



Universiteit
Leiden
The Netherlands

Understanding deep meta-learning

Huisman, M.

Citation

Huisman, M. (2024, January 17). *Understanding deep meta-learning*. SIKS Dissertation Series. Retrieved from <https://hdl.handle.net/1887/3704815>

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/1887/3704815>

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

Dutch summary

Diepe neurale netwerken hebben indrukwekkende prestaties laten zien in verschillende domeinen, vaak met capaciteiten op menselijk of bovenmenselijk niveau. Hun succes hangt echter sterk af van de beschikbaarheid van uitgebreide trainingsdata, wat problematisch wordt in domeinen waar het verzamelen van zulke data uitdagend, kostbaar of privacygevoelig is. Het verbeteren van de data-efficiëntie van diepe neurale netwerken en het overkomen van deze beperkingen is van groot belang. Door dit te doen, kunnen we het volledige potentieel van deze netwerken ontsluiten, waardoor ze effectief kunnen leren en zich kunnen aanpassen, zelfs wanneer ze met beperkte gegevens worden geconfronteerd. Deze verbetering maakt ook de weg vrij voor hun inzet in omgevingen met beperkte middelen, waardoor de democratisering van *deep learning* wordt bevorderd door het toegankelijker en toepasbaarder te maken in verschillende domeinen.

Een van de mogelijke oorzaken van hun inefficiënte leervermogen is het feit dat diepe neurale netwerken vaak zonder enige voorkennis worden getraind. *Deep meta-learning* is naar voren gekomen als een snelgroeiend veld om de leerefficiëntie van diepe neurale netwerken te verbeteren door ze de mogelijkheid te geven om eerdere ervaringen en kennis te hergebruiken. Dit proefschrift richt zich specifiek op de toepassing van *deep meta-learning* in scenario's voor leren met weinig trainingsdata, waarbij netwerken zich snel moeten aanpassen aan nieuwe taken met slechts een beperkt aantal voorbeelden per taak.

Ondanks de recente vooruitgang op dit gebied van *few-shot learning*, worden de onderliggende principes die het succes van meta-learning-algoritmen stimuleren nog steeds slecht begrepen, wat de ontwikkeling van algoritmen en ontwerpkeuzes belemmert. In dit proefschrift nemen we stappen om deze kenniskloof te overbruggen door een uitgebreid begrip te verwerven van de fundamentele principes van populaire *deep meta-learning* algoritmen, waardoor een beter geïnformeerde ontwikkeling van algoritmen mogelijk wordt en een robuuste theoretische basis wordt gelegd. Bovendien onderzoekt dit werk de integratie van theoretische principes in praktisch algoritmeontwerp om de prestaties van *deep meta-learning* technieken te verbeteren. Door deze onderzoekshiaten aan te pakken, beoogt dit proefschrift het veld vooruit helpen en de weg vrij te maken voor meer effectieve en principiële *meta-learning* technieken die een bredere toepasbaarheid en superieure prestaties bieden. Hieronder volgt een kort overzicht van het proefschrift.

Hoofdstuk 2 dient als een uitgebreide inleiding en overzicht en biedt lezers een solide theoretische basis voor het begrijpen van *deep meta-learning* algoritmen. We verdiepen ons in de belangrijkste methoden en categoriseren ze in drie hoofdcategorieën: i) op metrische gegevens gebaseerde technieken, ii) op modellen gebaseerde technieken en iii) op optimalisatie gebaseerde technieken. Door deze benaderingen te onderzoeken, willen we een holistisch begrip bieden van de diverse methodologieën die worden gebruikt bij *deep meta-learning*. Verder identificeren en bespreken we de belangrijkste

openstaande uitdagingen in het veld. Deze uitdagingen omvatten de behoefte aan prestatie-evaluaties op heterogene benchmarks om de robuustheid en generaliseerbaarheid van *meta-learning* algoritmen te waarborgen.

In Hoofdstuk 3 onderzoeken we een empirisch waargenomen prestatiekloof tussen twee populaire en sterk verwante *deep meta-learning* algoritmen: de meta-learning LSTM en MAML. We vonden deze prestatiekloof verrassend op basis van ons werk in Hoofdstuk 2 omdat de meta-learning LSTM expressiever is dan MAML en in theorie het gedrag van MAML zou kunnen nabootsen. Om deze prestatiekloof beter te begrijpen, introduceren we een nieuw algoritme genaamd TURTLE. Het ontwerp en de analyse van TURTLE laten zien dat de opmerkelijke prestatiekloof kan worden toegeschreven aan de invloed van gradiënten van de tweede orde. We vinden dat gradiënten van de tweede orde ook de nauwkeurigheid van de meta-learning LSTM aanzienlijk kunnen verhogen met kleine aanpassingen van de invoer die aan de LSTM wordt geleverd.

