


Inventarisatie open tekstboeken

Projectverslag werkgroep

Hergebruik open leermaterialen



Versnellingsplan
Onderwijsinnovatie
met ICT

 digitale leermaterialen



Inventarisatie open tekstboeken

Proejectverslag werkgroep
Hergebruik open leermaterialen

Versnellingsplan Onderwijsinnovatie met ICT -
Zone Digitale leermaterialen



**Versnellingsplan
Onderwijsinnovatie
met ICT**

Ruben Jacobse
Michiel de Jong
Sylvia Moes

Eindredactie
Nicole Bakker



Op deze uitgave is een Creative Commons Naamsvermelding 4.0-licentie van toepassing. Maak bij gebruik van dit werk vermelding van de volgende referentie: Jacobse, R., De Jong, M., Moes, S. (2021). Inventarisatie open tekstboeken. Projectverslag werkgroep Hergebruik open leermaterialen. Utrecht: Versnellingsplan Onderwijsinnovatie met ICT.

Inhoudsopgave

Inleiding	5
1. Fase I: Inventarisatie van open tekstboeken	7
1.1. Inleiding	7
1.2. Online bronnen van open tekstboeken en metadata	7
Directory of Open Access Books (DOAB)	8
British Columbia Open Textbooks (BCOpen)	8
Open Textbook Library (OTL)	8
Unglue.it	9
Overige (ongebruikte) bronnen	9
1.3. Stappenplan verwerking metadata	10
1.4. Conversie van MARCXML naar .csv-formaat	11
1.5. Dataverrijking	13
1.6. Samenvatting van relevante gegevens in metadata	14
Globaal overzicht alle titels	14
Overzicht per vakgebied	19
1.7. Opmerkingen en aanbevelingen	19
2. Fase II: Bewerkbaarheid van open tekstboeken	21
2.1. Inleiding	21
2.2. Overzicht van bestandsformaten	21
2.3. Documenten in pdf-formaat	23
2.4. Documenten in ePub-formaat	24
2.5. Documenten in MOBI-formaat	24
2.6. Documenten in HTML-formaat	25
2.7. Documenten in XML-formaat	25
2.8. Aanbevelingen	25
3. Conclusies en vervolgstappen	27
Bijlage A – Resultaten inventarisatie open tekstboeken per vakgebied	29

Inleiding

De transitie van commercieel naar digitaal open leermateriaal biedt grote kansen voor de professionalisering van docenten. Ook zorgt de overgang naar digitaal open leermateriaal voor een vermindering van de afhankelijkheid van commerciële uitgevers voor het aanbieden van onderwijsliteratuur. Maar deze transitie vindt in het hoger onderwijs nog zeer beperkt plaats.

De werkgroep Hergebruik open leermaterialen van de zone Naar digitale (open) leermaterialen van het Versnellingsplan Onderwijsinnovatie met ICT, ziet mogelijkheden om deze transitie te stimuleren. Door het hergebruik van open tekstboeken veel makkelijker te maken, verwacht de werkgroep een toename van het (her)gebruik ervan.

Docenten zullen gebruik maken van onderwijsliteratuur waar zij controle over hebben. Open tekstboeken bieden flexibiliteit bij het gebruik in lessen en vakken. En de toegankelijkheid van onderwijsliteratuur wordt voor studenten aanzienlijk vergroot, aangezien zij niet langer afhankelijk zijn van relatief gezien dure tekstboeken met een beperkte beschikbaarheid.

De werkgroep is onderdeel van de versnellingszone Naar digitale (open) leermaterialen. Binnen deze zone zetten vertegenwoordigers van zes universiteiten en twee hogescholen zich in voor het optimaal benutten van digitale (open) leermaterialen in het hoger onderwijs. De zone wil eraan bijdragen dat docenten en studenten uit een steeds rijker aanbod een optimale mix van digitale leermaterialen kunnen samenstellen en gebruiken, die aansluit bij de onderwijsvisie van docent en instelling én bij de behoeften van studenten.

Om het gebruik van open tekstboeken gemakkelijker te maken, is een goed overzicht nodig van het beschikbare materiaal. Aangezien dit overzicht in Nederland nog niet bestaat, is de werkgroep hiermee van start gegaan. De inventarisatie richt zich op publiek beschikbare open tekstboeken, met als selectiecriteria 'geschiktheid voor het campus onderwijs'. De inventarisatie besloeg het eerste deel van het project, fase I.

In fase I van het project zijn de volgende stappen gezet:

1. De reeds uitgevoerde inventarisaties van open tekstboek repositories door TU Delft en de Vrije Universiteit zijn samengebracht en uitgebreid om een nagenoeg compleet overzicht van bronnen voor open tekstboeken samen te stellen.
2. De open tekstboeken in deze repositories zijn in één overzicht samengevoegd en gecategoriseerd op kennisdomein en andere metadata.

Vervolgens is op basis van de inventarisatie van open tekstboeken, een verkenning gedaan naar de bewerkingsmogelijkheden hiervan. Want een belangrijk beoogd aspect van open tekstboeken, is de mogelijkheid voor docenten om de materialen te bewerken voor toepassing in hun eigen onderwijs. Veel open tekstboeken blijken te zijn gepubliceerd in een digitaal formaat dat niet of nauwelijks bewerkbaar is. Aansluitend heeft de werkgroep daarom een technische verkenning gedaan naar software, voor de conversie van slecht bewerkbare bestanden tot makkelijk bewerkbare bestandsformaten.

De activiteiten van fase II van het project:

1. Er is een inventarisatie gedaan van de meest voorkomende bestandsformaten van open tekstboeken uit de repositories.
2. Er is een technische verkenning gedaan naar manieren om verschillende open tekstboeken makkelijk in een bewerkomgeving op te nemen. Ook is onderzocht hoe je een open tekstboek kan terugbrengen tot een reeks formatvrije elementen, zodat docenten de content makkelijk naar behoefte kunnen bewerken.

Dit verslag beschrijft de uitvoering van beide fasen van het project, met resultaten, kanttekeningen en aanbevelingen voor vervolgstappen. Het is een verkorte versie. Voor het volledige verslag met technische details, kan je contact opnemen via e-mailadres leermaterialen@versnellingsplan.nl.

