereguleerd leren binnen deze flexibele leeromgeving kunnen begeleiden en bevorderen.

ZGL en data

Om opleidingen te ondersteunen, is behoefte aan inzicht in leergedrag, patronen hierin en bewustzijn over hoe deze inzichten gebruikt kunnen worden om het zelfgereguleerd leren te ondersteunen en het leerproces te begeleiden. Huidige meetmethodes om inzicht te geven in leergedrag en patronen zijn hierbij doorgaans niet toereikend. Zo worden vaak vragenlijsten gebruikt om leergedrag in beeld te brengen (Endedijk, Brekelmans, Slegers, & Vermunt, 2016), maar deze meten niet het gedrag zelf maar slechts de perceptie van de student (Panadero, Klug, & Järvelä, 2016). Daarnaast zijn veelal meerdere databronnen -die verschillende aspecten meten en elkaar aanvullen-nodig om complexe leerprocessen zoals ZGL in kaart te brengen (Malmberg, Järvelä, & Järvenoja, 2017, Noroozi et al., 2019).

Data uit een elektronische leeromgeving (ELO) kunnen een belangrijke rol spelen om deze gedragingen en patronen (in het bijzonder over langere termijn) in beeld te brengen en om zo input te geven voor (data-bewust) begeleiden (Volman, 2019). Binnen FHICT bieden de data uit de ELO Canvas hiervoor een aanknopingspunt. Studenten gebruiken Canvas voor het vinden van opdrachten, het bekijken van leermaterialen en het inleveren van uitwerkingen behorende bij opdrachten. Ook vindt de student feedback en beoordelingen door de docent in de ELO terug en houdt de student hier een logboek bij met reflecties en ontvangen feedback.

Afbeelding 1 toont het model waarin is weergegeven hoe het leerproces (in grijs) ondersteund kan worden door een data-gedreven begeleidingsproces.



Afbeelding 1: Mogelijke data-gedreven begeleiding van het leerproces

Onderzoeksopzet

Het in kaart brengen van gedragingen van studenten en patronen hierin vanuit de verschillende databronnen -om zo input te geven voor (data-bewust) begeleiden- vraagt een meerjarige aanpak. In dit eerste, eenjarige project is gefocust op het exploreren van de mogelijkheden van moderne technieken om het leerproces in kaart te kunnen brengen op basis van data uit de ELO.

Om de onderwijsleeractiviteiten en voortgang van studenten te meten, zijn de afgelopen jaren learning analytics-dashboards ontwikkeld. De meeste van deze LA-dashboards meten constructies als aanwezigheid, percentage ingeleverde opdrachten en resultaten voor tussentijdse toetsen (Lie, Huang, Lin, Ogata & Yang, 2018). Deze constructies geven echter niet altijd een goede indicatie van de voortgang van de student. Vooral als het instituut wil


dat studenten hun eigen leerproces plannen, uitvoeren en evalueren, is het meten van deze basisconstructies niet voldoende (Axelsen, Redmond, Heinrich & Henderson, 2020). Het leerproces van studenten kan op veel verschillende manieren verlopen en dit is moeilijk zichtbaar met de gegevens uit de ELO.

Daarom was de centrale vraag in dit onderzoek of de data uit de ELO een beeld geven van de route die de student bewandelt om zijn/haar leeruitkomsten aan te tonen. Hiervoor zijn de data van 623 studenten uit de ELO opgehaald die in de jaren 2017, 2018, en/of 2019 een semester Applied Data Science hebben doorlopen. Het betreft meta-data zoals het al dan niet (op tijd) inleveren van voorbereidingen, opdrachten en projecten. De meta-data geeft ook inzicht in het verloop van de leerroute over het semester. Deze data zijn geanonimiseerd en in een beveiligde omgeving opgeslagen ten behoeve van analyse. Vervolgens is nagegaan of en hoe deze data een beeld kunnen geven van de bewandelde leerroute. Deze route hebben we gedefinieerd als 'student journey', en omvat de opeenvolging van activiteiten die de student onderneemt om een leeruitkomst te behalen (zie Afbeelding 2).



Afbeelding 2: Student journey gebaseerd op meta-data over onderwijsleeractiviteiten

Om deze ingewikkelde patronen uit de data te halen, is de ELO-data op verschillende niveaus geanalyseerd. De niveaus zijn schematisch getoond in afbeelding 3. De *P* staat voor *Preparation* en de *E* voor *Exercise*.



