



Universiteit
Leiden
The Netherlands

Deep learning solutions for domain-specific image segmentation

Vadineanu, S.

Citation

Vadineanu, S. (2025, October 8). *Deep learning solutions for domain-specific image segmentation*. Retrieved from <https://hdl.handle.net/1887/4266937>

Version: Publisher's Version


License: [Licence agreement concerning inclusion of doctoral thesis in the Institutional Repository of the University of Leiden](#)

Downloaded from: <https://hdl.handle.net/1887/4266937>

Note: To cite this publication please use the final published version (if applicable).


Samenvatting

Beeldsegmentatie is een proces dat een afbeelding opdeelt in afzonderlijke regio's, waarbij deze worden geïdentificeerd en gecategoriseerd op basis van gedeelde kenmerken zoals kleur, textuur of grenzen (zie Figuur S1 voor een schematische weergave van celsegmentatie). Deze techniek biedt mogelijkheden om een breed scala aan problemen in gespecialiseerde domeinen aan te pakken, van het detecteren van tumoren in computertomografiescans voor medische beeldvorming tot het identificeren van vindplaatsen in archeologisch onderzoek. Momenteel zijn de best presterende algoritmen voor beeldsegmentatie gebaseerd op deep learning.



Figuur S1: Voorbeeld van beeldsegmentatie. De celvormen en de segmentatie zijn afkomstig uit [86].

Deep learning verwijst naar een categorie statistische modellen die worden getraind om taken uit te voeren door te leren van grote datasets. Bij beeldsegmentatie bijvoorbeeld wordt het model getraind met invoerafbeeldingen en de bijbehorende annotaties (gecategoriseerde regio's binnen de afbeelding). Een training pipeline voor deep learning-segmentatie-algoritmen omvat doorgaans een eerste fase waarin annotaties worden gemaakt (annotatieproces), gevolgd door een tweede fase waarin het algoritme wordt getraind met de invoerafbeeldingen en de eerder gemaakte annotaties (trainingsproces). Figuur S2 toont een overzicht van dit traject.



Figuur S2: Deep learning ontwikkel pipeline van een initiële set afbeeldingen naar een getraind model.

Ondanks de veelbelovende resultaten van deep learning voor beeldsegmentatie, wordt de brede toepassing ervan in gespecialiseerde domeinen beperkt door uitdagingen in de annotatie en training. Binnen de annotatie fase is het markeren van regio's in afbeeldingen niet alleen tijdrovend maar ook foutgevoelig door onnauwkeurige of verkeerd aangegeven grenzen, gezien dit proces vaak handmatig moet gebeuren. In gespecialiseerde domeinen is dit nog uitdagender, omdat deskundige kennis nodig is voor het annoteren, wat extra kosten met zich meebrengt en limitaties kent in beschikbaarheid van deskundigen. Experts in deze vakgebieden hebben vaak drukke agenda's, en de benodigde kennis is soms slechts aanwezig bij een kleine groep mensen. Wat de training betreft, vereisen deep learning-algoritmen grote hoeveelheden voorbeelden en hebben ze een slecht-inzichtelijk werkingsmechanisme voor het maken van beslissingen, wat ook weer extra obstakels oplevert. Het verzamelen van voldoende gegevens kan kostbaar zijn en speciale apparatuur vereisen, het voorbereiden van samples (zoals in medische beeldvorming), of zelfs reizen naar specifieke locaties (zoals voor archeologie). Een aanvullende uitdaging is dat deep learning-modellen geen duidelijke, stapsgewijze uitleg van hun beslissingsproces geven, waardoor eindgebruikers terughoudend zijn om erop te vertrouwen.

Dit proefschrift biedt een reeks oplossingen om de uitdagingen aan te pakken die gepaard gaan met de annotatie- en trainingsprocessen van deep learning-algoritmen voor beeldsegmentatie in gespecialiseerde domeinen. We richten ons daarbij specifiek op twee toepassingen: celsegmentatie in biomedische beeldvorming en de detectie van archeologische sites vanuit satellietbeelden. In Hoofdstuk 2 onderzoeken we de impact van annotatiefouten op de prestaties van deep learning-modellen voor celsegmentatie. Hierop voortbouwend, introduceert Hoofdstuk 3 een trainingstechniek die deep learning-modellen in staat stelt te leren van annotaties van lage kwaliteit, zoals annotaties met ontbrekende regio's of onnauwkeurige grenzen. In Hoofdstuk 4 presenteren we een nieuw deep learning-algoritme dat in staat is celsegmentatie uit te voeren met slechts een klein aantal geannoteerde afbeelding-annotatieparen (bijvoorbeeld 5 paren). Hoofdstuk 5 onderzoekt de toepassing van explainability-technieken op deep learning-modellen die zijn getraind voor beeldclassificatie. Hierbij worden visuele representaties gegenereerd van de afbeeldingsregio's die het model als relevant beschouwt. We analyseren deze visualisaties om inzicht te krijgen in de geleerde patronen en verfijnen ze verder om semi-automatische annotaties voor segmentatie van archeologische sites te creëren. Dit vermindert de benodigde tijd van domeinexperts in vergelijking met handmatige annotatie.