1 Fase I: Inventarisatie van open tekstboeken

1.1 Inleiding

Open tekstboeken worden door allerlei repositories en uitgevers aangeboden. Daarnaast bestaan er platforms die de tekstboeken van al deze repositories en uitgevers verzamelen. Dat proces staat ook wel bekend als harvesten. Een aantal van deze platforms biedt gebruikers de mogelijkheid om de metadata van hun collectie te exporteren. Er zijn vier grote platforms die hun metadata open beschikbaar stellen namelijk: Directory of Open Access Books (DOAB), British Columbia Open Textbooks, Open Textbook Library en Unglue.it.

De inhoud van de collecties die deze vier platforms aanbieden, wordt geanalyseerd door metadata. De metadata zijn gecodeerd in de Machine-Readable Cataloging (MARC) standaard voor bibliografische informatie. Deze wordt aangeboden in binaire MARC21 vorm met extensie .mrc óf in MARCXML-vorm met extensie .xml. De bibliografische informatie is lang niet voor elk tekstboek naar volledigheid ingevuld. Daarom ontbreken de metadata die het vakgebied van het tekstboek beschrijven dikwijls.

Door aanvullend gebruik te maken van het Library of Congress Classification (LCC) classificatiesysteem wordt het ontbreken van deze beschrijvende metadata, opgelost. Voor alle boeken met een zogeheten LCC-classificatie kan via een mapping worden bepaald onder welk(e) Edustandaard vakgebied(en) het tekstboek valt. De resulterende data worden samengevat en geanalyseerd in zowel een complete collectie als een collectie per vakgebied. Dit is zeer beknopt samengevat, de werkwijze die we als werkgroep hebben gehanteerd.

In dit hoofdstuk gaan we meer uitvoerig in op dit proces. Paragraaf 1.2 start met een beschrijving van de bronnen die voor de inventarisatie van open tekstboeken zijn gebruikt. Vervolgens wordt van paragraaf 1.3 tot 1.5 meer in detail ingegaan op het stappen voor de verwerking van de metadata die afkomstig zijn uit eerdergenoemde platforms en op de verrijking van deze metadata met LCC-classificaties. Paragraaf 1.6 presenteert de resultaten van de dataverwerkingsstappen via verschillende analyses. In paragraaf 1.7 worden tenslotte kanttekeningen en aanbevelingen geplaatst.

1.2 Online bronnen van open tekstboeken en metadata

De analyse in dit document beperkt zich tot een aantal publiek toegankelijke platforms die hun metadata vrij ter beschikking stellen. Platforms die geen metadata aanbieden of niet vrij-toegankelijke platforms, zoals platforms die registratie of een abonnement

vereisen, worden kort besproken maar zijn verder in dit onderzoek buiten beschouwing gelaten. Ook zijn Metafinders zoals Merlot, OER Metafinder of OASIS die andere platforms doorzoeken maar zelf geen boeken aanbieden, niet in deze inventarisatie opgenomen. Want zij stellen hun metadata niet open ter beschikking.

In totaal is 95% van de metadata van alle geïnventariseerde boeken in de dataset afkomstig van DOAB. De overige 5% is afkomstig van British Columbia Open Textbooks, Open Textbook Library en Unglue.it.

Directory of Open Access Books (DOAB)

De Directory of Open Access Books¹ (DOAB) is met ~31,400 unieke titels verreweg de grootste verzameling van open access boeken op het internet. DOAB bevat voornamelijk titels van academische uitgeverijen en open access titels van commerciële partijen (Springer Nature ~2400 titels, DeGruyter ~1700 titels, Brill ~640 titels, Taylor & Francis ~880 titels). Verder bevat DOAB ook titels aangeboden door andere platforms, zoals IntechOpen² (~7000 titels) en OpenEdition³ (~15800 titels).

British Columbia Open Textbooks (BCOpen)

Het British Columbia Electronic Library Network is aanbieder van de British Columbia Open Textbooks Collection (BCOpen)⁴ met ongeveer 320 titels. BCOpen bevat ongeveer 70 titels uit eigen collectie en bestaat verder uit titels van enkele Canadese overheidsinstanties, van kleinere platforms zoals OpenStax⁵ (Rice University, 41 titels), een beperkt aantal titels van Milne Open Textbooks⁶ (SUNY Geneseo, zeven titels van totaal ~100), enkele titels van Saylor Academy⁷ (negen van ~100 titels) en titels uitgegeven door andere universiteiten.

Open Textbook Library (OTL)

De Open Textbook Library⁸ wordt aangeboden door het Open Education Network van de University of Minnesota en bevat ongeveer 800 titels. Ook dit platform bevat titels uit de collecties van BCOpen (~37 titels), OpenStax (~58 titels), Milne Open Textbooks (~25 titels), en Saylor Academy (~54 titels). Verder bevat dit platform vooral titels die afkomstig zijn van verschillende universiteiten.

¹ www.doabooks.org

² www.intechopen.com

³ books.openedition.org/

⁴ open.bccampus.ca

⁵ openstax.org

⁶ milneopentextbooks.org

⁷ www.saylor.org/books/

⁸ open.umn.edu/opentextbooks/

Unglue.it

Unglue.it⁹ is een platform voor rechthebbenden voor verspreiding van hun boeken onder vrije licenties. Het platform bevat ongeveer 800 titels, waarvan het grootste deel afkomstig is van academische uitgeverijen. Een klein aantal werken in deze collectie behoort tot het genre fictie.

Overige (ongebruikte) bronnen

De vier hierboven genoemde platforms stellen allen van hun collecties een of meerdere vormen van metadata vrij beschikbaar. Daarnaast zijn er andere platforms die ofwel helemaal geen metadata bieden, of deze enkel na het sluiten van overeenkomsten aanbieden. Aangezien de metadata van deze collecties niet beschikbaar zijn binnen de looptijd van dit project of omdat deze platforms enkel (semi-)handmatig kunnen worden geïnventariseerd zijn deze niet meegenomen in de analyse. Voor de volledigheid van de inventarisatie noemen we deze collecties in het kort.

