

TNO PUBLIEK

Defence, Safety & SecurityKampweg 55
3769 DE Soesterberg
Postbus 23
3769 ZG Soesterbergwww.tno.nl

T +31 88 866 15 00

TNO-rapport**TNO 2020 R11746****Learning analytics in simulator training bij
Luchtverkeersleiding Nederland (LVNL)**

Datum	november 2020
Auteur(s)	L.M.M. Roijendijk A. de Bruijn E.A.P.B. Oprins
Oplage	2
Aantal pagina's	37 (incl. bijlagen)
Aantal bijlagen	n.v.t.
Opdrachtgever	Luchtverkeersleiding Nederland (LVNL)
Projectnaam	Performance measurement: proof of concept
Projectnummer	060.42341

Alle rechten voorbehouden.

Niets uit deze uitgave mag worden vermenigvuldigd en/of openbaar gemaakt door middel van druk, fotokopie, microfilm of op welke andere wijze dan ook, zonder voorafgaande toestemming van TNO.

Indien dit rapport in opdracht werd uitgebracht, wordt voor de rechten en verplichtingen van opdrachtgever en opdrachtnemer verwezen naar de Algemene Voorwaarden voor opdrachten aan TNO, dan wel de betreffende terzake tussen de partijen gesloten overeenkomst.

Het ter inzage geven van het TNO-rapport aan direct belanghebbenden is toegestaan.

© 2020 TNO

TNO PUBLIEK

Samenvatting

Doelstelling

Luchtverkeersleiding Nederland (LVNL) heeft als doelstelling om te onderzoeken of het toepassen van learning analytics de simulatoropleidingen bij LVNL efficiënter en effectiever zou kunnen maken. Learning analytics betreft het verzamelen, analyseren en interpreteren van diverse soorten data die informatie geven over het leerproces en de prestaties van leerlingen. De informatie wordt doorgaans gepresenteerd aan de eindgebruikers op overzichtelijke dashboards.

Methode

TNO heeft de opdracht gekregen om LVNL te ondersteunen in het verkennen van de mogelijkheden om learning analytics toe te passen in simulator training bij LVNL.

Hiertoe heeft TNO diverse activiteiten uitgevoerd:

- Beknopte scan van de state-of-the-art literatuur over learning analytics.
- Uitvoeren van twee pilot studies (GND, ACS): data analyse en visualisatie.
- Benchmark met eerder uitgevoerde projecten door TNO bij Defensie.
- Diverse gesprekken en overleg met potentiële eindgebruikers.

Resultaten

De verkenning heeft opgeleverd dat learning analytics zeker potentie heeft voor toepassing bij LVNL. Learning analytics kan worden ingezet op diverse niveaus, afhankelijk van de doelstelling die wordt beoogd. Zo kunnen data die gebaseerd zijn op een enkele oefening nuttig zijn voor (gepersonaliseerde) feedback tijdens de debriefing en adviezen over de oefeningen die volgen. Data van meerdere leerlingen, verzameld gedurende een gehele cursus, kunnen ondersteunen bij de beoordeling van leerlingen of bij een cursusevaluatie. In de pilots is vooral aandacht besteed aan het gebruik van learning analytics tijdens of na een oefening, maar uit de gesprekken is gebleken dat er juist (ook) meerwaarde wordt gezien in het verkrijgen van een beter overzicht over groepen leerlingen en de gehele cursus.

Het gebruik van learning analytics in simulator training staat wereldwijd nog in de kinderschoenen. Dit blijkt ook uit de uitgevoerde pilot studies bij LVNL, die zich met name hebben gericht op gebruik van gelogde data om prestaties van leerlingen in kaart te brengen. Het is technisch nog niet eenvoudig om de grote hoeveelheid data die in simulatoren worden opgeslagen te exporteren en te gebruiken ten behoeve van leren. Een internationale benchmark heeft opgeleverd dat hierin wel stappen worden gezet, bijvoorbeeld bij de Amerikaanse Defensieorganisatie (ADL): de ontwikkeling van xAPI om leerdata op gestandaardiseerde wijze op te slaan in een Learning Record Store (LRS) en met elkaar te kunnen koppelen. LVNL kan deze technologische ontwikkelingen volgen en de resultaten uit internationaal onderzoek in de toekomst daadwerkelijk gaan gebruiken.

Afgezien van de technische beperkingen is uit de pilots gebleken dat het komen tot bruikbare en eenduidige prestatiematen op basis van gelogde data behoorlijk ingewikkeld is. Dit heeft te maken met de complexiteit en dynamische karakter van de luchtverkeersleidingstaak. Hiertoe is een goede analyse met eindgebruikers noodzakelijk om te achterhalen welke maten bruikbaar zijn in de opleiding en voor welk doel, waarbij de relatie wordt gelegd met de competenties waar instructeurs al

goed in thuis zijn. De nadruk hier zou moeten liggen op wat men op dit moment mist aan informatie, en welke informatie kan bijdragen aan een verbetering van het opleidingsproces. Het helpt hierbij om voorbeelden (bijvoorbeeld interactieve dashboards) te laten zien van toepassingen van learning analytics, eventueel met gebruik van xAPI als technologische oplossing, in andere simulatoropleidingen (bijvoorbeeld Defensie). Indien er grote hoeveelheden gelogde data beschikbaar zijn door langere tijd data te verzamelen over grote groepen leerlingen, kan ook vanuit de data worden bekeken welke betekenisvol en onderscheidend zijn. Hierbij kunnen (nieuwe) analysetechnieken worden toegepast (statistiek, machine learning, data mining) om patronen en relaties te vinden, zowel onderlinge relaties tussen de diverse gelogde data als relaties met competentiebeoordelingen van instructeurs en andere meer subjectief verzamelde data (bijvoorbeeld self-ratings). Deze hoeveelheid en diversiteit aan data waren in de uitgevoerde pilots bij LVNL nog niet beschikbaar, dus dergelijke analyses konden nog niet uitgevoerd worden.

Algemeen uitgangspunt van learning analytics is dat de data zich niet beperken tot gelogde (performance) data. Juist de combinatie en diversiteit van verschillende soorten data zorgen voor een zo compleet mogelijk beeld van de prestaties en leerproces van leerlingen. Zo kunnen combinaties van gelogde data dienen als extra bewijslast bij het beoordelen van competenties door instructeurs. Naast gelogde data kunnen bijvoorbeeld workload metingen en bepaalde leerkenmerken (bijvoorbeeld self-efficacy, motivatie) bruikbare informatie bieden over het leerproces van leerlingen. In de toekomst zullen ook extra objectieve maten betrouwbaarder ingezet kunnen worden zoals eye-tracking en fysiologische maten (bijvoorbeeld stress).

Stappenplan

Er dienen nog diverse stappen gezet te worden voordat learning analytics bij LVNL geïmplementeerd kan worden. Het uitgangspunt, afgestemd met de eindgebruikers, dient hierbij te zijn wat de beoogde doelstellingen en eindproduct zijn ter ondersteuning of verbetering van de huidige simulatoropleidingen bij LVNL:

- Formuleren van een visie en doelstellingen
 - Ontwikkelen van een lange termijn visie over het gebruik van learning analytics en het resultaat (bijvoorbeeld een interactief dashboard voor instructeurs).
 - Opstellen van een programma van eisen waaraan learning analytics zou moeten voldoen voor de diverse eindgebruikers.
- Uitvoeren van een pilot met veel data
 - Inventarisatie van mogelijke data die verzameld zouden moeten worden.
 - Dataverzameling: mogelijk maken van data exports bij gelogde data, verzamelen van extra data t.b.v. validatie (bijvoorbeeld competentiebeoordelingen) .
 - Data-analyse: exploreren van relaties tussen data (bijvoorbeeld gelogde data en beoordelingen) met nieuwe technieken (bijvoorbeeld statistiek, machine learning).
 - Presentatie en visualisatie van de resultaten op eenvoudige prototypes van interactieve dashboards (bijvoorbeeld in Powerpoint).
- Implementatie
 - Opstellen van specificaties voor een learning analytics applicatie op basis van de gebruikerservaringen met de dashboards.
 - Ontwikkeling en eventueel verbreding naar andere cursussen of simulatoren.


Inhoudsopgave

Samenvatting.....	2
1 Inleiding	5
1.1 Doelstelling	5
1.2 Aanpak.....	6
2 Theoretisch kader	7
2.1 Achtergrond van learning analytics	7
2.2 Vormen van learning analytics	8
2.3 Verschillende soorten metingen	9
2.4 Learning analytics in simulator training	10
2.5 Inzetten van learning analytics	11
2.6 Learning analytics op diverse niveaus.....	12
2.7 Rol van instructeurs	13
2.8 Technologische toepassingen	14
2.9 Conclusies	14
3 Resultaten pilot studies LVNL.....	16
3.1 Torensimulator (GND)	16
3.2 Basic Sim (ACS)	23
3.3 Conclusies	24
4 Aanbevelingen	26
4.1 Toepassing van learning analytics bij LVNL.....	26
4.2 Prestatie-indicatoren.....	26
4.3 Implementatie in de praktijk.....	30
4.4 Stappenplan.....	31
5 Referenties	33

1 Inleiding

1.1 Doelstelling

In de opleiding van een luchtverkeersleider worden grote hoeveelheden data opgeslagen in de simulatoren. Op dit moment worden deze gelogde data nog maar weinig gebruikt ter ondersteuning van de opleiding. LVNL wil onderzoeken of deze data waardevolle informatie zouden kunnen geven over de prestaties en voortgang van de leerlingen, en op welke wijze het gebruik van data positief zouden kunnen bijdragen aan het opleiden van leerlingen. In eerste instantie betreft het hier gelogde data, maar ook andere data kunnen belangrijk zijn zoals bijvoorbeeld instructeursbeoordelingen of door leerlingen ingevulde vragenlijsten (bijvoorbeeld ervaren workload of motivationele kenmerken). Het opslaan, analyseren en presenteren van allerlei soorten leerdata wordt ook wel *learning analytics* genoemd (zie figuur 1.1). De informatie die volgt uit analyse van de data wordt doorgaans aan instructeurs en eventueel leerlingen zelf getoond door middel van (deels interactieve) dashboards.



Figuur 1.1 Schematische weergave van het gebruik van learning analytics.

Mogelijke toepassingen van learning analytics in simulatoropleidingen zijn:

- Gepersonaliseerd leren op basis van voortgang, gedrag, aanpak, kenmerken en/of voorkeuren van individuele leerlingen.
- Extra ondersteuning of bewijslast in de vorm van kwantitatieve data in de beoordeling van de prestaties en voortgang van leerlingen.
- Evaluatie van opleidingen, gebaseerd op data van groepen leerlingen.
- Extra ondersteuning en onderbouwing in het selectieproces.

LVNL heeft eerst zelf een verkenning gedaan naar de mogelijkheden voor data-export uit de torensimulator. Dit heeft inzicht gegeven in de hoeveelheid en inhoud van de data. LVNL heeft vervolgens TNO de opdracht gegeven om een verdiepingsslag te maken in de mogelijkheden die deze gelogde data bieden en wat voor eventuele extra of andere mogelijkheden er zijn met betrekking tot learning analytics in simulatoropleidingen van LVNL.

Dit betreft een eerste verkennende stap in de lange termijn ambitie om te komen tot een *Proof of Concept* van een applicatie, waarmee de prestaties van een leerling in een simulator op een nauwkeurige en robuuste manier (automatisch) kunnen worden vastgesteld, gediagnostiseerd, en gepresenteerd. Zo'n applicatie zou het aanbieden van geïndividualiseerde feedback en eventuele remediering mogelijk moeten maken.

