

# Variance and Resource Usage of Computational Experiments

---

Bachelorarbeit · Universität Basel

Nillan Sivarasa  
27.07.2026

# Aufbau

---

- 1 Einleitung
- 2 Planning & Benchmarking
- 3 Infrastruktur
- 4 Resultate
- 5 Diskussion & Fazit

# Einleitung

---

## Ausgangslage

- Computational Experiments vergleichen Algorithmen über gemessene Runs
- Bei Planning-Experimenten stehen Runtime, Coverage und Failures im Fokus
- Auf Shared HPC-Systemen können Scheduling, Node Placement und Interferenz die Messungen beeinflussen

## Hauptfrage

Wenn derselbe Planner Command auf derselben Benchmark-Task wiederholt wird:

Wie stabil ist die gemessene Runtime?

# Classical Planning mit Fast Downward

PDDL Task → Fast Downward → Plan oder Failure + Runtime

## Planner-Konfigurationen:

|                   |                                 |
|-------------------|---------------------------------|
| UCS               | einfache optimale Baseline      |
| A* LM-cut         | informierte optimale Search     |
| LAMA First        | Satisficing Search              |
| Operator Counting | LP-basierte Heuristic mit CPLEX |

# Benchmarking auf einem Shared Slurm-System

## Reliable Benchmarking braucht

- Resource Limits
- CPU Placement und mögliche NUMA-Effekte
- Isolation von anderen Jobs
- Measurement und vollständige Experimentdaten

## Praktische Limitation

BenchExec mit vollständiger cgroup-Isolation konnte auf dem Cluster nicht verwendet werden, weil Slurm Jobs die nötigen Sub-cgroups nicht erstellen konnten.

## Finaler Ansatz

Slurm Resource Requests + Apptainer Container + explizite Records der verbleibenden Limitationen

# Experimentelle Infrastruktur

## Pipeline

JSON Experiment → Slurm Array → Apptainer Container

Raw Outputs → CSV/JSON → Plots

## Experiment Settings

```
{
  "tasks": 133,
  "domains": 5,
  "repetitions": 5,
  "limits": {
    "time": "5 min",
    "memory": "4 GB"
  },
  "cpu_counts": [1, 2, 4, 8, 16, 32, 64,
128]
}
```


## Wichtige Metriken

- Mean Runtime
- Standard Deviation
- Coefficient of Variation (CV)
- Allocated CPU Time

# Leitfragen

- Q1** Wie stark variiert Runtime bei wiederholten Runs?
- Q2** Ändert ein kombiniertes UCS + A\* LM-cut Setup die Messungen?
- Q3** Wie wirken Memory Binding, CPU Allocation und Ressourcen?
- Q4** Welche Experimentdaten verbessern Repeatability?

# Runtime Variation über wiederholte Runs



## Interpretation

Hohe CV-Werte treten hauptsächlich bei sehr kurzen erfolgreichen Tasks auf.



Bei Mean Runtimes über ungefähr einer Sekunde bleibt CV unter etwa 3%.

Eine globale Runtime-Verteilung vermischt Task Difficulty mit Measurement Variation.

## Antwort

Varianz pro Task und Konfiguration analysieren.

# Isoliertes versus Kombiniertes Experiment-Setup



## Interpretation


Isolierte und kombinierte Runs verlaufen sehr ähnlich.

## Antwort

Einzelne Task-Werte ändern sich, aber nicht systematisch.

Kein klarer globaler Effekt auf Runtime oder CV.

# Memory Binding



## Interpretation

Keine Reduktion durch Memory Binding.


Median-CV-Werte sind grob ähnlich.

Setup Effekte sind kleiner als Task- und Konfigurationsunterschiede.

## Antwort

Memory Binding zeigte im getesteten Setup keinen klaren Stabilitätsvorteil. NUMA-Effekte werden damit nicht allgemein ausgeschlossen.

# CPU Allocation



## Interpretation

Fast Downward Commands sind Single-Process Runs.


Runtime-Linien bleiben von 1 bis 128 Requested CPUs flach.

## Antwort

Zusätzliche CPUs reservieren Kapazität ohne Runtime-Vorteil.

Nur so viele CPUs anfordern, wie genutzt werden können.

# Resource Usage



## Interpretation

Allocated CPU Time wächst fast proportional mit der Requested CPU Count.

128-CPU-Gruppen dominieren CPU Hours und das Estimated-kWh-Ranking.

kWh-Werte sind Schätzungen, keine direkte Energy Measurement.

## Antwort

CPU Allocation beeinflusst vor allem die reservierten Ressourcen.

Records machen das Experiment nachvollziehbar.

# Diskussion

---

## Limitationen

- Keine BenchExec/cgroup-Isolation auf dem Cluster
- Resultate hängen von Tasks, Limits, Configurations und Cluster Setup ab
- Direkte Energy Measurement nicht verfügbar

## Einordnung

- Container verbessern die Repeatability der Software-Umgebung
- Sie entfernen Scheduling-, Hardware- oder Interference-Effekte nicht
- Der klarste Setup-Effekt liegt im Resource Accounting, nicht in der Planner Runtime

# Fazit

---

## Antwort auf die Hauptfrage

Die Runtime ist bei längeren erfolgreichen Tasks relativ stabil. Hohe relative Schwankungen treten vor allem bei sehr kurzen Tasks auf.

## Kernaussagen

- Kombinierte UCS + A\* LM-cut Runs zeigten keinen klaren Runtime- oder CV-Shift
- Memory Binding verbesserte die Stabilität im getesteten Setup nicht klar
- Excessive CPU Allocation erhöht CPU-Time stark, ohne klaren Runtime-Vorteil
- Runtime Stability und Resource Accounting müssen getrennt interpretiert werden

## Future Work

Mehr Repetitions · Direct Energy Accounting · Tests über Node Types oder Partitions