Afbeelding 3: Een semester bevat meerdere sprints, die weer bestaan uit onderwijsleeractiviteiten

Elk van deze drie niveaus -semester, sprint en onderwijsleeractiviteit- heeft zijn eigen unieke kenmerken en is gebaseerd op de aggregatie van leeractiviteiten. Zo worden de individuele leeractiviteiten geaggregeerd tot sprint en de sprints worden geaggregeerd tot één semester.

Aggregatieniveau: semester

Op dit aggregatieniveau analyseren we de populatie gedurende een geheel semester. Hiermee krijgen we inzicht in bijvoorbeeld het gemiddelde percentage afgeronde opdrachten in een semester in relatie tot studiesucces. Om deze bewerkingen uit te voeren, zijn als startpunt van het onderzoek beschrijvende analyses toegepast zoals het percentage afgeronde voorbereidingsopdrachten afgezet tegen het wel of niet behalen van het semester. Daarnaast toetsen we de data op bruikbaarheid en indicatoren voor studiesucces met behulp van simpele Machine Learning algoritmes (zoals *k-nearest-neighbour* (KNN), *random-forest-classifier* (RTC) en *support-vector-machines* (SVM)).

De verkennende, exploratieve fase van dit onderzoek bestond uit het benaderen van de data op een semester-breed niveau. Omdat de resultaten op een algemeen niveau niet voldeden, zoomden we vervolgens in op een gedetailleerder maar complexere werkelijkheid, namelijk het analyseren op het niveau van onderwijsleeractiviteit.

Aggregatieniveau: onderwijsleeractiviteit

Dit betreft de analyse op basis van alle losse onderwijsleeractiviteiten. In tegenstelling tot het aggregatieniveau semester, vallen onder dit niveau analyses gebaseerd op de student en zijn individuele, losstaande leeractiviteiten. Op dit niveau beschouwen we de 'student-journey' als het meest accuraat en passen we geen aggregatiemethodes toe. Kortom, de data worden niet verwerkt (feature engineering) tot nieuwe variabelen.

Omdat standaard analysemethoden niet voldeden voor het werken met deze tijdseries data (50+ onderwijsleeractiviteiten over een periode in de tijd), aanvullend met de gecombineerde dimensies van de datakenmerken (5+ per onderwijsleeractiviteit, bestaande uit het wel of niet deelnemen van een student, op tijd inleveren en feedback) is in dit onderzoek gekozen voor het toepassen en toetsen van Artificial Intelligence. Specifiek zijn *LSTM's recurrent neural*

networks toegepast. Uniek aan deze neurale netwerken is het vermogen om tijdseries van data te verwerken -zoals de opeenvolging van onderwijsleeractiviteiten- en daarnaast de input uit de voorafgaande neurale netwerkcel te onthouden (Sherstinsky, 2020).

Aggregatieniveau: sprint

Vervolgens bestaan er ook tussenvormen, waarbij we niet alle onderwijsleeractiviteiten los beschouwen maar deze aggregeren. Deze tussenvorm is gebaseerd op de praktijk en worden *sprints* genoemd (zie Afbeelding 3). De courses bestaan in de praktijk uit verschillende sprints van bij elkaar horende onderwijsleeractiviteiten. Deze activiteiten zijn niet verplicht voor het behalen van een eindcijfer, maar helpen studenten de leerstof beter te begrijpen. De opdeling in de koppels 'voorbereiding' en 'oefening' zijn gebaseerd op de chronologische volgorde van deze twee in de praktijk.

De data worden geaggregeerd naar deze sprints waarin de gemiddelde uitkomsten van de onderwijsleeractiviteiten binnen deze sprints als features worden beschouwd. Daarmee is er een proxy gecreëerd met behulp van feature engineering gebaseerd op de processen uit de praktijk. Deze features weerspiegelen de *sprints* uit het curriculum, waarin elke *course* bestaat uit verschillende sprints. Met behulp van clustering-algoritmes, in dit geval *TSNE* (Van der Maaten & Hinton, 2008), is vervolgens getracht om groepen studenten te ontdekken met vergelijkbare leerpatronen binnen een groep. Deze resultaten kunnen ook op individueel niveau weergegeven worden.

Resultaten


De resultaten van dit onderzoek zijn op te delen naar de eerder besproken niveaus. Deze niveaus zijn gebaseerd op aggregatie van tijd (zie Tabel 2).