Een verwante methode aan *deep meta-learning* is de overdrachtsleermethode die algemeen bekend staat als pre-training en fine-tuning. In Hoofdstuk 4 onderzoeken we de waargenomen prestatieverschillen tussen finetuning, MAML en een andere *meta-learning* techniek genaamd Reptile. We presenteren resultaten die aangeven dat MAML en Reptile de neiging vertonen om zich te specialiseren in snelle aanpassing aan *low-data-regimes* die worden gekenmerkt door vergelijkbare datadistributies als degene die tijdens de training worden gebruikt. Onze bevindingen benadrukken het belang van zowel de uitvoerlaag als de aanwezigheid van *noisy* trainingsomstandigheden veroorzaakt door gegevensschaarste in de *few-shot* leeromgeving. Deze factoren dragen aanzienlijk bij aan het mogelijk maken van de specialisatie die wordt waargenomen in MAML en Reptile. Bovendien tonen we aan dat de vooraf getrainde functies die zijn verkregen via de finetuning-baseline een grotere diversiteit en onderscheidend vermogen vertonen in vergelijking met die geleerd door MAML en Reptile. Dit gebrek aan diversiteit en distributiespecialisatie in MAML en Reptile kan hun vermogen belemmeren om effectief te generaliseren naar doeltaken die aanzienlijk verschillen van de geobserveerde trainingstaken. Finetuning daarentegen kan gebruikmaken van de diverse reeks aangeleerde functies om zich met meer succes aan te passen aan dergelijke verre doeltaken.

In Hoofdstuk 5 gaan we terug naar een klassieke LSTM-benadering van *deep meta-learning*, waarbij het idee is om een trainingsdataset in een LSTM in te voeren en de voorspellingen voor nieuwe datapunten te conditioneren op de resulterende verborgen staat van het netwerk. Het is bekend dat deze benadering maximaal expressief is, dat wil zeggen dat de LSTM zou kunnen leren om elk leeralgoritme te implementeren. Ondanks de veelbelovende resultaten van deze aanpak bij kleine problemen en bij *reinforcement learning* problemen, heeft de aanpak weinig aandacht gekregen in de *supervised learning* hoek. We laten zien dat LSTM beter presteert dan de populaire *meta-learning* techniek MAML op een eenvoudige sinusgolf regressiebenchmark, maar dat LSTM zoals verwacht tekort schiet op complexere *few-shot* beeldclassificatie benchmarks. We identificeren twee potentiële factoren die bijdragen aan de waargenomen beperkingen en stellen een nieuwe methode voor, *Outer Product LSTM* (OP-LSTM) genaamd, om deze problemen effectief aan te pakken. OP-LSTM overtreft de prestaties van gewone LSTM en vertoont aanzienlijke prestatieverbeteringen. Hoewel deze resultaten geen nieuwe state-of-the-art vormen, staan de vorderingen van OP-LSTM orthogonaal op andere vorderingen op het gebied van *meta-learning*, wat nieuwe inzichten oplevert in hoe LSTM werkt bij beeldclassificatie, en nieuwe onderzoeksrichtingen oplevert.

In Hoofdstuk 6 onderzoeken we of de integratie van het feit dat meer expressieve modellen eerder geneigd zijn tot overfitten, de leerprestaties van neurale netwerken kan verbeteren door te meta-lernen welke parameters moeten worden aangepast. Om dit te onderzoeken, stellen we *Subspace Adaptation Prior* (SAP) voor, een nieuw op gradiënt gebaseerd *meta-learning* algoritme dat gezamenlijk goede

initialisatieparameters (voorkennis) en laaggewijze *parameter subspaces* leert in de vorm van subsets van bewerkingen die aanpasbaar moeten zijn. Op deze manier kan SAP leren welke bewerkingsubsets moeten worden aangepast op basis van de onderliggende taakverdeling, terwijl tegelijkertijd het risico van overfitting wordt verminderd bij het aanleren van nieuwe taken. We tonen aan dat deze mogelijkheid nuttig is, aangezien SAP superieure of concurrerende prestaties levert bij classificatie-instellingen voor weinig opnamen (winsten tussen 0,1% en 3,9% in nauwkeurigheid). Analyse van de aangeleerde deelruimten laat zien dat laag-dimensionale operaties vaak hoge activeringssterktes opleveren, wat aangeeft dat ze belangrijk kunnen zijn voor het bereiken van goede ‘few-shot’ leerprestaties.

Als zodanig hebben we in dit proefschrift analyse en empirische validatie uitgevoerd van verschillende *meta-learning* systemen, waaronder MAML, Reptile, finetuning en verschillende op LSTM gebaseerde benaderingen. Daarnaast hebben we de integratie van theoretische principes voor praktische algoritme-ontwikkeling onderzocht. Kortom, we hebben een kleine stap gezet in de richting van een beter begrip van *deep meta-learning*-algoritmen, waarmee we de weg hebben vrijgemaakt voor robuustere en meer principiële meta-learning-technieken met een bredere toepasbaarheid en superieure prestaties.