JSTOR¹⁰ biedt voor hun collectie (~6500 titels) een metadatabestand aan voor bibliotheken via OCLC Worldshare Collection Manager. Ook wordt een Excelbestand met beperkte metadata zoals titels, auteurs en ISBN gepubliceerd. Uit een steekproef van deze titels blijkt dat de meeste ook lijken te zijn opgenomen in DOAB. Het JSTOR-metadatabestand is voor dit project niet via OCLC aangevraagd.

LibreTexts¹¹ is een platform met ~400 titels in dertien verschillende categorieën. Het platform bevat ook titels van OpenStax. LibreTexts biedt downloads aan in verschillende bestandsformaten, zoals pdf, imsc (Canvas/Brightspace) en als webpagina's. LibreTexts biedt ook een 'remixer' aan, een tool waarmee docenten delen van boeken kunnen mixen en samenvoegen.

BookBoon¹² is een platform dat tegen betaling meer dan 1000 open tekstboeken beschikbaar stelt. Voor studenten zijn de meeste boeken gratis, mits ze een account aanmaken.

Open Culture¹³ biedt een pagina met 200 links naar oorspronkelijke bronnen van open tekstboeken. Deze lijst bevat onder andere een aantal OpenStax boeken.

⁹ unglue.it/

¹⁰ guides.jstor.org/oabooks

¹¹ libretexts.org/

¹² bookboon.com


¹³ www.openculture.com/free_textbooks

Het **American Institute of Mathematics**¹⁴ heeft een lijst met links naar oorspronkelijke bronnen van ongeveer 60 open tekstboeken op het gebied van wiskunde, die zijn geëvalueerd door de organisatie. Zowel pdf als een HTML, XML, of LaTeX bronformaat is beschikbaar voor de meeste titels. Via andere open access platforms lijken de meeste van deze boeken niet vindbaar.

1.3. Stappenplan verwerking metadata

De platforms die metadata van hun collecties aanbieden hanteren verschillende bestandsformaten. BCOpen en OTL gebruiken MARC21 (.mrc) terwijl DOAB en Unglue.it MARCXML gebruiken (zie paragraaf 1.4 voor meer details). DOAB biedt daarnaast een .csv-bestand aan met metadata. Dit bestand is inhoudelijk bijna hetzelfde als het MARCXML-bestand, er zijn enkele verschillen in de aanwezige datavelden.

Figuur 1 toont de verwerking van metadata in een schematisch overzicht.



Figuur 1 Schematisch overzicht van stappen in de verwerking van metadata.

De stappen in de verwerking van metadata toegelicht:

- De vier bronbestanden worden gedownload van internet in MARC21 (.mrc) en MARCXML (.xml) bestandsformaat. Het bronbestand van BCOpen wordt eens per kwartaal genereerd, de bronbestanden van de andere drie platforms worden bij het downloaden automatisch aangemaakt. Je vindt de URL's van deze bestanden in tabel 1.

¹⁴ aimath.org/textbooks/approved-textbooks/

- De MARC21 bestanden worden vervolgens omgezet naar MARCXML. Dit is een bestandsformaat dat leesbaar is voor zowel mens als machine.
- Vanuit de bestanden in het hiërarchische MARCXML-formaat worden de data, uit de voor dit project relevante velden, verwerkt tot data in tabelvorm in .csv-formaat, met één rij per record. De metadata is gereed voor verdere verrijking.
- Want bij sommige boeken ontbreken relevante velden. De .csv-bestanden worden daarom aangevuld met extra data uit andere bronnen.
- Voor open tekstboeken afkomstig uit DOAB worden de Library of Congress Classificaties (LCC) vanuit het online aangeboden .csv-bestand toegevoegd aan het uit MARCXML verkregen .csv-bestand.
- Voor metadata afkomstig uit andere platforms zonder LCC, is een application programming interface (API) gebruikt, namelijk de OCLC Classify API. Met behulp van deze API wordt de informatie verkregen die op basis van het ISBN de LCC-code bepaalt.
- Het is nu mogelijk om volgens de LCC-velden te bepalen tot welk vakgebied(en) het boek behoort volgens de Edustandaard indeling. Het kan voorkomen dat een boek onder meer dan één Edustandaard vakgebied wordt ingedeeld, omdat een boek meerdere LCC-waarden kan hebben. Daarnaast zijn er ook enkele LCC-categorieën die onder meerdere Edustandaard vakgebieden vallen.

Tabel 1 URL's van online metadatabronnen

Bestand	URL
DOAB (.csv)	www.doabooks.org/doab?func=csv
BCOpen (.mrc)	bceln.ca/sites/default/files/marc_records
OTL (.mrc)	open.umn.edu/opentextbooks/download.mrc
DOAB (.xml)	www.doabooks.org/oai
UnglueIT (.xml)	unglue.it/marc/all

1.4. Conversie van MARCXML naar .csv-formaat

De bestanden die van internet zijn gedownload in de MARC-formaten, bevatten ook velden die geen relevante informatie voor dit project bevatten. Daarom is bij de conversie naar een.csv-bestand in tabelvorm, een beperkt aantal velden meegenomen. Andere MARC-velden blijven dus ongebruikt. Aangezien in de MARC-formaten soms data op verschillende manieren worden weergegeven en over meerdere velden zijn verspreid,

is bij de conversie naar een .csv-bestand een extra stap toegepast. De MARCXML-data worden uitgelezen en (indien nodig) samengevoegd. Tabel 2 toont de relevante .csv kolommen en de corresponderende MARC-velden.