1.2 Aanpak

TNO heeft de volgende aanpak gevolgd:

- Enkele gesprekken en bijeenkomsten met LVNL-experts om te verkennen waar de behoeften en mogelijkheden liggen bij LVNL, mede op basis van twee demonstraties van simulatoropleidingen (GND en ACS) verzorgd door LVNL.
- Samenvatten van de state-of-the-art kennis op het gebied van learning analytics, met als focus de toepassing in simulatoropleidingen, waarbij tevens een benchmark met learning analytics toepassingen in andere domeinen (Defensie en Politie) in eerder uitgevoerd TNO-onderzoek (zie hoofdstuk 2).
- Analyseren en visualiseren van data afkomstig uit de torensimulator voor de GND cursus, en een verkenning van mogelijke data voor ACS (zie hoofdstuk 3).
- Samenbrengen van de state-of-the-art kennis en de praktijk van LVNL om te komen tot een set aanbevelingen voor LVNL om verdere stappen te kunnen zetten in learning analytics (zie hoofdstuk 4).


2 Theoretisch kader

2.1 Achtergrond van learning analytics

In het onderwijs wordt steeds vaker technologie ingezet, waardoor er nieuwe mogelijkheden ontstaan om gebruik te maken van big data om het leerproces inzichtelijk te maken (Avella et al., 2016). Door deze ontwikkelingen is er steeds meer interesse gekomen in onderzoek naar en toepassing van learning analytics. Learning analytics verwijst naar het meten, verzamelen, analyseren en rapporteren van data over lerenden en hun context, met als doel het begrijpen en optimaliseren van leren en de omgeving waarin leren plaatsvindt (Ferguson, 2012). Learning analytics wordt ingezet om meer inzicht te krijgen in het leerproces van studenten, om zo gerichte feedback te kunnen geven en positieve effecten te bewerkstelligen op leerprestaties; uiteindelijk leidend tot effectiever onderwijs (Jetten, Peeters, Oprins, & Veldhuis, 2017; Pennings, De Bruijn, Blankendaal & Oprins, in progress).

Clow (2012) en van den Bogaard en collega's (2016) zien learning analytics als een cyclisch proces (zie figuur 2.1). Dat proces begint bij gedrag van studenten (wat is hun achtergrond, welke vaardigheden bezitten ze al, welke cursussen volgen ze, welke resultaten halen ze, etc.). Dit studentgedrag levert resultaten op (bijvoorbeeld over gevolgde cursussen en toets-resultaten), welke geïnterpreteerd kunnen worden met behulp van analyse en visualisatie. Goede visualisaties (bijvoorbeeld in de vorm van een dashboard) zijn van belang, omdat het vaak gaat om grote hoeveelheden data die zo in beeld gebracht moeten worden dat ze gemakkelijk te interpreteren zijn. Op basis van de analyses kunnen voorspellingen gedaan worden bijvoorbeeld over welke studenten in een risicogroep vallen, of welke cursussen of lessen lastig zijn. Deze voorspellingen kunnen gebruikt worden om interventies in te zetten (volgen of juist overslaan van cursussen, aanpassen van cursussen, etc.; Verbert, Duval, Klerkx, Govaerts, & Santos, 2013).

Learning analytics vindt zijn oorsprong in de data science. Onderzoek waarin gekeken wordt naar de bruikbaarheid en toepasbaarheid van onderwijskundige theorieën bij het werken met learning analytics staat nog in de kinderschoenen. In een rapport over learning analytics in het onderwijs (van den Bogaard et al., 2016) wordt aangegeven dat het grootste knelpunt bij learning analytics het verzamelen van de juiste gegevens is: Welke leerdata zijn betekenisvol en relevant om het leerproces in kaart te brengen? In de literatuur zijn nog geen duidelijke methoden beschreven om dit op een systematische manier aan te pakken, omdat dit voor elk domein en elke doelstelling van learning analytics anders is.



Figuur 2.1 De learning analytics cirkel (Clow, 2012; van den Bogaard, 2016).

2.2 Vormen van learning analytics

Twee vormen van learning analytics kunnen onderscheiden worden: *embedded* en *extracted analytics* (Wise, Zhao, & Hausknecht, 2013). Embedded analytics verwijst naar data-analyse en visualisaties in de leeromgeving, die gedurende het leerproces kunnen worden ingezet voor het aanbieden van gepersonaliseerde feedback en interventies. Extracted analytics verwijst naar data-analyse waarvoor de data uit de leeromgeving gehaald wordt voordat er analyses mee gedaan kunnen worden (Wise et al., 2013). Embedded analytics wordt vaak gebruikt om beslissingen te maken namens de mens, terwijl extracted analytics ingezet wordt om de mens te ondersteunen in het maken van beter geïnformeerde beslissingen (Klerkx, Verbert & Duval, 2017). Embedded analytics (bijvoorbeeld computer assisted instruction, CAI) ook beter gemaakt kunnen worden door ervaringen met extracted analytics. Embedded analysemodellen, die geautomatiseerde analyses uitvoeren, zijn vooral bruikbaar voor taken die duidelijke goede of foute antwoorden hebben, omdat het bij dit type taken haalbaar is voor het systeem om het huidige prestatieniveau te beoordelen en te bepalen of een aanpassing in de taak of feedback nodig is. Bij complexere taken, waarbij er meerdere goede antwoorden mogelijk zijn, is het veel lastiger voor het systeem om te bepalen wat juist of onjuist gedrag is.

Volgens Baker (2016) worden systemen die gebruik maken van extracted analytics het meest gebruikt en zijn deze ook het meest succesvol. Dit komt doordat deze systemen de belangrijkste informatie over brengen naar de mens, die deze informatie vervolgens kan gebruiken. Op deze manier maakt het systeem optimaal gebruik van de sterktes en zwaktes van mensen en computers. Mensen zijn flexibel, terwijl computers veel data kunnen verwerken. Systemen die gebruik maken van extracted analyse kunnen een aantal nadelen van compleet autonome systemen overkomen. Allereerst kunnen autonome systemen minder goed om gaan met taken waarbij er geen duidelijk goed of fout antwoord is. Sommige aspecten van leergedrag of leerprestaties kunnen ook nog niet gevangen worden in het systeem.

Ten tweede is het in sommige gevallen goedkoper of meer ethisch verantwoord om gebruik te blijven maken van beoordelingen van instructeurs of studenten, ondanks de mogelijkheden van het systeem. Ten derde kunnen autonome systemen niet herkennen wanneer een model door ongebruikelijke omstandigheden niet klopt. Ten vierde veranderen studenten over de tijd en dit betekent dat geautomatiseerde interventies of feedback mee moeten veranderen. Als laatste kost het veel tijd om een compleet autonoom systeem te ontwikkelen. Ontwikkelingen met betrekking tot lerende artificiele intelligentie zouden hier in de toekomst een rol in kunnen gaan spelen.

Systemen die extracted analyse gebruiken kunnen instructeurs op deze manier aanvullen in hun beoordelingsvermogen. Een risico hierbij is dat dit type analytics een behoorlijke vaardigheid van de instructeur vraagt om de data te kunnen interpreteren en beoordelen. Om optimaal gebruik te maken van de capaciteiten van de instructeurs en het systeem, kunnen embedded en extracted analytics ook worden geïntegreerd. Daarin is het belangrijk om een goede balans te vinden tussen geautomatiseerde analyse door het systeem en subjectievere analyse door de instructeur (Boven, Boer-Visschedijk, Rijk, & Veldhuis, 2019). Het verschilt per domein of de nadruk (meer) moet liggen op het systeem of juist op de inbreng van de instructeur.

2.3 Verschillende soorten metingen

Een grote uitdaging in het toepassen van learning analytics, is het afleiden van het competentieniveau van een lerende puur op basis van observaties van het gedrag. Het gedrag van een lerende komt immers niet alleen voort uit zijn/haar competentieniveau, maar ook uit andere kenmerken, zoals motivatie of ervaren stress. Wanneer een lerende op een tweede oefening slechter presteert dan op een eerste oefening, hoeft dat niet per se te betekenen dat een lerende minder vaardig is geworden. Het kan bijvoorbeeld ook zo zijn dat de leerling verveeld is geraakt door de herhaling. Het gedrag van een lerende als geheel moet worden geïnterpreteerd om te kunnen beoordelen in welke mate een leerling bepaalde competenties bezit (Sottolare, Goldberg, & Ragusa, 2013). De enige manier om hierachter te komen, is door aan de lerende te vragen om het denkproces gedurende een oefening te vocaliseren, of om te reflecteren op de eigen prestatie. Om uit te vinden of een leerervaring inderdaad geleid heeft tot betere prestaties, moet de lerende opnieuw een zelfde soort oefening aangeboden krijgen, om te zien of beter gepresteerd wordt dan de keer daarvoor (Koedinger et al., 2012).

Om de variabelen die leerprestaties beïnvloeden uit elkaar te halen, is het belangrijk om data over deze verschillende kenmerken van een lerende te verzamelen. Op deze manier kan beter beoordeeld worden of een lerende iets niet begrijpt of een vaardigheid niet bezit, of dat een lerende bijvoorbeeld moe of ongemotiveerd is, waardoor minder gepresteerd wordt. Het verzamelen van deze verschillende soorten data is een belangrijk onderdeel van learning analytics. Bij learning analytics wordt vaak gebruik gemaakt van een leermodel waarin verschillende kenmerken van een lerende zijn opgeslagen, zoals vaardigheidsniveau, motivatie, fysiologische aspecten, persoonlijkheidskenmerken, etc. (Van den Bosch, Peeters, & Boswinkel; Jetten et al., 2017). Dit leermodel wordt gebruikt om te bepalen welke leeractiviteit het meest effectief, efficiënt en motiverend is om de leerdoelen die een lerende heeft te bereiken.

Het leermodel probeert te modeleren wat er in het hoofd van de lerende gebeurt. Welke exacte leerdata opgenomen moeten worden in zo'n leermodel, is nog niet duidelijk. Daar zou meer onderzoek naar gedaan moeten worden, zodat op basis van een leermodel gepersonaliseerde feedback gegeven kan worden, en zodat de leeromgeving aangepast kan worden aan de kenmerken van de lerende (Van den Bosch et al., 2017).

Er zijn diverse meetinstrumenten beschikbaar die regelmatig worden ingezet voor het meten van allerlei soorten leerkenmerken en bruikbaar zijn voor learning analytics. Voorbeelden zijn: het meten van workload met behulp van de NASA TLX (Hart & Staveland, 1998) of het meten van motivationele kenmerken en leerstrategieën met behulp van de Motivated Strategies for Learning Questionnaire (MLSQ, Pintrich & De Groot, 1990). Nieuwere en meer experimentele metingen betreft het gebruiken van sensoren. Zo zijn er diverse fysiologische maten die ingezet kunnen worden om workload te meten (Charles & Nixon, 2019). Kijkgedrag kan worden gemeten met behulp van eye-tracking. Resultaten van Moore & Gugert (2010) tonen aan dat hoe langer individuen gefixeerd zijn op een belangrijk vliegtuig, hoe beter de situational awareness was voor dit vliegtuig. Ook de manier van aandacht spreiden had een effect op de situational awareness en prestatie.

2.4 Learning analytics in simulator training

Tot nu toe focussen studies naar learning analytics zich vooral op algemene en theoretische aspecten van learning analytics. Er zijn weinig empirische studies naar de toepassing en effecten van learning analytics uitgevoerd (Viberg, Hatakka, Bälter, & Mavroudi, 2018). Verder bestuderen de meeste studies learning analytics in de context van online leeromgevingen, zoals e-learning of Massive Open Online Courses (MOOCs). Ook wordt learning analytics nog weinig gebruikt in beroepsopleidingen en vooralsnog meer in primair en voortgezet onderwijs.

