



Universiteit
Leiden
The Netherlands

From benchmarking optimization heuristics to dynamic algorithm configuration

Vermetten, D.L.

Citation

Vermetten, D. L. (2025, February 13). *From benchmarking optimization heuristics to dynamic algorithm configuration*. Retrieved from <https://hdl.handle.net/1887/4180395>

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/1887/4180395>

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

Samenvatting

In de context van optimalisatie kan benchmarking worden gezien als een verbinding tussen het theoretisch analyseren van algoritmes en de praktijk. De empirische aard van benchmarking zorgt ervoor dat experimenten op grote schaal kunnen worden uitgevoerd om vragen te beantwoorden die te complex zijn voor de huidige theoretische methoden. Tegelijkertijd hoeft benchmarking niet in een specifiek praktisch gebied te passen, maar kan het een breder scala aan fundamentele vragen bestuderen. Deze combinatie zorgt dat benchmark-studies een grote variëteit aan nieuwe inzichten over de relatieve sterktes en zwaktes van optimalisatie algoritmes kunnen opleveren.

Gezien de potentiële voordelen van robuuste benchmarking-opstellingen is het belangrijk dat er laagdrempelige tools beschikbaar worden gemaakt. Deze opstellingen moeten flexibel genoeg zijn om tegemoet te komen aan de grote verscheidenheid aan vragen die worden gesteld, terwijl ze tegelijkertijd rigoureuze kaders bieden voor de rest van de benchmarking-pijplijn. In deze thesis focussen we op IOHprofiler, een benchmarking pakket ontwikkeld als hulpmiddel voor de bredere onderzoeksgemeenschap. Met behulp van een modulaire structuur kan IOHprofiler worden geïntegreerd met veel bestaande tools die op grote schaal worden gebruikt. Deze integraties vormen de ruggengraat voor de experimenten die in deze thesis worden gebruikt, omdat de bijbehorende data, zowel over de prestatie van de algoritmes als over hun gedrag, eenvoudig kan worden hergebruikt. Op deze manier kunnen we verder gaan dan de gebruikelijke ‘competitieve’ instelling, waarbij alleen gelet wordt op het algoritme met de beste gemiddelde prestaties, en in plaats daarvan inzicht krijgen in de complementariteit tussen verschillende algoritmes.

Een van de belangrijkste manieren waarop complementariteit tussen algoritmes nuttig kan zijn, is in de context van algoritmeselectie en -configuratie. In plaats van te vertrouwen op één enkel algoritme voor een breed scala aan problemen, gebruiken we een reeks test-functies om te bepalen welk algoritme of welke algoritmeconfiguratie

we moeten gebruiken op nieuwe problemen. Deze meta-leertaak profiteert van de variatie tussen algoritmen, die kan worden verkregen door naar verschillende soorten algoritmen te kijken, maar ook binnen een algoritmefamilie door rekening te houden met een grote hoeveelheid modificaties die de afgelopen decennia zijn voorgesteld. We laten zien hoe twee modularisaties van populaire evolutionaire algoritmen kunnen leiden tot nieuwe inzichten over combinaties van algoritmische ideeën, resulterend in verbeterde prestaties ten opzichte van eerdere, met de hand ontworpen versies van dezelfde algoritmen.

Hoewel er op probleemniveau al sprake is van complementariteit van algoritmen, blijkt uit de benchmarkgegevens van verschillende bronnen ook dat er ook sprake is van complementariteit in de prestaties binnen individuele functies. Hoewel sommige algoritmen uitstekend zijn in het vinden van veelbelovende regio's, blinken andere uit in snelle convergentie zodra deze regio is gevonden. Als zodanig wordt het begrip dynamische algoritmeselectie, waarbij we tijdens de optimalisatieprocedure tussen verschillende algoritmen kunnen wisselen, in detail bestudeerd. We benadrukken het inherente potentieel van deze aanpak, terwijl we tegelijkertijd de aspecten van deze wisseling benadrukken die verder ontwikkeld moeten worden om betrouwbare dynamische algoritme-combinaties te creëren.

Dynamische algoritmeselectie is een veelbelovend onderzoeksgebied binnen optimalisatie, maar studies naar de prestaties ervan zijn nog enigszins beperkt. Dit is grotendeels een gevolg van de moeilijkheid om betrouwbare benchmarking-opstellingen voor dit scenario te creëren. Hoewel verschillende suites voor benchmarking-optimalisatie-algoritmen beschikbaar zijn, zijn deze niet bijzonder geschikt voor meta-leerscenario's, omdat er geen echt eerlijke manier is om het algemeen vereiste onderscheid tussen train- en testproblemen te creëren dat wordt gebruikt door de vereiste machine learning-technieken. Om deze reden stellen we een benchmark-probleemgenerator voor, gebaseerd op veelgebruikte black-box-optimalisatieproblemen, die kan worden gebruikt om willekeurige hoeveelheden train- en testproblemen te genereren om deze meta-leermechanismen te benchmarken.