Tabel 2 .csv kolommen en MARC21 velden waaruit deze zijn opgebouwd

.csv kolommen	MARC21 veld(en)
ID	001
Titel	245a (titel) + 245b (subtitel)
Editie	250a 250b
Auteur(s)	100a of 700a (anders 245c)
Taal	546a of 041a
ISBN	020a (meerdere keren mogelijk)
LCC	050a + 050b
DOI	024a (enkel als 024_2 == "doi")
Onderwerp	650a (meerdere keren mogelijk)
Steekwoorden	653a (meerdere keren mogelijk)
Vorm	650v (meerdere keren mogelijk)
Samenvatting	520a
Inhoudsopgave	505a
Serie titel	490a
Serie ISSN	490x
Uitgever	260b
Jaar van uitgave	260c of 542g
Auteursrecht licentie	540a of 540f of 542f
Bestandsformaat	347b
URL van bronbestand of webpagina	856u

Voor de conversie van MARCXML naar .csv is het noodzakelijk om een aantal handelingen uit te voeren die zorgen voor een meer uniforme weergave van de data in een aantal velden. MARC heeft geen dwingende regels voor de inhoudelijke vorm van datavelden. Beheerders van de verschillende bronnen zijn vrij om net iets andere manieren te gebruiken om dezelfde soort informatie vast te leggen. In dit project zijn voor een meer uniforme weergave van de data daarom de volgende handelingen uitgevoerd:

- Herstellen van omgewisselde velden in aangeboden bestanden.
- Uniforme weergave van titels, auteursnamen, steekwoorden etc.
- Creative Commons licentie formaten herkennen en in hetzelfde formaat opslaan.
- Talen in taalveld herkennen en indien nodig vertalen.

1.5. Dataverrijking

In paragraaf 1.3 schreven we dat in de MARC/MARCXML-bestanden niet alle velden zijn ingevuld. In deze paragraaf lichten we verder toe hoe we de data met extra informatie hebben verrijkt. Om de informatie van deze ontbrekende velden te verkrijgen, is de Library of Congress Classification gebruikt. Deze classificatie methode zet extra stappen om open tekstboeken in te delen op vakgebied.

DOAB biedt de mogelijkheid om een .csv-formaat export te maken van de LCC-classificaties van de meeste records. Deze informatie ontbreekt in de XML-versie van de DOAB-data. Door gebruik te maken van deze LCC-data, kan de missende data in het .xml bestand worden aangevuld met missende waarden, nadat het .xml-bestand is geconverteerd naar een .csv-bestand.

De OCLC Classify v2 API kan worden gebruikt om via een identificerend kenmerk (zoals bijvoorbeeld ISBN, titel, of OCLC-nummer) de classificatie van een werk op te vragen. Via de LCC-code, die al in de metadata van open tekstboeken aanwezig was of die later is toegevoegd via de hiervoor beschreven stappen, zijn de open tekstboeken globaal op kennisdomein ingedeeld. De LCC-code van een tekstboek bevat een prefix, deze omschrijft het kennisdomein van het tekstboek.

Hier is vervolgens een mapping van gemaakt. De LCC-prefixen (de eerste letter, of eerste twee letters van de code) zijn gekoppeld aan de vakgebieden volgens de Edustandaard taxonomie. Tabel 3 toont de gehanteerde mapping. Deze mapping is binnen de context van dit onderzoek ontwikkeld. Het ontbreekt aan input van experts en daarom kan deze mapping niet als een definitieve of correcte koppeling worden beschouwd.

Tabel 3 Voorbeeld van mogelijke mapping van LCC-prefix naar Edustandaard vakgebied

Edustandaard vakgebied	LCC-prefixen
Aarde en Milieu	G, GA, GB, GC, GE, GF, QE, QH, QK, QR, S, SB, SD, SF, SK
Economie en Bedrijf	GV, HB, HC, HD, HE, HF, HG, HJ, TX
Exact en Informatica	BC, QA, QB, QC, QD, QE
Gedrag en Maatschappij	BF, GN, GR, GT, GV, H, HA, HM, HN, HQ, HS, HT, HV, HX,
Gezondheid	QL, QM, QP, R, RA, RB, RC, RD, RE, RF, RG, RJ, RK, RL, RM, RS, RT, RV, RX, RZ, SH,
Interdisciplinair	U, UA, UB, UC, UD, UE, UF, UG, UH, V, VA, VB, VC, VD, VE, VF, VG, VK, VM
Kunst en Cultuur	AZ, B, BC, BD, BH, BJ, BL, BM, BP, BQ, BR, BS, BT, BV, BX, C, CB, CC, CD, CE, CJ, CN, CR, CS, CT, D, DA, DB, DC, DD, DE, DF, DG, DH, DJ, DK, DL, DP, DQ, DR, DS, DT, DU, DX, E, F, M, ML, MT, N, NA, NB, NC, ND, NE, NK, NX
Onderwijs en Opvoeding	L, LA, LB, LC, LD, LE, LF, LG, LH, LJ, LT
Recht en Bestuur	J, JA, JC, JF, JJ, JK, JL, JN, JQ, JS, JV, JZ, K, KB, D, KE, KF, KG, KH, KJ, KK, KL, KZ
Taal en Communicatie	P, PA, PB, PC, PD, PE, PF, PG, PH, PJ, PK, PL, PM, PN, PQ, PR, PS, PT, PZ
Techniek	NA, T, TA, TC, TD, TE, TF, TG, TH, TJ, TK, TL, TN, TP, TR, TS, TT, VM

1.6. Samenvatting van relevante gegevens in metadata

In deze paragraaf presenteren en bespreken we de resultaten van de dataverwerkingsstappen die in de voorgaande paragrafen zijn gezet. De analyse is opgesplitst in twee delen: de gehele set aan metadata van alle boeken wordt beschouwd in deze paragraaf. Er zijn ook overzichten gemaakt per Edustandaard vakgebied. Die vind je terug in Bijlage A.


Globaal overzicht alle titels

Op de volgende pagina's staan visuele weergaven met analyses van de gehele set aan metadata van alle boeken. De open tekstboeken zijn geanalyseerd op deze categorieën:

- Vakgebieden
- Bronportalen
- Uitgeverijen
- Talen
- Licentietypen
- Bestandsformaten

Vakgebieden


Onderstaande figuur toont de verdeling van de open tekstboeken over de 11 Edustandaard vakgebieden. Na de verrijking van de metadata is er uiteindelijk voor ongeveer 27500 boeken een LCC-classificatie bepaald. Bijna 6000 boeken kunnen niet worden ingedeeld op vakgebied en zijn daarom gelabeld als vakgebied 'onbekend'. Een boek kan meerdere LCC-classificaties hebben en kan dus onder meerdere vakgebieden vallen. Omdat de onderstaande figuur het aantal boeken per vakgebied weergeeft, is de som van de boeken per vakgebied groter dan het totaal aantal boeken.