Veel training in het veiligheidsdomein vindt echter plaats in gesimuleerde omgevingen, van desktop simulatie of serious games tot high fidelity simulatoren. Opleiden in gesimuleerde omgevingen is vooral nodig in het veiligheidsdomein, omdat daar vaak complexe taken moeten worden uitgevoerd in een veiligheidskritische context (Nazir, Sorenson, Øvergård, & Manca, 2015). Door gebruik te maken van simulatoren kunnen verschillende gevaarlijke situaties getraind worden in een veilige, gecontroleerde, maar ook realistische omgeving. Simulatoren verzamelen vaak grote hoeveelheden leerdata, waardoor ze een interessante toepassing voor learning analytics kunnen zijn (Brinkhuis et al., 2018; Long & Siemons, 2011; Papamitsiou & Economides, 2016). Ondanks deze potentie, wordt learning analytics nog nauwelijks toegepast op data uit simulatoren (Pennings et al., in progress; De Bruijn et al., in progress). Het toepassen van learning analytics in simulatoren kan heel waardevol zijn, omdat dat de effectiviteit en efficiëntie van simulator training kan verbeteren door de training beter aan te passen op de behoeften van een individuele leerling.

Hoewel de technologische mogelijkheden steeds geavanceerder worden, is het voor de meeste simulatoren nog niet mogelijk om prestaties en leerprocessen van leerlingen bij te houden of te beoordelen, zeker niet op een geautomatiseerde manier (Bessiris, Kyriakopoulou, Ghajar, & Steuckrath, 2011).

Een belangrijke reden hiervoor is dat het lastig is om betekenisvolle indicatoren te bepalen die inzicht kunnen geven in het prestatieniveau van leerlingen. Zulke prestatie-indicatoren zijn noodzakelijk om de relevante data uit het systeem te halen (Nazir et al., 2015). Het achterhalen van prestatie-indicatoren is met name bij complexe taken lastig, omdat er daarbij niet per se een goed of fout antwoord is. Studies uit andere domeinen, waarin duidelijkere leerdoelen en prestatie-maten te formuleren zijn, kunnen inzicht geven in hoe learning analytics het beste kan worden toegepast in simulatortraining. Deze resultaten en inzichten kunnen vervolgens helpen bij het toepassen van learning analytics in complexere domeinen (Pennings et al, in progress). Er is op dit moment nog veel onduidelijk over wat de beste manier is om relevante data uit het systeem te exporteren, zowel technisch als onderwijskundig (De Bruijn, Blankendaal, Roijendijk, Oprins, & Pennings, in progress).

Het aanbieden van real-time feedback tijdens training wordt gezien als een belangrijke component in effectieve simulatortraining, om drie redenen (Billings, 2012): 1) het verhoogt de motivatie door het verschil tussen huidige en gewenste prestatieniveau aan het te tonen; 2) het vermindert onzekerheid over hoe een lerende presteert, en; 3) het helpt een lerende om te leren hoe een fout verbeterd moet worden. Feedback en beoordelingen worden meestal gegeven door instructeurs. Hoewel zij vaak een goed beeld hebben van wat goede prestaties inhouden, is de beoordeling op deze manier voor een groot deel gebaseerd op een subjectieve maat in plaats van objectieve data (Salas et al., 1998). Learning analytics kan een goede aanvulling zijn op deze subjectieve beoordelingen, waardoor beter geïnformeerde en onderbouwde feedback gegeven kan worden (Klerkx et al., 2017). Simulators kunnen real-time prestaties monitoren gedurende de training. Door het opslaan en ophalen van prestatiedata uit simulators, kunnen leerlingen en instructeurs meer inzicht krijgen in de vaardigheden en competenties die een leerling nog onvoldoende ontwikkeld heeft. Op deze manier kan een training beter aangepast worden aan het niveau en de behoeften van een individuele leerling (Ramírez-Noriega, Juárez-Ramírez, & Martínez-Ramírez, 2017).

2.5 Inzetten van learning analytics

Voor het goed implementeren van learning analytics kunnen zes vragen gesteld worden, om helder te maken voor welke doel je learning analytics in wil zetten en welke resultaten je verwacht (Knight & Buckingham Shum, 2017). Deze gaan in op de overwegingen die genomen kunnen worden bij het inzetten van learning analytics.

1. Wat meten we?
De kennis, vaardigheden of doelen die je in kaart wil brengen.
2. Hoe meten we?
De kwantificering van het gedrag dat je in kaart wil brengen.
3. Waarom is deze kennis belangrijk voor ons?
Om onderscheid te maken tussen zaken die echt waardevol zijn en dingen die makkelijk te meten zijn.
4. Voor wie is de beoordeling?
5. Waar vindt de beoordeling plaats?
De locatie waar de digitale gegevens worden verzameld.
6. Wanneer vindt de beoordeling en feedback plaats?

Dit is gerelateerd aan het verschil in benadering tussen voorspellen van of juist reflecteren op prestaties: real-time feedback of feedback nadat het leren plaatsvond.

2.6 Learning analytics op diverse niveaus

Op basis van de literatuur kan onderscheid gemaakt worden in verschillende niveaus om learning analytics toe te passen in simulatoropleidingen (zie ook Pennings et al., in progress).

2.6.1 *Real-time*

Allereerst kan (near) real-time analyse inzicht geven in leerprocessen van individuele leerlingen (bijvoorbeeld Gašević, Dawson, Rogers, & Gasevic, 2016; Kizilcec & Brooks, 2017). Op deze manier kunnen instructeurs gepersonaliseerde feedback geven en gerichte interventies inzetten, deels gebaseerd op data over de prestaties van een leerling, maar ook op basis van gedrag in de leeromgeving en niet-cognitieve kenmerken van de leerling (Arnold and Pistilli, 2012; Kizilcec, Piech, & Schneider, 2013; Sedkaoui & Khelfaoui, 2019; Wise et al., 2014). Feedback van goede kwaliteit wordt als essentieel gezien in simulatortraining (bijvoorbeeld Ahlborg et al., 2015; Farmer et al., 1999, Marciano, Haugen, Sannerud, & Komulainen, 2019). Het gebruik van learning analytics kan bijdragen aan kwalitatief goede feedback, omdat deze dan niet meer puur gebaseerd is op subjectieve beoordelingen van instructeurs, maar ook op meer objectieve data uit de simulator.

2.6.2 *Lesniveau*

Ten tweede kan learning analytics ingezet worden om informatie over leerprestaties direct na een les terug te koppelen aan de leerling in de debriefing. Op deze manier kan inzicht gegeven worden in de leervoortgang die een leerling maakt. Ook kunnen individuele leerlingen vergeleken worden met prestaties van andere leerlingen. Op basis van deze informatie kan formatieve feedback gegeven worden (vergelijking met een norm aan het eind van een les of leerprogramma) of kunnen voorspellingen gedaan worden over leerprestaties (Brinkhuis et al., 2018; Foltz & Rosenstein, 2017; Papamitsiou & Economides, 2016). Zo kan learning analytics worden ingezet om leerlingen te identificeren die het risico lopen op onderpresteren en hen te voorzien van gepersonaliseerde hulp of feedback (Gašević et al., 2016; Kizilcec et al., 2013; Papamitsiou & Economides, 2016; Sedkaoui & Khelfaoui, 2019; Sønderlund, Hughes, & Smith, 2019).

2.6.3 *Cursus- of opleidingsniveau*

Ten derde kan learning analytics ingezet worden op cursus- of opleidingsniveau waarbij de data van een groep of meerdere groepen leerlingen worden samengenomen. Door deze data op groepsniveau met elkaar te combineren, kunnen evaluaties van cursussen of opleidingen worden uitgevoerd (Drachsler & Kalz, 2016). Zo kunnen oefeningen geïdentificeerd worden waarin de meerderheid van de leerlingen veel fouten maken; deze oefeningen zijn waarschijnlijk moeilijker. Deze informatie kunnen instructeurs en ontwikkelaars gebruiken om aanpassingen te doen in de inhoud of vorm van de cursus of opleiding (Long & Siemons, 2011).

2.7 Rol van instructeurs

Geautomatiseerde feedback op basis van learning analytics kan de beoordelingen en feedback van instructeurs niet zonder meer vervangen (Farmer et al., 1999). Om feedback effectief in te zetten, door de instructeur en/of de simulator, moet deze van voldoende kwaliteit zijn (Ahlborg et al., 2015; Farmer et al., 1999, Marcano et al., 2019). Echter zijn instructeurs zich er niet altijd van bewust dat hun beoordelingen worden beïnvloed door hun eigen level van ervaring en percepties van wat goed of fout is (Manca et al., 2012). Learning analytics kan een bijdrage leveren aan het geven van kwalitatief goede en objectief onderbouwde feedback, door meer inzicht te geven in de prestaties van leerlingen: wat hebben ze al geleerd en welke vaardigheden of competenties moeten nog verder ontwikkeld worden? Zo kan de feedback beter aangesloten worden bij wat een student nodig heeft (Avella, Kebritchi, Nunn & Kanai, 2016; Boven et al., 2019, Ramírez-Noriega, Juárez-Ramírez, & Martínez-Ramírez, 2017).

Learning analytics dashboards zijn een goede manier om instructeurs te ondersteunen bij het geven van gepersonaliseerde feedback over leervooruitgang (Rienties, Cross, & Zdrahal, 2016b; Tempelaar, Rienties, & Giesbers, 2015). Veel studies tonen het potentieel van learning analytics dashboards aan (bijvoorbeeld Heath & Fulcher, 2017; Papamitsiou & Economides, 2016; Schwendimann et al., 2016). Echter moeten instructeurs zich, om gebruik te maken van learning analytics dashboards, bewust zijn van de complexe interactie tussen technologie, pedagogiek en vakspecifieke kennis (Mishra & Koehler, 2006; Rienties & Toetenel, 2016; Verbert et al., 2013). Het is niet eenvoudig om learning analytics dashboards te ontwikkelen die dit inzicht geven en die ook nog leiden tot concrete acties (Schwendimann et al., 2017). Het is complex om instructeurs te voorzien van data visualisaties op basis waarvan ze evidence-based interventies kunnen inzetten. Wat aan deze complexiteit bijdraagt is het feit dat de meeste leeromgevingen verschillende typen data hebben over leerlingen en hun prestaties, waardoor het lastig is om een compleet beeld te krijgen van het leerproces (Heath & Fulcher, 2017; Rienties et al., 2016a). Veel leerkrachten vinden het lastig om de verschillende databronnen en dashboards te interpreteren om betekenisvolle verbanden te leggen tussen de verschillende datacomponenten. Uit onderzoek blijkt dan ook dat veel leerkrachten moeite hebben om learning analytics aanbevelingen om te zetten in concrete acties (Herodotou et al., 2017).

Om die reden is het van belang dat instructeurs worden geholpen om learning analytics dashboards in de praktijk te gebruiken. Dit kan door middel van professionaliseringsactiviteiten waarin ze de vaardigheden ontwikkelen om effectief gebruik te maken van technologie en learning analytics dashboards. Een factor die kan bijdragen aan het actief en effectief gebruik van learning analytics dashboards is acceptatie van technologie (Rienties et al., 2016c). Volgens het Technology Acceptance Model (TAM) is de intentie om learning analytics dashboards te gebruiken afhankelijk van twee factoren (Davis, Bagozzi, & Warshaw, 1989), namelijk: de verwachte bruikbaarheid (de mate waarin instructeurs verwachten dat het gebruik van dashboards bijvoorbeeld de kwaliteit van het lesgeven verbetert) en de verwachte moeilijkheid van gebruik (de moeite die instructeurs verwachten dat het kost om dashboards te gebruiken). Factoren die bijdragen aan de acceptatie van technologie zijn bijvoorbeeld geslacht, ervaring met lesgeven en ervaring met technologie (Teo & Zhou, 2016).