Tabel 2 Verschillende analyse technieken per niveau en hun opbrengst

Niveau	Analysetechnieken	Opbrengsten
Semester	Beschrijvende analyse Machine learning • <i>RTC</i> • <i>SVM</i> • <i>KNN</i>	Inzicht in de datastructuur. Gemiddeld genomen dragen onderwijsleeractiviteiten uit de ELO bij aan het studiesucces
Sprints	Machine learning • <i>TSNE</i>	Herkennen en definiëren van verschillende leerroutes met ieder een eigen mate van studiesucces
Onderwijsleeractiviteit	Neurale netwerk: • <i>CNN</i> • <i>RCN</i> • <i>LSTM</i>	Voorspellen van studiesucces halverwege het semester op basis van de tot dan toe afgelegde leerroute

Aggregatieniveau: semester

De verkennende, exploratieve fase van dit onderzoek bestond uit het benaderen van de data op een semester-breed niveau, dus op populatieniveau over de gehele tijdsspanne van een semester. Hierbij hanteerden we het gemiddelde over de hele tijd, voor de hele populatie als uitgangspunt. De resultaten van voorbeeldanalyses op het hoogste aggregatieniveau zijn te zien in Afbeelding 4. Dit figuur zet het percentage gemaakte opdrachten af tegen de groep studenten die het semester wel en niet succesvol afronden. Studenten die het semester succesvol afronden, maken gemiddeld meer voorbereidende oefeningen.



Abeelding 4: Percentage voorbereiding compleet


Aggregatieniveau: onderwijsleeractiviteit

Op dit aggregatieniveau hanteerden we een *Neural Network* om de uitkomsten (voldoende/onvoldoende) halverwege het semester (na 8 weken) voor een student te voorspellen. Hiervoor verwerkte het *LSTM Recurrent Neural Network* gemiddeld 250 datapunten per student. Voor 70% van de studenten werd het *LSTM*-model met datapunten gevoed (training data) inclusief het eindresultaat van het semester voor deze studenten. Vervolgens werd de overige 30% van de data gebruikt om de accuraatheid van het model te testen. Van deze 30% werd de helft van de datapunten (het eerste deel van het semester) gebruikt. In 93% van de gevallen voorspelde het model, op basis van data van het eerste deel van het semester, de uitkomst correct. Dit zijn veelbelovende resultaten die kunnen dienen als opstap naar het vervolgonderzoek.

Aggregatieniveau: sprint


Voor deze analyses zijn sequenties geëxtraheerd die bestaan uit koppels van voorbereidingen en oefeningen. Het inzoomen op deze sprints leverde interessante resultaten op. Met behulp van de features die op *sprint niveau* zijn gecreëerd konden door toepassing van een *TSNE*-cluster algoritme groepen studenten worden geïdentificeerd die onderling verschillen in de mate van het uitvoeren van de *sprints* en het slagingspercentage.

Deze groepen zijn in Afbeelding 5 gemarkeerd met drie cirkels. *TSNE* is een factor verminderde analyse, waarbij we in dit geval 18 variabelen vertalen naar twee. Deze twee variabelen zijn afgezet op de x-as en y-as om vervolgens tot een visuele vormgeving te komen.




Afbeelding 5: TSNE-cluster


In Afbeelding 6.a, 6.b en 6.c zijn de 'student-journeys' gevisualiseerd met behulp van de eerder gedefinieerde sprints (in dit geval negen sprints gemarkeerd als B1 tot en met B9), inclusief het percentage studenten dat het semester succesvol afrondt. De groepen verschillen in studierendement (respectievelijk 88%, 51% en 87%) en de mate van het uitvoeren van onderwijsleertaken *preparations* en *exercises*.



Afbeelding 6.a: Student-journey 1, 88% voldoende



Afbeelding 6.b: Student-journey 2, 51% voldoende



Afbeelding 6.c: Student-journey 3, 87% voldoende

In de resultaten herkennen we drie 'student-journeys' die mogelijk samenhangen met zelfregulerend leren. Zo heeft de eerste groep studenten (Afbeelding 6.a) het hoogste percentage studiesucces, maar zien we ook dat deze groep het minst actief is in de voorbereiding en uitvoering van de opdrachten. Dit geeft een verder verfijnd beeld en bewijst de meerwaarde van het inzoomen op de specifieke leerprocessen.

Wanneer we Afbeelding 6.b en 6.c vergelijken, zien we een gelijke mate van uitvoering maar een verschil in voorbereiding en een groot verschil in het percentage voldoende. Deze bevindingen roepen het beeld op van twee groepen studenten:

1. Studenten die minder actief zijn binnen de ELO en toch succesvol het semester afronden (Afbeelding 6.a).
2. Studenten waarbij de voorbereiding en uitvoering samenhangt met het slagingspercentage (Afbeelding 6.b en 6.c).