Bronportalen


De bronportalen zijn de platforms waaruit de metadata in dit onderzoek afkomstig is. Verreweg de meeste titels (~32,000 of 95%) komen uit DOAB. Dit was te verwachten, omdat DOAB een repository is die academische open access literatuur aanbiedt in verschillende vormen. DOAB is niet beperkt tot open tekstboeken voor hoger onderwijs,

maar bevat ook onder andere samengestelde werken. De andere platforms zijn veel nadrukkelijker dan DOAB wel gericht op het aanbod van educatieve tekstboeken. Hoewel de absolute aantallen van deze repositories dus veel lager zijn, zijn de tekstboeken die ze bevatten veel nadrukkelijker gericht op toepassing in het onderwijs.




Talen

Onderstaande figuur laat zien in welke talen de open tekstboeken zijn geschreven. Boeken waarvan geen taal in de metadata is ingevuld zijn gelabeld als 'onbekend'. Talen met kleine aantallen boeken zijn samengevat onder de noemer 'anders'. Van sommige boeken bevat het taalveld in de metadata meerdere talen, waardoor hieruit niet direct te herleiden is welk van de genoemde talen correct is. Deze boeken zijn ook in de categorie 'anders' ingedeeld.




Uitgeverijen

Onderstaande figuur geeft een overzicht van de uitgeverijen waardoor de boeken zijn gepubliceerd. Veel boeken zijn afkomstig van verschillende universiteitsuitgeverijen, voornamelijk uit Europa en Noord-Amerika. Omdat er tientallen 'university presses' zijn met elk tientallen tot honderden titels, zijn deze samengevat als 'universiteitsuitgeverijen'. Alle andere typen uitgeverijen, waarvan per uitgever minder dan 500 boeken beschikbaar zijn, vallen onder 'anders'. De open tekstboeken van deze uitgeverijen worden geharvest en weergegeven in DOAB.



Licentietypen

Onderstaande figuur toont het type licentie waaronder boeken beschikbaar zijn gesteld. Verreweg het grootste deel van de boeken (66 %) heeft een Creative Commons licentie (in de figuur weergegeven als CC-...). Boeken die volgens de metadata beschikbaar zijn onder een verscheidenheid aan uitgeverij-specifieke licenties zijn samengevat in 'anders'.



Bestandsformaten

Onderstaande tabel geeft een overzicht van de bestandsformaten waarin de titels volgens de metadata beschikbaar zijn. Bij bijna driekwart van de titels is deze informatie niet aanwezig in de metadatabestanden en is het bestandsformaat dus onbekend. Vaak bevat de metadata voor deze boeken enkel een URL van een webpagina, waar het daadwerkelijke bestand kan worden gedownload. In sommige gevallen geeft de metadata een bestandsformaat maar blijkt bij inspectie van de webpagina dat het boek in verschillend formaten verkrijgbaar is. Dit geldt bijvoorbeeld voor veel titels in de BC Open dataset.

Tabel 4 Overzicht van bestandsvormen en aantallen waarin deze voorkomen in de metadata

Bestandsformaat	Aantal
pdf	9774
xml	39
ePub	33
onbekend	23442

Overzicht per vakgebied

Voor 10 van de 11 Edustandaard vakgebieden is een beknopter overzicht van de data gemaakt. Geen van de boeken in de dataset is ingedeeld in het vakgebied 'Interdisciplinair', dus van dat vakgebied is geen overzicht gemaakt.

De volgende categorieën worden per Edustandaard vakgebied weergegeven:

- Talen
- Publicatiejaar
- Licentietypen
- Steekwoorden

Op basis van de steekwoorden in het 'keywords' veld van het .csv-metadatabestand in tabelvorm, zijn woordenwolken gemaakt. Deze wolken geven een globaal overzicht van de meest voorkomende steekwoorden per vakgebied. In totaal zijn de 200 meest voorkomende steekwoorden weergegeven waarbij geldt dat groter afgebeelde steekwoorden vaker voorkomen dan de kleinere. Hiervoor zijn enkel de steekwoorden van Engelstalige boeken gebruikt. De figuren zijn gemaakt met behulp van het Python softwarepakket Word Cloud¹⁵. Van de overige categorieën zijn de verschillen tussen de vakgebieden relatief gering, hiervan zijn geen visualisaties gemaakt. Je vindt de resultaten in Bijlage A.

1.7. Opmerkingen en aanbevelingen

Voor de inventarisatie van open tekstboeken hebben we diverse stappen doorlopen. Gebaseerd op de observaties tijdens dit proces, plaatsen we de volgende opmerkingen en aanbevelingen.

- Van veel boeken ontbreken de LCC-codes in de metadata, terwijl deze vaak wel op het voorschutblad in het boek zelf staan. Door de LCC-codes uit de volledige tekst te extraheren, kan dit worden opgelost.
- Het is gewenst dat de mapping van LCC-prefixen naar Edustandaard vakgebieden in dit onderzoek, door inhoudelijke experts wordt gevalideerd. Een mapping naar bijvoorbeeld Edustandaard studierichting of opleiding kan dan ook worden gemaakt, door gebruik te maken van meer informatie dan alleen de beginletter(s) van de LCC-classificatie.
- De bestandsformaten zijn in de metadata meestal afwezig of incompleet (veel titels in BC Open worden op de website bijvoorbeeld in meerdere formaten aangeboden). Een mogelijke oplossing hiervoor is het aanvullen van deze informatie met behulp van webcrawlers die de URL van de bron doorzoeken.