2.8 Technologische toepassingen

Met name in het militaire domein is gestart met technologische toepassingen van learning analytics. Advanced Distributed Learning (ADL) is een programma van het Ministerie van Defensie in de United States (<http://www.adlnet.org>) dat adaptieve trainingssystemen aan het ontwikkelen is en waarbij learning analytics een centrale rol speelt. ADL heeft een Total Learning Architecture (TLA) ontworpen waarin door middel van learning analytics allerlei soorten data kunnen worden gedeeld tussen diverse leersystemen zoals simulatoren en Learning Management Systems (LMS). Hierbij spelen Application Programming Interfaces (APIs) een belangrijke rol, en met name de Experience API (xAPI). Dit betreft een standaard voor het definiëren van leer- en prestatiedata om deze, verzameld in diverse leersystemen, op dezelfde manier te kunnen opslaan en gebruiken (Folsom-Kovarik & Raybourn, 2016). Inmiddels worden wereldwijd steeds meer leersystemen 'xAPI compliant' gemaakt, ook binnen Nederland. Met simulatoren is nu een eerste begin gemaakt in een samenwerking tussen TNO en het Ministerie van Defensie. Simulatoren zijn doorgaans nog niet uitgerust met xAPI of met learning analytics. Dit vereist, ook voor LVNL, verdere softwareontwikkeling bijvoorbeeld in overleg met de fabrikanten. Er zijn wel steeds meer LMS en e-learning applicaties die een learning analytics module bevatten, al dan niet op basis van xAPI.

Een ander Amerikaans initiatief waarmee veel onderzoek wordt gedaan naar learning analytics ten behoeve van gepersonaliseerd leren betreft de open source architectuur: Generalized Intelligent Framework for Tutoring (GIFT; Sottolare et al., 2013). Hierin worden ook nadrukkelijk diverse soorten data, waaronder gelogde data maar ook psychologische en fysiologische data (biometrie) bijvoorbeeld voor het meten van workload of stress, gecombineerd om zo compleet mogelijk een 'learner state' (leerprofiel) samen te stellen.

2.9 Conclusies

Uit de literatuur blijkt dat learning analytics sterk in opkomst is. Er wordt steeds meer wetenschappelijk onderzoek uitgevoerd naar het verzamelen, analyseren en presenteren van leer- en prestatiedata, en ook komen er steeds meer toepassingen beschikbaar in de praktijk. Deze beperken zich vooralsnog vooral tot e-learning, Massive Open Online Courses (MOOCs) en LMS. Learning analytics toegepast in simulatoren staat nog in de kinderschoenen. Dit komt onder andere door technologische beperkingen voor de opslag en export van data. Hier zijn wel ontwikkelingen in, bijvoorbeeld de opkomst van xAPI om data op gestandaardiseerde wijze op te slaan in een Learning Record Store (LRS) en het ontwerpen van dashboards. Veel toepassingen in de praktijk zijn gericht op het kunnen aanbieden van gepersonaliseerd leren en evaluatie van opleidingen. Relevante data om een compleet beeld te kunnen vormen van de lerende (leerprofiel) betreft niet alleen gelogde data, maar ook meer subjectief verzamelde data zoals beoordelingen van instructeurs en ervaringen van leerlingen zelf (bijvoorbeeld vragenlijsten).

Om learning analytics effectief te kunnen inzetten, is het van belang om samen met de gebruikers (bijvoorbeeld instructeurs) de doelstellingen te formuleren en op basis hiervan de juiste data te gaan verzamelen en op een bruikbare wijze te presenteren.

De literatuur heeft uitgewezen dat de mogelijkheden voor learning analytics zeer breed en divers zijn, waardoor het beste is om met de basis te starten, namelijk wat men er op termijn mee wil bereiken en wie waarvoor de informatie gaat gebruiken.

3 Resultaten pilot studies LVNL

In twee pilots is verkend wat de mogelijkheden zijn van het gebruik van gelogde data in simulatortraining ten behoeve van performance measurement: de torensimulator (ground control (GND) cursus) en de Basic Sim (ACS cursus).

3.1 Torensimulator (GND)

3.1.1 Doel

Het project is gestart met het exploreren van de mogelijkheden van het gebruik van gelogde data voor de torensimulator omdat voor deze simulator datafiles uit de simulator geëxporteerd konden worden. LVNL had eerder al handmatige analyses uitgevoerd op enkele datafiles uit deze simulator en zag potentie om dit op een geautomatiseerde wijze verder te onderzoeken. Het doel was daarom om deze bestaande datafiles verder te analyseren om tot betekenisvolle prestatie-indicatoren te komen die inzicht geven in het leerproces van de leerlingen tijdens oefeningen op de Toren simulator. Met deze variabelen kan dan learning analytics worden toegepast op verschillende niveaus (real-time, les, cursus).

3.1.2 Methode

Als eerste hebben LVNL en TNO gezamenlijk afgebakend voor welke doelgroep de analyses zouden worden uitgevoerd. Er is daarbij gekozen om te focussen op oefeningen voor de GND cursus in de Toren simulator, omdat er op korte termijn een cursus plaats zou vinden waar datafiles verzameld zouden kunnen worden door LVNL.

TNO heeft de bestaande datafile en de datafiles die later uit de cursus beschikbaar werden geanalyseerd in Python en een aantal visualisaties gemaakt van deze data. Voor deze analyses is gebruik gemaakt van de Python packages 'Pandas', 'Seaborn', en 'Bokeh'. Ook heeft TNO een demonstratie van de Toren simulator bijgewoond om een beter beeld te vormen over de GND cursus en de taak van de ground controller, want inzicht hierin is belangrijk is voor het toepassen van LA.

Gezamenlijk met LVNL heeft TNO een lijst met variabelen opgesteld die mogelijk een indicatie van de prestatie kunnen geven. Deze lijst is opgesteld in een aantal iteraties met onderwijsexperts binnen TNO en LVNL (o.a. met brainstormsessies). Aan de hand van variabelen uit de vliegdata van de simulator zijn samengestelde ofwel composiet variabelen bedacht die berekend kunnen worden uit deze vliegdata. Een voorbeeld hiervan is de gemiddelde tijd dat een vliegtuig stilstaat tijdens het taxiën. Hiervoor zal met informatie uit de vliegdata (positie en snelheid van het vliegtuig per tijdseenheid) eerst bepaald worden wanneer een vliegtuig taxiëet, waarna berekend kan worden hoeveel tijd het vliegtuig stil heeft gestaan tijdens het taxiën. Dit wordt berekend per vliegtuig en daarna weer gemiddeld om tot de genoemde composiet variabele te komen. Als laatste heeft er een digitale sessie plaatsgevonden met onder andere de GND cursus manager die de lijst met prestatie indicatoren heeft bekeken. In deze sessie werd ook zijn behoefte aan learning analytics geïnventariseerd.

3.1.3 Resultaten

3.1.3.1 Verzamelde simulator data

Er zijn data verzameld tijdens 4 lessen van de GND cursus die plaatsvond eind 2019. De lessen werden uitgevoerd door twee deelnemers (een leerling en een instructeur), die ieder verantwoordelijk waren voor een andere sectie op Schiphol. Er nam maar 1 leerling deel aan deze cursus, waardoor er niet voor meerdere deelnemers data verzameld kon worden. De beschikbare dataset kwam uit AT-Tower (de kern van de simulatie software). Daarbij was zowel een file met vliegplandata (Astra-data) beschikbaar als een file met piloot commando's waarmee gezien kan worden wanneer piloten bepaalde acties uitvoerden. De nadruk in het project heeft gelegen op het vaststellen van interessante composiet variabelen die uit de vliegplandata gehaald kunnen worden. In de vliegplandata wordt per seconde informatie over alle aanwezige vliegtuigen/voertuigen op Schiphol vastgelegd aan de hand van een hele reeks variabelen, waarvan de meest interessante: positie x-as, positie y-as, snelheid, heading, vliegtuigtype (waaruit light/medium/heavy is af te leiden), verwacht moment van aankomst en vertrek. Voor nu was het nog niet mogelijk om het vliegverkeer afgehandeld door de leerling te scheiden van het verkeer afgehandeld door de instructeur. Er lijken echter wel mogelijkheden te zijn om dit technisch voor elkaar te krijgen door de piloot commandodata te gebruiken, waarin het zichtbaar is wanneer vliegtuigen worden overgedragen naar een andere sectie.

Data uit de randsystemen (Voice Communication System, CCIS, Baanbaken panel, frequenties, baanverlichting, etc.) zouden ook kunnen bijdragen aan learning analytics, maar zijn niet meegenomen omdat hiervan nog geen data beschikbaar was. Deze data zijn mogelijk interessant, om bijvoorbeeld te laten zien wie verantwoordelijk is voor welk vliegtuig op welk moment. In principe is het zo dat een vliegtuig alleen aan een volgende verantwoordelijke wordt overgedragen wanneer deze 'conflictvrij' is, waarmee deze data dus informatie kan geven over de duur van handelen. Daarnaast zou ook het communicatiegedrag (het aantal gevoerde RT calls en de gemiddelde duur) afgeleid kunnen worden uit het Voice Communication System.

3.1.3.2 Prestatie-indicatoren

Onderstaande lijst geeft een overzicht van mogelijke composietvariabelen die inzicht zouden kunnen geven in het leergedrag van de leerlingen afgeleid uit de vliegdata. Het doel is om met deze prestatie-indicatoren inzicht te kunnen geven in de competenties van de leerlingen, gericht op een veilige en efficiënte verkeersafhandeling. Een groot aantal variabelen wordt berekend per vliegtuig, waarna er een gemiddelde of een som over de vliegtuigen in een oefening berekend kan worden. Dit gemiddelde kan dan weer vergeleken worden tussen leerlingen of met een expert.

Tabel 3.1 Composietvariabelen vliegdata GND cursus.


Composietvariabelen uit vliegdata
Totaal aantal afgehandelde vliegtuigen (inbound, outbound)
Volgorde opstijgen en landen van vliegtuigen (inbound, outbound)
Volgorde van type vliegtuigen die opstijgen en landen (inbound, outbound)
Afstand tussen startende of aankomende vliegtuigen (inbound, outbound)
Aantal incidenten af te leiden uit routes
Aantal keer separatieminima tussen vliegtuigen overschreden
Afgelegde route per vliegtuig (inbound, outbound)
Getaxiede afstand per vliegtuig (inbound, outbound)
Aantal keer stilstaan tijdens taxiën per vliegtuig (inbound, outbound)
Duur stilstaan tijdens taxiën per vliegtuig (inbound, outbound)
Aantal intersecties gebruikt voor take-off per vliegtuig (outbound)
Aantal alternatieve pushbacks per vliegtuig (outbound)
Delta geplande T/O tijd t.o.v. werkelijke T/O tijd
Delta geplande aankomsttijd t.o.v. werkelijke aankomsttijd

3.1.3.3 Visualisaties

Diverse afbeeldingen zijn gemaakt om een indruk te geven van de mogelijkheden van learning analytics voor de GND cursus.