Conclusies

In dit onderzoek stond de vraag centraal of de data uit de ELO een beeld geven van de route die de student bewandelt in het uitvoeren van onderwijsleeractiviteiten. Deze route hebben we gedefinieerd als 'student-journey', en bevat de opeenvolging van onderwijsleeractiviteiten die de student onderneemt om een leeruitkomst te behalen. Om deze ingewikkelde patronen uit de data te kunnen halen, zijn de data uit de ELO met behulp van AI-technieken op verschillende aggregatieniveaus geanalyseerd. Met de op AI gebaseerde analyses kon een aantal patronen zichtbaar gemaakt worden die met reguliere (statistische) methodes niet waren gevonden.

De analyses op het hoogste aggregatieniveau toonden aan dat studenten die succesvol een semester afronden ook meer voorbereidende opdrachten doen. Echter, als we inzoomen, zien we verschillende patronen. Zo is er een groep studenten die het semester haalt zonder dat de aangeboden onderwijsleeractiviteiten worden opgepakt (de groep uit Afbeelding 6a). Verder onderzoek moet uitwijzen of dit studenten zijn met een hoge mate van ZGL. Daarnaast is er een groep studenten die de onderwijsleeractiviteiten zeker het eerste deel van het semester oppakt waarvan een deel van de studenten het semester haalt en een ander deel niet. Met de genoemde AI-algoritmes is een onderverdeling te maken in een subgroep waarvan een hoog percentage het semester haalt (87%), en een subgroep waarvan het slagingspercentage veel kleiner is (51%).

Toekomst

De resultaten laten zien dat data uit de leeromgeving tot interessante analyses kunnen leiden die informatie kunnen verschaffen over de 'student-journey' van een student naar het wel of niet behalen van leeruitkomsten. We zien daarbij dat er verschillende 'journeys' te onderscheiden zijn. Of de 'journeys' een indicatie geven van de mate van ZGL van de student verdient verder onderzoek.

Ook is verder onderzoek benodigd in hoeverre differentiatie in de begeleiding van de gevonden groepen kan leiden tot een hoger slagingspercentage op semesterniveau. Hiermee wordt het in de toekomst misschien mogelijk om de docentbegeleiding af te laten hangen van wat de data uit de ELO ons vertelt over de mate van sturing die de student nodig heeft.

Literatuurreferenties

Axelsen, M., Redmond, P., Heinrich, E., & Henderson, M. (2020). The evolving field of learning analytics research in higher education: From data analysis to theory generation, an agenda for future research. *Australasian Journal of Educational Technology*, 36(2), 1-7. doi:10.14742/ajet.6266

Endedijk, M.D., Brekelmans, M., Sleegers, P., & Vermunt, J.D. (2016). Measuring students' self-regulated learning in professional education: Bridging the gap between event and aptitude measurements. *Quality and Quantity*, 50(5), 2141–2164.

Land, S.M., Hannafin, M.J., & Oliver, K.M. (2009). Student-centered learning environments: Foundations, assumptions, and design. In D. Jonassen & S. Land (Eds.), *Theoretical Foundations of Learning Environments* (pp. 3–49). New York, NY: Taylor & Francis.

Maaten, van der, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of machine learning research*, 9(11).

Malmberg, J., Järvelä, S., & Järvenoja, H. (2017). Capturing temporal and sequential patterns of self-, co-, and socially shared regulation in the context of collaborative learning. *Contemporary Educational Psychology*, 49, 160-174. <https://doi.org/10.1016/j.cedpsych.2017.01.009>

Noroozi, O., Alikhani, I., Järvelä, S., Kirschner, P. A., Juuso, I., & Seppänen, T. (2019). Multimodal data to design visual learning analytics for understanding regulation of learning. *Computers in Human Behavior*, 100, 298-304. <https://doi.org/10.1016/j.chb.2018.12.019>

Panadero, E., Klug, J., & Järvelä, S. (2016). Third wave of measurement in the self-regulated learning field: when measurement and intervention come hand in hand. *Scandinavian Journal of Educational Research*, 60(6), 723–735

Sherstinsky A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404

Schloemer, P., & Brennan, K. (2006). From students to learners: Developing self-regulated learning. *Journal of Education for Business*, 82(2), 81–87.

Volman, L. (2019). Pleidooi voor een onderwijskundige visie op gepersonaliseerd leren. *Pedagogische Studiën*, 2019(96), 64–75.

Zimmerman, B. (2008). Investigating self-regulation and motivation: historical background, methodological developments, and future prospects. *American Educational Research Journal*, 45(1), 166–183.