¹⁵ pypi.org/project/wordcloud/

- Er is onduidelijkheid over de juistheid van de licentietypes die in de metadata staan. DOAB geeft bijvoorbeeld vaak de licentie zoals deze in het boek staat, terwijl die mogelijk verschilt met de licentie waaronder het boek via een website wordt verstrekt.
- In de metadata is de taal van een boek soms onduidelijk of multi-interpretabel. Daarom kan het beter zijn om de taal uit de geëxtraheerde tekst van het document zelf af te leiden.
- Het door DOAB aangeboden .csv-bestand met o.a. de LCC-codes bevat fouten. Die moeten handmatig worden hersteld door de gebruiker, voordat het bestand geschikt is om de metadata te verrijken. Dit probleem heeft de werkgroep aangekaart bij de organisatie achter het DOAB-platform, in de hoop dat zij deze fouten zelf zullen oplossen.
- Met de oplevering van deze inventarisatie, is het belangrijk om methodes te ontwikkelen die deze lijsten van tekstboeken makkelijk doorzoekbaar maken. De vindbaarheid van tekstboeken met behulp van deze inventarisatie is nu nog beperkt tot de onderwerpen en kennisgebieden van de tekstboeken zoals die beschreven staan in de metadata. Handmatig doorzoeken van de platforms is geen optie omdat het voor docenten en studenten een (te) tijdsintensieve activiteit is.
- Vanuit de werkgroep hebben we gezocht naar mogelijkheden om een geautomatiseerde analyse van de inhoud van open tekstboeken te maken, met als doel veel meer beschrijvende informatie voor deze open tekstboeken te genereren. Deze informatie kan worden gebruikt om open tekstboeken effectief te koppelen aan vakken die worden gegeven bij diverse opleidingen in het hoger onderwijs. Hiervoor is een proof-of-concept uitgevoerd met de software Elasticsearch.

ElasticSearch¹⁶ is een zoekmachine backend ontwikkeld door Elastic B.V. en is grotendeels als open-source beschikbaar onder de Apache softwarelicentie¹⁷. ElasticSearch is geschikt om van grote aantallen documenten de volledige tekst doorzoekbaar te maken. Dit maakt deze software zeer geschikt om een collectie van tekstboeken volledig te indexeren en te doorzoeken. Binnen SURF is er al kennis van het gebruik van ElasticSearch. We verwachten daarom dat het doorzoekbaar maken van open tekstboeken, relatief makkelijk kan worden geïntegreerd in bestaande platforms zoals het Edusources. Dit proof-of-concept is mede mogelijk gemaakt door de expertise en het technische advies van Jelmer de Ronde van SURF. Stuur een e-mail naar leermaterialen@versnellingsplan.nl voor een uitgebreide beschrijving van de technische uitvoering van dit proof-of-concept.

¹⁶ www.elastic.co/elasticsearch/

¹⁷ www.apache.org/licenses/

2. Fase II: Bewerkbaarheid van open tekstboeken

2.1. Inleiding

Een belangrijke motivatie voor het gebruik van open tekstboeken, is de mogelijkheid om het materiaal te hergebruiken. De bewerkbaarheid van open tekstboeken is daarom een wezenlijk kenmerk. Veel open tekstboeken zijn echter gepubliceerd in een bestandsformat dat niet of nauwelijks bewerkbaar is. Bijvoorbeeld als pdf of ePub.

In het tweede deel van dit project, heeft de werkgroep aansluitend op de inventarisatie ook een technische verkenning uitgevoerd. Er is onderzoek gedaan naar software die het mogelijk maakt om snel en gemakkelijk dit soort slecht bewerkbare bestanden te converteren tot makkelijk bewerkbare bestandsformaten, met inachtneming van de Creative Commons licentievoorwaarden van deze materialen.

Voor de verkenning zijn de volgende activiteiten uitgevoerd:

1. Er is een overzicht gemaakt van de bestandsformaten waar het grootste deel van de open tekstboeken uit de repositories van de in de eerste fase van het project gemaakte lijst onder vallen. De open tekstboeken die interessant zijn voor hbo- en wo-opleidingen in Nederland, zijn van verschillende internationale aanbieders en platforms afkomstig.
2. Er is een technische verkenning gedaan naar software die in staat stelt om slecht bewerkbare open tekstboeken om te zetten naar bestanden met bewerkbare bestandsformaten, zodat docenten deze tekstboeken makkelijk kunnen aanpassen. Deze bestandsformaten zijn onder meer pdf en ePub.
3. Er is een overzicht opgesteld van oplossingsrichtingen, voor de bewerking van open tekstboeken die gepubliceerd zijn in moeilijk bewerkbare formats. Dit is opgeleverd als een overzicht van scenario's voor boeken die verschillende soorten content bevatten. Denk hierbij aan tekst, plaatjes, tabellen, vectorfiguren e.d.

2.2. Overzicht van bestandsformaten

Uit de resultaten van het eerste deel van dit project (zie paragraaf 1.6 Bestandsformaten) blijkt het lastig om te achterhalen in welk bestandsformaat open tekstboeken worden aangeboden. Om een beter overzicht te krijgen is daarom steekproefsgewijs bij de 17 grootste uitgeverijen, die samen ongeveer de helft van alle titels in de dataset uitgeven, bekeken in welke formaten zij hun boeken op hun eigen website aanbieden. Ook het kleinere BCCampus is toegevoegd omdat de meeste titels op dit platform in meerdere formaten worden aangeboden.

Tabel 5 Overzicht van bestandsformaten per uitgever op basis van steekproef

Uitgeverij	Aantal titels	Bestandsformaten
IntechOpen	2026	Alleen pdf én HTML-webpagina
MDPI - Multidisciplinary Publishing institute	1680	Alleen pdf
KIT Scientific Publishing	1674	Alleen pdf
De Gruyter	1636	Altijd pdf, soms ook ePub
Frontiers Media SA	1370	Altijd pdf én ePub
Peter Lang International Academic Publishing Group	1311	Altijd pdf, soms ook ePub
Springer Nature	1173	Altijd pdf, vaak ook ePub
Taylor & Francis	859	Alleen pdf
Transcript Verlag	783	Altijd pdf, soms ook ePub
Amsterdam University Press	638	Alleen pdf
Australian National University Press	584	Altijd pdf, soms ePub, HTML, MOBI
Coimbra University Press	543	Alleen pdf
Universitätsverlag Göttingen	517	Altijd pdf soms ePub
Brill	447	Alleen pdf
Böhlau	347	Alleen pdf
Open Book Publishers	312	Altijd pdf, soms XML (TEI ¹⁸) of online HTML; vaak ePub en MOBI tegen betaling;
Manchester University Press	294	Altijd pdf, soms HTML-download
BCCampus	71	Altijd pdf, vaak ook HTML, ePub, MOBI en XML (Pressbooks ¹⁹), soms DOCX/ODT

¹⁸ tei-c.org/guidelines/¹⁹ pressbooks.com/

Uit de steekproef blijkt dat bijna alle titels worden aangeboden in pdf-formaat. Het op één na meest gebruikte formaat is ePub. Veel minder voorkomend zijn MOBI, de verschillende XML-formaten en HTML-webpagina's of DOX/ODT-documenten. In de volgende paragrafen (2.3 -2.7) volgt een meer nauwkeurige beschrijving van deze bestandsformaten, inclusief de mogelijkheden om deze formaten te bewerken.