Real-time niveau

Veel van de composietvariabelen kunnen berekend worden per vliegtuig en daarmee ook gevisualiseerd worden per vliegtuig. Figuur 3.1 is daar een voorbeeld van. In deze afbeelding staat per vliegtuig de taxiduur van de uitgaande vliegtuigen in minuten weergegeven. De volgorde waarin de vliegtuigen gepresenteerd zijn in de grafiek, geeft de volgorde waarin de vliegtuigen zijn afgehandeld weer. De groene stippellijn laat de gemiddelde taxiduur zien. Deze grafiek maakt zichtbaar of er vliegtuigen zijn geweest die extreem lang getaxied hebben. Wanneer de taxi duur langer is of langer dan verwacht voor een bepaalde taxi route, kan dit inzicht geven of de luchtsverkeersleider het vliegverkeer efficiënt heeft gestroomlijnd. Om inzicht te geven in een specifieke oefening voor een specifieke leerling kunnen dit soort visualisaties gemaakt worden. De patronen binnen een oefening zouden vergeleken kunnen worden met andere leerlingen, door voor meerdere leerlingen deze visualisaties te maken, of informatie van meerdere leerlingen te combineren binnen een afbeelding.

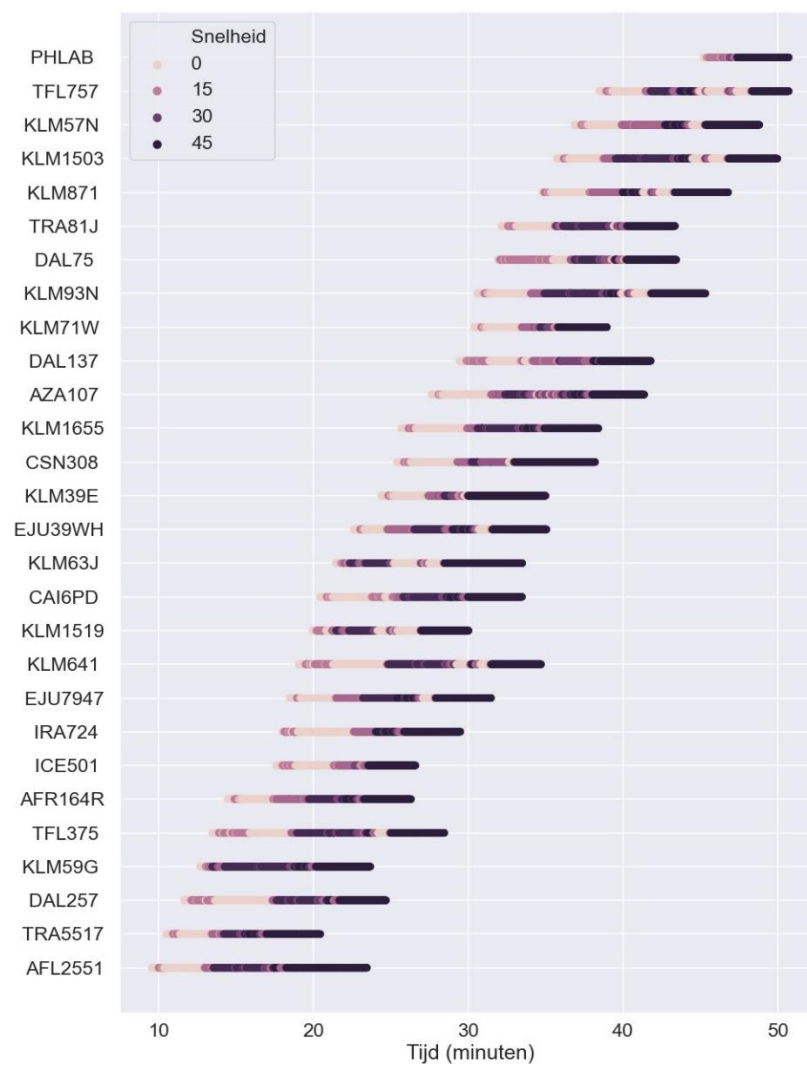


Figuur 3.1 Taxi duur in minuten per vliegtuig en gemiddeld over alle vliegtuigen (groene stippellijn) in één oefening. De vliegtuigen staan op de horizontale as in volgorde van afhandelen.

Een andere mogelijkheid is het visualiseren van de routes van de vliegtuigen waarbij extra informatie wordt weergegeven in kleur (bijvoorbeeld de snelheid). Hier kan onder andere mee gevisualiseerd worden wanneer taxiënde vliegtuigen stil komen te staan. Figuur 3.2 laat deze afbeelding zien voor alle vliegtuigen in een oefening. Een dergelijke afbeelding zou gemaakt kunnen worden voor een combinatie van specifieke vliegtuigen of specifieke momenten in een oefening, waarmee een instructeur een leerling achteraf nog kan laten zien wat er speelde op dat moment in de oefening. Een andere manier om de snelheden van de vliegtuigen per vliegtuig weer te geven is geïllustreerd in Figuur 3.3.




Figuur 3.2 Visualisatie van de vliegtuigroutes met bijbehorende snelheden van een oefening (outbounds).



Figuur 3.3 Overzicht over tijd van de snelheid per vliegtuig binnen een oefening (outbounds).


Naast afbeeldingen is het ook mogelijk om een interactief dashboard te ontwikkelen, waarmee het makkelijker is om ook de tijd-dimensie goed te visualiseren. Figuur 3.4 toont een screenshot van een versimpelde versie van een dergelijk interactief dashboard, waarin de routes van de vliegtuigen versneld kunnen worden afgespeeld (en gepauzeerd). In het voorbeeld worden inbound en outbound vliegtuigen met een verschillende kleur weergegeven. Met een dashboard zou een instructeur met een leerling de oefening terug kunnen kijken en zijn advies onderbouwen met de objectieve data. In het dashboard kan belangrijke informatie voor de ground controller worden gevisualiseerd. De vliegtuigen zouden bijvoorbeeld een verschillende kleur kunnen krijgen naar zwaarte of er kunnen meldingen komen wanneer vliegtuigen te dicht achter elkaar hebben gereden. Meer onderzoek is nodig om een dergelijk dashboard verder te ontwikkelen.




Figuur 3.4 Screenshot van interactief dashboard waarop de vliegroutes versneld afgespeeld kunnen worden. Het type verkeer (inbound, outbound) wordt weergegeven met een kleur.

Lesniveau

Doordat er maar voor 1 leerling data beschikbaar was, was het niet mogelijk om afbeeldingen te creëren waarin leerlingen vergeleken worden met elkaar. Figuur 3.5 en Figuur 3.6 geven daarom voorbeelden weer hoe dergelijke informatie gevisualiseerd kan worden met fictieve data. In Figuur 3.5 wordt een staafdiagram gebruikt om een composiet variabele te visualiseren en in Figuur 3.6 een lijngrafiek waarin ook het gemiddelde wordt weergegeven.



Figuur 3.5 Inbound taxi afstand per oefening voor 2 verschillende leerlingen.



Figuur 3.6 Inbound taxi afstand per oefening voor vier verschillende leerlingen, inclusief gemiddelde.

3.1.4 Discussie

In een feedbacksessie, waarin de visualisaties zijn getoond aan onder andere de GND cursusmanager, is gediscussieerd over de lijst van composietvariabelen en de gemaakte afbeeldingen. De belangrijkste conclusie is dat de taak van de GND verkeersleider te complex is om de prestaties volledig uit te drukken in absolute waarden, afkomstig uit de vliegplandata. Daarmee zijn de gelogde data in de GND cursus niet voldoende representatief om als (enige, belangrijkste) maten voor de prestaties van leerlingen gebruikt te kunnen worden.

Deze complexiteit wordt vooral veroorzaakt door de grote variatie en variabiliteit in de taak van de GND verkeersleider. Er bestaan vele werkwijzen en oplossingen om dezelfde (verkeers)situatie veilig en efficiënt af te handelen. Bovendien is de taak zeer dynamisch. Dit houdt in dat een bepaalde verkeersafhandeling tot nieuwe situaties leidt, die voor elke individuele verkeersleider verschillend kunnen zijn. Dit vertaalt zich door naar de oefeningen in een opleiding.

Een oefening zal steeds verschillend verlopen, afhankelijk van de werkwijze en oplossingen die de leerling kiest. Het standaard scenario van de oefening kan ook in real-time nog aangepast worden door de instructeurs om te zorgen dat de leerling toch de leerdoelen van een les kan behalen. Bovendien is het soms lastig om de data goed te interpreteren omdat oefeningen door meerdere leerlingen tegelijk worden uitgevoerd (vaak 3 tegelijk) en daarmee kunnen leerlingen ook invloed hebben op elkaars prestatie. Het zou interessant zijn om juist deze verschillen met behulp van learning analytics inzichtelijk te maken.

De aan te leren taken in de Unit Training, waaronder de GND cursus, zijn over het algemeen complexer dan in de Initial Training. Als de taak eenvoudiger is, zijn er minder mogelijke opties om situaties in een scenario verschillend af te handelen. Naarmate een taak meer procedureel is, kunnen vaststaande maten zoals afgeleid kunnen worden uit vliegplandata gemakkelijker als prestatie maat worden gebruikt.

Gelogde data in het leerproces kunnen altijd wel wat extra informatie opleveren indien deze tijdens of direct na de oefening beschikbaar komen zodat de coaching hierop kan worden aangepast. Een vergelijking van leerdata tussen leerlingen op oefening- of cursusniveau kan wel interessant zijn indien de leerlingen dezelfde taak uitvoeren. De informatie kan dan gebruikt worden om de simulatieoefeningen te evalueren. In de toekomst komen er mogelijk ook stand alone simulaties, waar niet altijd een instructeur bij zal zijn. Automatische feedback voor de leerling is in dat geval zeker nuttig, maar de complexiteit van de taak zal blijven.

Vanwege de beperkingen in de aangeleverde dataset alsmede de ervaren complexiteit van de GND taak is besloten om ook de mogelijkheden voor learning analytics bij andere LVNL-simulatoren te verkennen.

3.2 Basic Sim (ACS)

3.2.1 Doel

Als tweede optie voor het exploreren van learning analytics is gekozen voor de ACS cursus van de Initial Training omdat de verwachting is dat radar functies minder vrijheidsgraden hebben in de operationele taakuitvoering waardoor het makkelijker zou kunnen zijn om de afwijking van de standaard waar te nemen. Tevens doorlopen meerdere leerlingen per jaar deze module (2 groepen van 8 trainees per jaar).

3.2.2 Methode

Er is een beperkte verkenning uitgevoerd om de learning analytics mogelijkheden voor de Basic Sim in kaart te brengen. Hierbij is als eerste gekeken naar de mogelijkheden van het extraheren van data uit de simulator. Daarnaast heeft er een digitale demonstratie sessie plaatsgevonden van de simulator door een instructeur. Ook zijn twee video-opnames van lessen met trainees aangeleverd.

3.2.3 Resultaten

3.2.3.1 Simulatie data

Uit de simulator komt maandelijks een datafile beschikbaar, waar de gebruikstijd van Basic Sim posities wordt gelogd. Daarnaast heeft de simulator een display ingebouwd dat een instructeur aan het einde van een oefening kan raadplegen met informatie, zoals het aantal separatieonderschrijdingen en de hoeveelheid verkeer

per tijdsinterval. Deze informatie wordt echter niet gelogd. Ook vliegdata of gebruikersdata wordt niet gelogd, waardoor het momenteel niet mogelijk is om learning analytics toe te passen.

3.2.3.2 *Prestatie-indicatoren*

Gebaseerd op de aangeleverde informatie, hierbij een overzicht met mogelijk interessante prestatie-indicatoren voor de ACS cursus:

Vliegdata:

- Hoeveelheid verkeer afgehandeld in een bepaald (in te stellen) tijdsinterval, uitgesplitst in type verkeer (inbound, outbound, overflight);
- Locatie (x,y,z) over tijd per vliegtuig;
- Snelheid over tijd per vliegtuig;
- Aantal (bijna) overtredingen separatieminima per vliegtuig.