2.3. Documenten in pdf-formaat

Het ontwerp van de pdf-standaard zorgt ervoor dat documenten altijd met dezelfde lay-out worden gepresenteerd, op elk apparaat en in elke pdf-lezende applicatie. Om dit mogelijk te maken zijn documenten in pdf-formaat opgebouwd uit elementen, die elk een coördinaat op een pagina hebben. In tegenstelling tot bijvoorbeeld een Microsoft Worddocument, kent een pdf geen structuur met informatie over 'rollen' van stukken tekst zoals hoofdtekst, titels en paginanummering. Zodra een document als pdf wordt opgeslagen gaat deze informatie verloren. Dit maakt een pdf vrijwel onmogelijk om te bewerken.

Voor het overnemen van complete pagina's of hoofdstukken zonder deze te bewerken kan je een tool als PDFSam²⁰ gebruiken. Om een volledige pdf te converteren naar een ander bestandsformaat kan Adobe Acrobat Pro²¹ worden gebruikt. Maar dan blijven de eerdergenoemde beperkingen van de pdf aanwezig. Bij conversie naar bijvoorbeeld een .docx-formaat heeft het nieuwe document geen concept van welke rol een bepaald stuk tekst heeft in het document. Tekstvakken blijven beperkt tot één bladzijde. De bewerking van doorlopende stukken tekst is vrijwel onmogelijk zonder een nieuw document op te bouwen.

De beste optie voor pdf-documenten is daarom extractie van zo veel mogelijk nuttige losse elementen om deze vervolgens met de hand te verwerken tot een nieuw bestand in een formaat dat wél bewerkbaar is. Door de manier waarop een pdf is opgebouwd, zijn er helaas geen tools die dit volledig automatisch kunnen uitvoeren. Om alle tekstelementen binnen een document te extraheren, leveren de tools Apache Tika en het Poppler pakket²² redelijke resultaten op. Laatstgenoemde is echter voornamelijk gericht op gebruik onder één van de Linux distributies maar is met wat extra stappen ook grotendeels bruikbaar op Windows.

²⁰ pdfsam.org/²¹ acrobat.adobe.com/nl/nl/acrobat/acrobat-pro.html²² poppler.freedesktop.org/

Onder de paraplu van het Poppler project bevinden zich ook een aantal 'utilities' met een specifieke taak. Zo is er het programma *pdftotext* dat (vergelijkbaar met Tika) enkel de tekstelementen uit een pdf-document haalt en opslaat in een tekstbestand. De *pdftoxml* utility doet een soortgelijke extractie, maar neemt ook per tekstvak in de pdf, informatie als lettertype en paginacoördinaten mee. Vergelijkbaar hiermee is de utility *pdftohtml* die van een pdf een (aantal) HTML-bestanden maakt en daarbij zoveel mogelijk van de oorspronkelijke opmaak probeert te behouden (hieronder vallen bijvoorbeeld ook rasterafbeeldingen). Tot slot kunnen rasterafbeeldingen worden ontsloten door gebruik te maken van *pdftoimage*.

De bewerking van tabellen, vectorfiguren en vergelijkingen is vanuit een pdf vrijwel onmogelijk. Op het internet is een redelijk aantal sites die claimen dit te kunnen, maar (naast licentiebeperkingen) uit een steekproef blijkt dat de resultaten hiervan niet goed genoeg zijn voor gebruik. Een betere optie is daarom een screenshot maken om deze vervolgens in te voegen in het nieuwe document.

Vanwege de opbouw van documenten in pdf-formaat wordt nadrukkelijk geadviseerd om, indien mogelijk, gebruik te maken van de documenten die als bron dienen voor de conversie naar pdf werd gemaakt. Omdat deze voor de meeste bestanden niet publiek worden aangeboden zal het meestal noodzakelijk zijn om contact met auteur of uitgeverij te leggen.

2.4. Documenten in ePub-formaat

Bestanden met de ePub-extensie zijn eigenlijk 'vermomde' ziparchieven die HTML-bestanden bevatten. Deze bestanden zijn vooral bedoeld voor toepassing op e-readers. Simpelweg hernoemen van 'abc.epub' naar 'abc.zip' maakt het mogelijk om het archief uit te pakken en de HTML-bestanden te bewerken met een tekst- of HTML-editor. De documenten zijn vervolgens in een webbrowser te bekijken. Daarnaast zijn er ook softwarepakketten die ePub-bestanden direct bewerkbaar maken: Calibre²³ en Sigil²⁴.

2.5. Documenten in MOBI-formaat

Bestanden met de .mobi extensie zijn vooral bedoeld voor gebruik op de Kindle e-readers. Via het softwarepakket Calibre kunnen deze bestanden worden omgezet naar ePub-formaat en verder worden bewerkt.

²³ calibre-ebook.com/

²⁴ sigil-ebook.com/

2.6. Documenten in HTML-formaat

Documenten in HTML-formaat zijn al kort aangestipt in paragraaf 2.4 over documenten in ePub-formaat. Bewerking van documenten in HTML-formaat is mogelijk in een tekst- of HTML-editor in combinatie met een webbrowser.

2.7. Documenten in XML-formaat

Voor documenten in dit formaat is het van belang welk type XML er is gebruikt. Voor open tekstboeken zijn TEI en Pressbooks de twee gevonden typen. Hoewel alle bestanden in XML-formaat in een teksteditor kunnen worden geopend en bewerkt, is het ook in dit geval makkelijker om de relevante elementen naar een nieuw document in beter bewerkbaar formaat de kopiëren.

2.8. Aanbevelingen

De bewerking van de bestanden waarin de meeste open tekstboeken worden verspreid is relatief lastig of zoals in het geval van pdf-documenten, vrijwel onmogelijk. De beknopte technische verkenning die binnen dit project is uitgevoerd, heeft geen nieuwe inzichten opgeleverd met betrekking tot bewerkbaarheid van deze documenten. Zo komen wij tot de volgende aanbevelingen:

- Neem indien mogelijk contact op met de oorspronkelijke auteurs om de bronbestanden te achterhalen en deze te gebruiken als basis voor bewerkingen.
- Gebruik pdf-bewerkingssoftware om content uit een pdf te bewerken tot een nieuw document. Neem hierbij de Creative Commons licentievoorwaarden in acht.
- Voor het hergebruik van visuele content zoals schematische figuren, plaatjes, foto's en tabellen is het maken van screenshots een alternatieve oplossing. De kwaliteit van een screenshot is meestal minder dan het origineel.
- Auteurs van tekstboeken moeten in overweging nemen hoe zij verwachten dat hun tekstboek wordt hergebruikt. Publicatie van een tekstboek met een open licentie die gebruikers toestaat om het tekstboek te bewerken en hergebruiken is niet toereikend, als het format van het gepubliceerde bestand zelf slecht bewerkbaar is.

3. Conclusies en vervolgstappen

Het project 'Inventarisatie open tekstboeken' is uitgevoerd door de werkgroep Hergebruik open leermaterialen van de zone Naar digitale (open) leermaterialen. Voor het eerst is in Nederland een poging gedaan om een volledig overzicht te maken van open tekstboeken en om inzicht te krijgen in de onderwerpen en vakgebieden waarvoor open tekstboeken zijn gepubliceerd. Uit de resultaten van de inventarisatie blijkt de beschikbaarheid van veel open tekstboeken, gepubliceerd met open licenties. En dat aantal groeit gestaag door.

Tijdens de uitvoering van de inventarisatie van bestaande open tekstboeken heeft de werkgroep voor het maken van een volledig overzicht, een grote afhankelijkheid ervaren van de beschikbaarheid van metadata van de tekstboeken. In dit onderzoek zijn de tekstboeken geïnventariseerd die vindbaar zijn op platforms die hun metadata open beschikbaar stellen. Voor uitbreiding van deze inventarisatie, is toegang tot de metadata van ongebruikte bronnen die zijn genoemd in paragraaf 1.2, noodzakelijk.

De metadata die wél beschikbaar is, blijkt niet altijd uniform, of van een slechte kwaliteit die het onmogelijk maakt om tot een duidelijke indeling van tekstboeken te komen op basis van onderwerpen, kernwoorden en/of vakgebieden. Door gebruik te maken van geavanceerde tools kan de metadata verder worden verrijkt. Waardoor het bijvoorbeeld ook mogelijk wordt om te analyseren welke kernbegrippen voorkomen in een tekstboek. ElasticSearch lijkt een veelbelovende tool voor deze toepassing.

Een korte verkenning in het tweede deel van het project naar de bewerkbaarheid van de geïnventariseerde open tekstboeken, toont aan dat deze slecht is voor veel tekstboeken. Hoewel de licenties van de boeken meestal toestaan om content te bewerken of te kopiëren en in een andere context toe te passen, blijkt de vorm waarin de content is gepubliceerd, niet toereikend voor dat doel. Daarom adviseren wij om bij de ontwikkeling van diensten die auteurs ondersteunen bij de publicatie van open lesmateriaal, veel aandacht aan dit vraagstuk te geven en dit op te lossen. Zo zal toekomstig open lesmateriaal werkelijk geschikt zijn om te kopiëren, aan te passen en te remixen met andere content tot nieuwe content.

Deze aanbevelingen dienen als advies voor de werkgroep Infrastructuur & Content, van de zone Digitale leermaterialen. De suggesties voor het verder verrijken van metadata en de ontwikkeling van diensten rondom de publicatie van open tekstboeken zijn inmiddels opgenomen in het tweejarig projectvoorstel van deze werkgroep. Hiermee komen de activiteiten van de werkgroep Hergebruik open leermaterialen ten einde.


Wil je op de hoogte worden gehouden over het vervolg van het project? Of wens je meer informatie over de technische uitvoering van dit project? Stuur een e-mail aan leermaterialen@versnellingsplan.nl onder vermelding van inventarisatie open tekstboeken.

Bijlage A

Resultaten inventarisatie
open tekstboeken
per vakgebied




Onderwerpen




 Licentietypen

Overzicht vakgebied Gedrag en Maatschappij





Aantal boeken per publicatiejaar



Onderwerpen

Talen




 Licentietypen

Overzicht vakgebied Gezondheid


Aantal publicaties

2.705




Aantal boeken per publicatiejaar

Talen





Onderwerpen



)) Licentietypen

Overzicht vakgebied Onderwijs en Opvoeding




Onderwerpen



Overzicht vakgebied Recht en Bestuur

Aantal publicaties

3.742





Aantal boeken per publicatiejaar



Onderwerpen

Talen




Licentietypen


Overzicht vakgebied Taal en Communicatie

Aantal publicaties 

4.092





Aantal boeken per publicatiejaar



Onderwerpen

Talen




) Licentietypen


Overzicht vakgebied Techniek

Aantal publicaties

2.917





Aantal boeken per publicatiejaar



Onderwerpen

Talen



Licentietypen



Het Versnellingsplan Onderwijsinnovatie met ICT is een vierjarig programma van SURF, Vereniging Hogescholen en de VSNU dat inzet op het samenbrengen van initiatieven, kennis en ervaringen en snel en concreet aan de slag gaan met kansen voor het hoger onderwijs. Dit gebeurt in acht verschillende 'zones'. In de Versnellingszone Naar digitale (open) leermaterialen werken 8 instellingen aan de ambitie dat studenten en docenten in staat zijn hun optimale mix van leermaterialen te kunnen samenstellen en gebruiken.



Meer informatie en onze publicaties vind je op
www.versnellingsplan.nl