Verkeersleider toetsenbord/muis gedrag:

- Aantal keer klikken op vliegtuigen voor extra informatie;
- Aantal keer oproepen van vliegtuigen;
- Volgorde van klikken op vliegtuigen;
- Aantal keer meten van afstanden met digitale liniaal.

Piloot data:

- Hoeveelheid en type commando's van piloten (nader onderzoek nodig om te bepalen wat interessant is).

3.2.4 *Discussie*

Tijdens de discussie in diverse emails en na afloop van de toelichting van de ACS cursus en demonstratie kwamen vergelijkbare punten naar voren als reeds besproken voor de GND cursus. Dit betreft in de eerste plaats (opnieuw) het gebrek aan beschikbare data die (nog) niet eenvoudig uit de Basic Sim geëxporteerd kunnen worden. Hierdoor kan er nog geen learning analytics worden uitgevoerd. In de tweede plaats vindt men het, zeker zonder voorbeelden, lastig om zich een voorstelling te maken van wat learning analytics kan betekenen, ook op de hogere niveau's zoals vergelijkingen tussen leerlingen op les- of cursusniveau. Net als bij GND zijn er ook bij ACS meerdere werkwijzen en oplossingen mogelijk, waardoor elke oefening anders verloopt bij verschillende leerlingen. Daarom vertrouwen de instructeurs meer op hun eigen subjectieve totaalbeeld van de prestaties van de leerlingen. Beschikbare data en op basis hiervan het ontwikkelen van enkele voorbeeldtoepassingen zijn nodig om de mogelijke meerwaarde van learning analytics in de Initial Training (en ACS in het bijzonder) te kunnen onderzoeken.

3.3 **Conclusies**

Uit de pilots bij GND en ACS, alsmede de diverse gesprekken hierover, kan worden geconcludeerd dat learning analytics potentie heeft voor gepersonaliseerde coaching, zelfstandig oefenen in stand-alone simulators, en cursusevaluatie in de toekomst. Met name het vergelijken van prestaties van leerlingen onderling of verschillen tussen oefeningen is interessant, waarbij het gebruik van aanvullende informatie zoals beoordelingen van instructeurs onontbeerlijk is. Het zuiver baseren op gelogde prestatiedata, zoals de variabelen die zijn afgeleid van de vliegplandata, is echter te beperkt om een goed beeld te vormen van de prestaties en competentie-ontwikkeling van leerlingen bij het aanleren van luchtverkeersleidingstaken.

Dit geldt niet alleen voor cursussen in de Unit Training (bijvoorbeeld GND) maar ook voor de relatief minder complexe taken die aangeleerd worden in de Initial Training (bijvoorbeeld ACS). Een radartaak (zoals ACS) en de taken op de toren (zoals GND) worden als vergelijkbaar ervaren voor wat betreft complexiteit en dynamiek in het aanleren hiervan. Dit maakt het komen tot eenduidige prestatie-maten puur op basis van gelogde data extra uitdagend.

Het gebruik van gelogde data vereist echter het technisch kunnen exporteren van data uit de simulatoren. De huidige simulatoren bij LVNL zijn nog niet goed toegerust voor het toepassen van learning analytics. Indien er grote hoeveelheden data, van meerdere leerlingen en cursussen, beschikbaar zouden zijn, aangevuld met andersoortige data zoals instructeursbeoordelingen, zouden op basis van de data de bredere mogelijkheden van learning analytics getoond kunnen worden aan instructeurs en cursusmanagers. Doordat dit nu nog niet mogelijk was, bleven de discussies over de potentie van learning analytics wat abstract in de (beperkte) pilots.

4 Aanbevelingen

4.1 Toepassing van learning analytics bij LVNL

Op basis van de literatuur (zie paragraaf 2.6) en eerdere ervaringen van TNO met learning analytics in simulatortraining bij andere domeinen, bijvoorbeeld de Tactical Indoor Simulation (TACTIS) voor (schiet)training van militairen (zie voorbeelden en visualisaties in Pennings et al., in progress) en de brugsimulator van de marine (work in progress), kunnen diverse niveaus van toepassing worden onderscheiden die ook relevant zijn voor LVNL (zie tabel 4.1):

Tabel 4.1 Toepassingsmogelijkheden van learning analytics bij LVNL in simulatortraining.

Wanneer	# Leerlingen	Doelstelling	Inzage	Inhoud
1. Real-time	1 leerling	Bijsturing tijdens de oefening (personalisatie)	Instructeur Leerling	Specifieke events
2. Na elke oefening	1 - 2 leerlingen	Debriefing: reflectie met leerlingen die dezelfde oefening gedaan hebben	Instructeurs Leerlingen	Informatie oefening Prestaties leerling(en)
3. Na/tijdens een cursus	Hele groep	Monitoren voortgang leerlingen & beoordeling Evaluatie van een specifieke cursus	Instructeurs Cursus-manager	Informatie cursus Prestaties leerlingen
4. Na meerdere cursussen	Alle groepen	Algehele evaluatie Managementinformatie over alle leerlingen	Cursus- en Training-managers	Overzicht cursussen Overzicht leerlingen

In de pilots beschreven in hoofdstuk 3 is vooral aandacht besteed aan het tweede niveau, namelijk het gebruik van gelogde data direct na een oefening, met een beperkt uitkijkje naar de andere niveaus. Niveaus 3 en 4 zijn echter voor LVNL mogelijk nog meer relevant. Op niveau 3 worden op dit moment ook de instructeurs-beoordelingen reeds geanalyseerd en (soms) gepresenteerd. De wijze waarop de prestatie en competentieontwikkeling wordt gemeten, hangt af van de indicatoren die iets zeggen over prestaties en competenties.

4.2 Prestatie-indicatoren

4.2.1 Soorten metingen

Het goed toepassen van learning analytics vraagt om een duidelijke definitie van indicatoren die inzicht geven in het prestatieniveau en competentieontwikkeling van leerlingen. Diverse soorten metingen moeten met elkaar worden gecombineerd om een zo compleet mogelijk beeld te verkrijgen.

Het hangt sterk af van het type taak in hoeverre prestaties duidelijk gevat kunnen worden in objectieve data zoals gelogd in een simulator. Naarmate een taak meer procedureel, gesloten ('closed-looped') en enkelvoudig is, is dit gemakkelijker dan voor taken die meer open ('open-looped') en complex zijn en creativiteit of

probleemoplossend vermogen eisen. Simulaties met geautomatiseerde feedback, puur op basis van gelogde data, zijn dan ook meestal gericht op part-task training van bepaalde procedures. Dit geldt bijvoorbeeld ook voor de eerder onderzochte simulator TACTIS: alleen de part-task trainer waarin individuele schiettechniek wordt geoefend, verloopt geautomatiseerd. Binnen de luchtverkeersleiding zien we dit bijvoorbeeld bij bepaalde selectietests zoals DART, die ook geheel automatisch verloopt met prestatie-indicatoren gericht op veiligheid en efficiency. Het is lastig om bij een complexe luchtverkeersleidingstaak geautomatiseerde modellen te gebruiken, omdat zonder gekwantificeerde variabelen niet geprogrammeerd kan worden of bepaald gedrag goed of fout is. Reeds in de jaren '80 is onderzoek verricht naar geautomatiseerde prestatiemetingen in simulatoren (bijvoorbeeld Farmer et al., 1999) maar dit is altijd een uitdaging gebleven voor complexe taken.


Om deze reden is uitsluitend het gebruik van gelogde data te beperkt in de complexe luchtverkeersleidingstaken om valide uitspraken te kunnen doen over de ontwikkeling van competenties van leerlingen. De instructeursbeoordelingen zouden daarom leidend moeten blijven in het monitoren van de competentieontwikkeling van leerlingen over de tijd. Gelogde data kunnen extra, evidence-based, onderbouwing geven bij de meer subjectieve beoordeling van instructeurs. Daarnaast kunnen subjectieve ervaringen van de leerlingen zelf waardevol zijn. Zo kunnen vragenlijstdata interessante informatie bieden over het leerproces, zoals ervaren workload of bepaalde motivationele kenmerken. Een zelfbeoordeling op competenties geeft ook veel inzicht in de wijze waarop leerlingen hun eigen competentieontwikkeling zien. Binnen LVNL is dit al vaker toegepast. Gebruik van diverse type data komt niet alleen uit de literatuur maar ook praktijkervaringen bevestigen de meerwaarde (zie onderstaand kader).

In de toekomst zullen ook andere meetmethoden beschikbaar komen die het mogelijk maken om meer objectieve informatie te verzamelen. Het toepassen van fysiologische metingen (bijvoorbeeld hartslag) zal toenemen (onder andere door de opkomst van wearables) om bijvoorbeeld meer informatie te verkrijgen over de mate van workload die leerlingen ervaren. Eye tracking om oogbewegingen te kunnen registreren (zoals bij de KLU reeds is toegepast) kan binnen de luchtverkeersleiding extra interessant zijn omdat leerlingen voortdurend het verkeer moeten scannen en hun aandacht moeten verdelen ten behoeve van hun situational awareness.


Voorbeeld Tactical Indoor Simulation (TACTIS)

De cursus schiettechniek in TACTIS, bedoeld voor schutters in een CV90 voertuig, is gebruikt voor een experiment learning analytics bij het Ministerie van Defensie. Diverse soorten data van 66 cursisten, verdeeld over 4 cursussen, zijn verzameld. Dit betrof een complexe set gelogde data, workloadmetingen (NASA TLX), en motivationele kenmerken (MSLQ). Ook zelfbeoordelingen door de cursisten zijn meegenomen. Relaties tussen workload, motivatie en prestaties zijn aangetoond. Diverse voorbeeld dashboards zijn in ontwikkeling om uiteindelijk een learning analytics applicatie te kunnen ontwikkelen (Pennings et al., in progress; De Bruijn et al., in progress).

Voorbeeld 1: eindscore van twee leerlingen voor alle (achtereenvolgende) lessen.



Voorbeeld 2: gemiddelde scores NASA TLX voor alle cursisten voor alle lessen:



4.2.2 Objectieve maten

In de uitgevoerde pilots is gefocust op gelogde data die op basis van een bepaalde oefening verzameld zijn (2^e niveau in tabel 1). Composietvariabelen (combinaties, optellingen) dienen te worden opgesteld om daadwerkelijke indicatoren die iets zeggen over de prestaties van leerlingen te verkrijgen. Dit geldt voor alle niveaus waarop learning analytics wordt toegepast waarbij bijvoorbeeld ook gemiddelden over leerlingen of over lessen kunnen worden berekend. Bij voorkeur dienen de objectieve data gerelateerd te kunnen worden aan de competenties waarop de leerlingen toch al worden beoordeeld, om de gelogde data als ondersteuning in de

coaching of beoordeling te kunnen gebruiken. Zo kunnen de gelogde data extra informatie bieden over de veiligheid en efficiency van de verkeersafhandeling. Tabel 4.2 geeft enkele voorbeelden die specifiek uitgewerkt zouden moeten worden voor de diverse type taken (toren of radar).

Tabel 4.2 Voorbeelden van objectieve metingen, gekoppeld aan competenties.

Competentie	Metingen	Mogelijke maten
Efficiency	Vliegplandata	Capaciteit: aantal afgehandelde vliegtuigen per tijdseenheid (inbounds, outbounds)
		Gevlogen routes (visualisatie in 2D of 3D)
		Afgelegde afstand (gemiddeld per vliegtuig)
		Tijd: mogelijke vertraging of versnelling
		Aantal variaties in snelheid, hoogte, richting
	Radiotelefonie	Aantal en lengte van de RT-calls
	Systeem input	Aantal invoeren in het systeem
Veiligheid	Vliegplandata	Aantal (bijna) overschreden separatieminima (afstand, hoogte)
		Aantal (extra) conflicten
Workload management	Radiotelefonie	Aantal en 'toon' van de RT-calls
		Tijd tussen bepaalde events en RT-calls
	Systeem input (sensoren)	Tijd tussen RT-calls en betreffende invoer (fysiologische metingen voor werklast)
Situationeel awareness	Systeem input	Aantal en variatie in clicks op vliegtuigen
	(eye-tracking)	(variatie in scannen van vliegtuigen)

In de discussies is naar voren gekomen dat dergelijke maten voor een bepaalde oefening niet zo representatief zijn omdat de verkeersafhandeling per leerling verschilt. Bovendien heeft een bepaalde actie direct weer invloed op de verkeerssituatie die volgt. Daarom zouden in eerste plaats niet de *absolute* waarden moeten worden beschouwd, maar *relatieve* waarden, namelijk: composietvariabelen gebaseerd op combinaties van bovengenoemde metingen, en opgeteld over meerdere oefeningen of een hele cursus (3^e en 4^e niveau in tabel 4.1). Dergelijke composietvariabelen, in relatieve vorm, kunnen worden gebruikt om verschillen tussen leerlingen in kaart te brengen en hiermee gerelateerd worden aan competenties zoals bijvoorbeeld de algehele efficiency van de verkeersafhandeling. Zo'n composietvariabele bestaat dan bijvoorbeeld uit meerdere indicatoren voor efficiency die (in een bepaalde verhouding) worden 'opgeteld' vanuit de vliegplandata (capaciteit plus afgelegde afstand, etc.) en wellicht ook in combinatie met andere type data zoals de radiotelefonie en systeem input. Hoe hoger het abstractieniveau (bijvoorbeeld over meerdere oefeningen heen), hoe robuuster de maat zal zijn, en hiermee de representativiteit voor de competentieontwikkeling. Zo zal een leerling die bijvoorbeeld drie keer zoveel RT-calls gebruikt met een gemiddeld veel langere afgelegde afstand per vliegtuig minder efficiënt te werk gaan dan een andere leerling. Dit kan de instructeur weliswaar ook observeren maar met behulp van gelogde data bovendien extra onderbouwen, objectief en evidence-based. Dergelijke overzichten van de competentieontwikkeling kunnen meer inzicht geven in het leerproces, bijvoorbeeld hoe een leerling zich ontwikkelt over de tijd en hoe hij/zij presteert ten opzichte van andere leerlingen.

Het is wel van belang om de prestatie-maten daadwerkelijk te valideren. Dit kan bijvoorbeeld door bij data van een groot aantal leerlingen de relaties te bekijken tussen de beoordeelde competenties door instructeurs en/of leerlingen zelf, en de objectieve data. Wanneer grote hoeveelheden data beschikbaar zijn, kan getoetst worden welke maten het beste de prestaties en de voortgang van een leerling voorspellen. Tegenwoordig bestaan er nieuwe (statistische) methoden om dit op een efficiënte wijze te doen zoals machine learning en data mining. Deze methoden zijn vooral nuttig indien er vanuit de LVNL simulatoren grote hoeveelheden data opgeslagen en geëxporteerd kunnen worden. Een mogelijke technologie, die weliswaar niet noodzakelijk is maar het opslaan en exporteren van leerdata wel gemakkelijker kan maken, betreft de standaard xAPI. Het verdient aanbeveling om deze ontwikkeling te volgen.

4.2.3 Kritische gebeurtenissen

Een andere mogelijkheid is om data te gebruiken die gericht zijn op het verbeteren van situational awareness op basis van kritische gebeurtenissen. Dit betreft een hele andere manier om met data om te gaan, in dit geval gebaseerd op een specifieke oefening. Zie kader voor een voorbeeld bij de marine.

Voorbeeld brugsimulator (marine)

Voor de brugsimulator bij de Nederlandse marine is TNO bezig met het ontwikkelen van learning analytics toepassingen die lerenden en instructeurs helpen inzicht te krijgen in het situationeel bewustzijn (Endsley, 1995) tijdens scheepsnavigatie-taken. Hier zal onder andere data uit de Ship Handling Simulator (SHS) voor worden gebruikt. Net als bij LVNL, zijn de lessen die gegeven worden op deze simulator dynamisch: leerlingen worden niet allemaal met dezelfde verkeerssituaties geconfronteerd, doordat de keuzes die ze maken het scenario beïnvloeden. Binnen een scheepsnavigatieles komen gebeurtenissen voor waar een student op zou moeten handelen om te voorkomen dat er ongelukken gebeuren; dit worden kritische gebeurtenissen genoemd (Fowlkes et al., 1998). In het geval van de SHS ontstaat een kritische gebeurtenis bijvoorbeeld wanneer een ander schip binnen een bepaalde afstand van het eigen schip komt. Voor een specifieke les zullen instructeurs tijdens de les (die door meerdere studenten zal worden uitgevoerd) informatie gaan vastleggen over de kritische gebeurtenissen (wanneer deze voorkomen) en het gedrag van de student (hoe hij/zij hiernaar handelt), dat als context zal dienen om de simulator data te interpreteren. Er wordt een dashboard ontwikkeld waar gegevens uit de simulator, zoals de snelheid en vaarkoers van het schip en het kijkgedrag met de verrekijker, worden gecombineerd met de context informatie (de gebeurtenissen). Dit dashboard zal de instructeur kunnen helpen om het situationeel bewustzijn van de leerling beter te beoordelen en kan na een oefening objectief inzicht geven aan een student over zijn/haar gedrag. De instructeursbeoordelingen kunnen op les en cursus-niveau geanalyseerd worden om inzicht te krijgen hoe het situationeel bewustzijn over tijd verandert.

4.3 Implementatie in de praktijk

Nut en noodzaak van het toepassen van learning analytics kan niet worden bepaald zonder de inbreng van de gebruikers. Dit zijn in eerste plaats de leerlingen zelf, bijvoorbeeld als zij real-time feedback zouden kunnen krijgen op basis van data, of visualisaties in een dashboard waarin leerlingen zelf inzicht krijgen in hun voortgang en leerproces. Daarnaast zijn de instructeurs, cursus- en trainingsmanagers belangrijke gebruikers. Zij zijn immers degenen die de learning

analytics data gebruiken, interpreteren en op basis daarvan acties ondernemen om leerlingen te ondersteunen of om een opleiding te verbeteren. In dit geval gaat het om extra informatie over het leerproces in de vorm van gelogde data of self-ratings van de leerlingen naast het reeds bestaande beoordelingssysteem. Instructeurs zijn zich er niet altijd van bewust dat hun beoordelingen worden beïnvloed door hun eigen level van ervaring en percepties van wat goed of fout is. Learning analytics kan een bijdrage leveren aan het geven van objectief onderbouwde feedback en een breder beeld van de leerkenmerken van de lerende. Dit maakt personalisatie mogelijk op allerlei manieren, niet alleen gericht op prestaties maar ook 'zachtere' kenmerken zoals bijvoorbeeld leervoorkeuren en zelfvertrouwen. Cursus- en trainingsmanagers kunnen een beter overzicht krijgen over groepen leerlingen en cursussen door middel van learning analytics.

Zoals aangegeven in paragraaf 2.7 is het voor instructeurs niet altijd even eenvoudig om data te begrijpen en interpreteren. Voorbeelden van mogelijke dashboards, duidelijk herkenbaar, eenvoudig en gevisualiseerd, kunnen helpen om dit begrip te verbeteren. In steeds meer onderzoeken wordt gekeken naar de manier waarop learning analytics resultaten op een voor instructeurs effectieve en bruikbare manier gevisualiseerd kunnen worden. Deze zijn voor LVNL zeker ook toepasbaar. Instructeurs dienen bovendien goed te worden begeleid in het begrijpen van de data. Voor een begrip in mogelijke toepassing van learning analytics in de breedte kan ook worden gestart met een relatief eenvoudigere leeromgeving dan simulatoren zoals e-learning of LMS waarin meer theoretisch wordt geleerd. Het exporteren van data is in dergelijke systemen over het algemeen gemakkelijker.

Het verdient aanbeveling om eerst in kaart te brengen welke informatie over leerlingen relevant is in de breedte (niet beperkt tot gelogde data) en op welk moment de informatie nodig is, bijvoorbeeld: debriefing na een oefening of les, het gepersonaliseerd aanbieden van oefeningen of opleiding, (bredere) coaching op bepaalde competenties, beoordelen van leerlingen, evalueren van een cursus, trendanalyse van prestaties of andere kenmerken over groepen leerlingen, etc. Vervolgens kan worden nagedacht over de wijze waarop de informatie gepresenteerd of (bij voorkeur) gevisualiseerd kan worden bijvoorbeeld in de vorm van dashboards. Dit biedt de basis om daadwerkelijk aan de slag te gaan met een selectie van mogelijk relevante data.

4.4 Stappenplan

Er dienen nog diverse stappen gezet te worden voordat learning analytics bij LVNL geïmplementeerd kan worden. Het uitgangspunt, afgestemd met de eindgebruikers, dient hierbij te zijn wat de beoogde doelstellingen en eindproduct zijn ter ondersteuning of verbetering van de huidige simulatoropleidingen bij LVNL:

- Formuleren van een visie en doelstellingen
 - Ontwikkelen van een lange termijn visie over het gebruik van learning analytics en het resultaat (bijvoorbeeld een interactief dashboard voor instructeurs).
 - Opstellen van een programma van eisen waaraan learning analytics zou moeten voldoen voor de diverse eindgebruikers.

- Uitvoeren van een pilot met veel data
 - Inventarisatie van mogelijke data die verzameld zouden moeten worden.
 - Dataverzameling: mogelijk maken van data exports bij gelogde data, verzamelen van extra data t.b.v. validatie (bijvoorbeeld competentie-beoordelingen).
 - Data-analyse: exploreren van relaties tussen data (bijvoorbeeld gelogde data en beoordelingen) met nieuwe technieken (bijvoorbeeld statistiek, machine learning).
 - Presentatie en visualisatie van de resultaten op eenvoudige prototypes van interactieve dashboards (bijvoorbeeld in Powerpoint).
- Implementatie
 - Opstellen van specificaties voor een learning analytics applicatie op basis van de gebruikerservaringen met de dashboards.
 - Ontwikkeling en eventueel verbreding naar andere cursussen of simulatoren.

5 Referenties

- Ahlborg, L., Weurlander, M., Hedman, L., Nisell, H., Lindqvist, P. G., Felländer-Tsai, L., & Enochsson, L. (2015). Individualized feedback during simulated laparoscopic training: a mixed methods study. *International Journal of Medical Education*, 6, 93-100. doi:10.5116/ijme.55a2.218b.
- Arnold, K. E., & Pistilli, M. D. (2012, April). Course signals at Purdue: Using learning analytics to increase student success. In *Proceedings of the 2nd international conference on learning analytics and knowledge* (pp. 267-270). ACM.
- Avella, J. T., Kebritchi, M., Nunn, S. G., & Kanai, T. (2016). Learning analytics methods, benefits, and challenges in higher education: A systematic literature review. *Online Learning*, 20(2), 13-29.
- Baker, R. S. (2016). Stupid tutoring systems, intelligent humans. *International Journal of Artificial Intelligence in Education*, 26(2), 600-614.
- Bessiris, Y., Kyriakopoulou, D., Ghajar, F., & Steuckrath, C. (2011). Long distance operator training. *Computer Aided Chemical Engineering*, 29, 1115-1119.
- Billings, D. R. (2012). Efficacy of adaptive feedback strategies in simulation-based training. *Military Psychology*, 24(2), 114-133.
- Bosch, K. van den, Peeters, M.M.M., & Boswinkel, R.A. (2017). *Literature review on individual learning concepts. Part A: Personalized Learning*. TNO report (R11438).
- Brinkhuis, M. J. S., Savi, O. A., Hofman, A. D., Coomans, F., Van der Maas, H. L. J., & Maris, G. K. J. (2018). Learning as it happens: A decade of analyzing and shaping a large-scale online learning system. *Journal of Learning Analytics*, 5(2), 29-46.
- Boven, L., Van de Boer-Visschedijk, G., Rijk, R. van, & Veldhuis, G. (2019). *Literatuurverkenning: Rol van de begeleider bij gebruik van Learning Analytics*. TNO rapport (R11220).
- Charles, R. L., & Nixon, J. (2019). Measuring mental workload using physiological measures: A systematic review. *Applied Ergonomics*, 74 (May 2018), 221-232.
- Clow, D. (2013). An overview of learning analytics. *Teaching in Higher Education*, 18(6), 683-695.
- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User acceptance of computer technology: a comparison of two theoretical models. *Management Science*, 35(8), 982-1003.
- De Bruijn, A. G. M., Blankendaal, R. A. M., Roijendijk, L. M. M., Oprins, E. A. P. B., & Pennings H. J. M. (In progress). The data analytic process behind applying learning analytics in an existing military simulator training.
- Drachsler, H., & Kalz, M. (2016). The MOOC and learning analytics innovation cycle (MOLAC): a reflective summary of ongoing research and its challenges. *Journal of Computer Assisted Learning*, 32(3), 281-290. doi: <https://doi.org/10.1111/jcal.12135>.
- Endsley, M. R. (1995). Measurement of situation awareness in dynamic systems. *Human Factors*, 37(1), 65-84. <https://doi.org/10.1518/001872095779049499>.
- Farmer, E. W., Jorna, P. G. A. M., Riemersma, J. B. J., Rooij, J. C. G. M. van, & Moraal, J. (1999). *Handbook of simulator-based training*. London: Ashgate.

- Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 4(5-6), 304-317.
- Folsom-Kovarik, J. T., & Raybourn, E. M. (2016, November). Total Learning Architecture (TLA) enables next-generation learning via meta-adaptation. In *Proceedings of the IITSEC*.
- Foltz, P. W. & Rosenstein, M. (2017). Data mining large scale formative writing. In G. Siemens and C. Lang (eds.). *Handbook of Learning Analytics and Educational Data Mining*. Beaumont, Alberta: Society for Learning Analytics Research.
- Fowlkes, J., Dwyer, D. J., Oser, R. L., & Salas, E. (1998). Event-based approach to training (EBAT). *The international journal of aviation psychology*, 8(3), 209-221.
- Gašević, D., Dawson, S., Rogers, T., & Gasevic, D. (2017). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68–84.
- Hart, S. G., & Staveland, L. E. (1988). Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. *Advances in psychology*, 52, 139-183.
- Heath, J., & Fulcher, D. (2017). From the trenches: Factors that affected learning analytics success with an institution-wide implementation. Paper presented at the 7th International learning analytics & knowledge conference (LAK17; pp. 29-35). Vancouver, BC: Practitioner Track.
- Jetten, A. M., Peeters, M. M. M., Oprins, E. A. P. B., & Veldhuis, G. J. (2017). *Literature review on individual learning concepts. Part B: Learning Analytics*. Soesterberg: TNO.
- Jivet, I., Scheffel, M., Drachsler, H., & Specht, M. (2017). Awareness is not enough: pitfalls of learning analytics dashboards in the educational practice. In *European Conference on Technology Enhanced Learning* (pp. 82-96). New York City: Springer.
- Kizilcec, R. F., Piech, C., & Schneider, E. (2013). Deconstructing disengagement: analyzing learner subpopulations in massive open online courses. In *Proceedings of the third international conference on learning analytics and knowledge* (pp. 170-179). ACM.
- Kizilcec, R.F. and Brooks, C. (2017) Diverse Big Data and Randomized Field Experiments in Massive Open Online Courses. In: Lang, C., Siemens, G., Wise, A., and Gašević, D. (eds.). *Handbook of Learning Analytics* (pp. 211-222). Beaumont, Alberta: Society for Learning Analytics Research.
- Klerkx, J., Verbert K., & Duval, E. (2017). Learning Analytics Dashboards. In: Lang, C., Siemens, G., Wise, A., and Gašević, D. (eds.), *Handbook of Learning Analytics*, Society for Learning Analytics Research, pp. 143-150.
- Knight, S., Buckingham Shum, S. (2017). Theory and Learning Analytics. In: Lang, C., Siemens, G., Wise, A., and Gašević, D. (eds.), *Handbook of Learning Analytics* (pp. 17-22). Beaumont, Alberta: Society for Learning Analytics Research.
- Koedinger, K. R., Corbett, A. T., & Perfetti, C. (2012). The Knowledge-Learning-Instruction framework: Bridging the science-practice chasm to enhance robust student learning. *Cognitive Science*, 36(5), 757–798.
- Long, P., & Siemens, G. (2011). Penetrating the fog: Analytics in learning and education. *Educause Review*, 46(5), 31–40.

- Marcano, L., Haugen, F. A., Sannerud, R., & Komulainen, T. (2019). Review of simulator training practices for industrial operators: How can individual simulator training be enabled?. *Safety Science*, 115, 414-424. doi: 10.1016/j.ssci.2019.02.019.
- Mishra, P., & Koehler, M. J. (2006). Technological pedagogical content knowledge: A framework for teacher knowledge. *Teachers College Record*, 108(6), 1017-1054.
- Moore, K., & Gugerty, L. (2010). Development of a novel measure of situation awareness: The case for eye movement analysis. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 54(19), 1650–1654.
- Nazir, S., Sorensen, L. J., Øvergård, K. I., & Manca, D. (2015). Impact of training methods on Distributed Situation Awareness of industrial operators. *Safety Science*, 73, 136-145. doi: 10.1016/j.ssci.2014.11.015.
- Papamitsiou, Z., & Economides, A. A. (2016). Learning analytics for smart learning environments: A meta-analysis of empirical research results from 2009 to 2015. In J. M. Spector, B. B. Lockee, & D. M. Childress (Eds.), *Learning, design, and Technology: An international compendium of theory, research, practice, and policy* (pp. 1–23). New York: Springer.
- Pennings, H. J. M., De Bruijn, A. G. M., Blankendaal, R. A. M., & Oprins E. A. P. B. (in progress). The application of learning analytics in a military simulator training.
- Pintrich, R. R., & De Groot, E. V. (1990). Motivational and self-regulated learning components of classroom academic performance, *Journal of Educational Psychology*, 82, 33-40.
- Ramírez-Noriegaa, A., Juárez-Ramírez, R., & Martínez-Ramírez, Y. (2017). Evaluation module based on Bayesian networks to Intelligent Tutoring Systems. *International Journal of Information Management*, 37, 1488-1498. doi:http://dx.doi.org/10.1016/j.ijinfomgt.2016.05.007.
- Rienties, B., Boroowa, A., Cross, S., Kubiak, C., Mayles, K., & Murphy, S. (2016a). Analytics4Action evaluation framework: A review of evidence-based learning analytics interventions at Open University UK. *Journal of Interactive Media in Education*, 1(2), 1-12. doi: 10.5334/jime.394.
- Rienties, B., Cross, S., & Zdrahal, Z. (2016b). Implementing a learning analytics intervention and evaluation framework: what works? In B. Kei Daniel (Ed.), *Big data and learning analytics in Higher Education* (pp. 147–166). Cham: Springer International Publishing. doi:https://doi.org/10.1007/978-3-319-06520-5_10.
- Rienties, B., Giesbers, B., Lygo-Baker, S., Ma, H. W. S., & Rees, R. (2016c). Why some teachers easily learn to use a new virtual learning environment: A technology acceptance perspective. *Interactive Learning Environments*, 24(3), 539-552.
- Rienties, B., & Toetenel, L. (2016). The impact of learning design on student behaviour, satisfaction and performance: a cross-institutional comparison across 151 modules. *Computers in Human Behavior*, 60, 333-341. doi: 10.1016/j.chb.2016.02.074.
- Salas, E., Bowers, C. A., & Rhodenizer, L. (1998). It is not how much you have but how you use it: toward a rational use of simulation to support aviation training. *International Journal of Aviation Psychology*, 8(3), 197–208. doi:10.1207/s15327108ijap0803_2.

- Sedkaoui, S., and M. Khelfaoui. 2019. Understand, Develop and Enhance the Learning Process with Big Data. *Information Discovery and Delivery*, 47(1), 2–16. doi:10.1108/IDD-09-2018-0043.
- Schwendimann, B. A., Rodriguez-Triana, M. J., Vozniuk, A., Prieto, L. P., Boroujeni, M. S., Holzer, A., Gillet, D. & Dillenbourg, P. (2016). Perceiving learning at a glance: A systematic literature review of learning dashboard research. *IEEE Transactions on Learning Technologies*, 10(1), 30-41.
- Sønderlund, A. L., Hughes, E., & Smith, J. (2019). The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology*, 50(5), 2594-2618. doi: <https://doi.org/10.1111/bjet.12720>.
- Sottolare, R. A., Goldberg, B., & Ragusa, C. (2013). Characterizing an Adaptive Tutoring Learning Effect Chain for Individual and Team Tutoring. In *Interservice/Industry Training, Simulation, and Education Conference* (pp. 1–13). San Francisco: Jossey-Bass.
- Tempelaar, D. T., Rienties, B., & Giesbers, B. (2015). In search for the most informative data for feedback generation: Learning analytics in a data-rich context. *Computers in Human Behavior*, 47, 157-167. doi: 10.1016/j.chb.2014.05.038.
- Teo, T., & Zhou, M. (2016). The influence of teachers' conceptions of teaching and learning on their technology acceptance. *Interactive Learning Environments*, 25(4), 1-15. doi: 10.1080/10494820.2016.1143844.
- Van den Bosch, K., Peeters, M. M. M., & Boswinkel, R. A. (2017). *Literature review on individual learning concepts. Part A: Personalized learning*. Soesterberg: TNO.
- Van den Bogaard, M., Drachsler, H., Duisterwinkel, H., Knobbout, J., Manderveld, J., & de Wit, M. (2016). *Report learning analytics in education design: a guide*. Enschede: Surfned.
- Verbert, K., Duval, E., Klerkx, J., Govaerts, S., & Santos, J. L. (2013). Learning analytics dashboard applications. *American Behavioral Scientist*, 57(10), 1500-1509.
- Verbert, K., Govaerts, S., Duval, E., Santos, J. L., Van Assche, F., Parra, G., & Klerkx, J. (2014). Learning dashboards: an overview and future research opportunities. *Personal and Ubiquitous Computing*, 18(6), 1499-1514.
- Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2018). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 89, 98-110.
- Wise, A., Zhao, Y., & Hausknecht, S. (2014). Learning analytics for online discussions: Embedded and extracted approaches. *Journal of Learning Analytics*, 1(2), pp. 48-71.

Distributielijst rapport TNO 2020 R11746

Opdrachtgever Luchtverkeersleiding Nederland (LVNL) Stationsplein Zuid-West 1001 1117 CV SCHIPHOL	pdf
Geadresseerde Referent, Roadmap Directeur R. Le Fèvre	Soort email-alert
Projectleider E.A.P.B. Oprins	email-alert
Research manager projectleider E.W. Boot	email-alert
Auteurs L.M.M. Roijendijk A. de Bruijn	email-alert
TNO Archief locatie TNO Archief locatie	hardcopy cd