

HPC-Scheduling mit PBS Pro

Altair

Summer 2010



PBS Professional – New in 10.x!

OS Provisioning

Scheduling
Formula

Fairshare

High-availability
Reservations

Web Services

Job
Dependencies

24x7 On-line
Community

On-demand
Licensing

Hooks

Policy-based
Scheduling

Standing
Reservations

Kerberos

Age-based
Scheduling

License
Scheduling

EAL3+ Security

GPU Scheduling



Estimated Job
Start Times

Huge Scalability

Green
Provisioning

Over-subscription

Script-less Job
Submission

Eligible time

\$restrict_user

Preemption

Dynamic
Resources

Interactive Jobs

User/Group VIP
Limits

Meta-scheduling

MPI Integrations

Fail-over

Checkpoint /
Restart

Job Arrays

Topology
Placement Sets

Job History
(qstat -x)

Multi-core

Peer Scheduling

Backfill TopN

Job Management

Job Submit mittels qsub:

```
#PBS -N MyJob
#PBS -l mppwidth=128
#PBS -l mppnppn=4
#PBS -l mppdepth=6
#PBS -l walltime=01:00:00
#PBS -j oe
export OMP_NUM_THREADS=6
aprun -B a.out
```

Erläuterung:

Name

Anzahl MPI-Prozesse

Anzahl MPI-Prozesse pro Node (opt)

Anzahl OpenMP-Threads pro Prozess

Laufzeit

Behandlung von stdout/stderr (opt)

Für OpenMP Runtime

aprun -B: aprun-Parameter werden aus der Batch-Umgebung ausgelesen

Weitere User-Kommandos:

Anzeigen der Jobs bzw der Queues: qstat [-a|-f|-Q]

Löschen von Jobs: qdel

Job vom Scheduling ausnehmen und rückgängig machen: qhold und qrls

Vorschlag zur Queue-Struktur

- User müssen keine Queue angeben
 - Jobs werden nach Größe (in Core-Anzahl) und Laufzeit automatisch in die richtige Queue geleitet
 - Passt der Job in keine Queue, wird er nicht angenommen
- Vorhandene Queues:
 - testq: bis zu 96 Cores, max. 2 Stunden Walltime
 - c1kt48h: bis zu 1.024 Cores, max. 48 Stunden Walltime
 - c2kt8h: bis zu 2.048 Cores, max. 8 Stunden Walltime
 - c4kt2h: bis zu 4.096 Cores, max. 2 Stunden Walltime
- Bei Erreichen des Walltime-Limit werden Jobs abgebrochen
- Weitere Einstellungen:
 - Zahl der laufenden Jobs pro Queue
 - Zahl der laufenden Jobs pro User pro Queue
 - Zugang mittels User Id

Flexible Jobprioritäten mittels Formel: Ansatz

- Queues zur Definition von Jobklassen
 - Limits für Zahl der laufenden Jobs oder belegten Nodes
 - ACLs für User und Gruppen
- Formel zur Berechnung der Jobpriorität und damit der Startreihenfolge
 - Reihenfolge strikt einhalten (`strict_ordering: true`)
 - Verbesserung der Auslastung mittels Backfill (`backfill_depth`)
 - Jede Ressource (vordefiniert oder selbst hinzugefügt) kann in der Formel verwendet werden plus einige spezielle Ressourcen (`queue_priority`, `eligible_time`)
 - Verfolgung für Admins (Scheduler-Log) und für User (`est_start_time_freq`, `qstat -T`, erst mit PBS 10.4)

Flexible Jobprioritäten mittels Formel: Vorschlag

`job_sort_formula =`

`Wsize * mppwidth *
mppdepth +`

`Wwait * eligible_time /
3600.0 +`

`Wqueue * queue_priority +`

`Wuser * user_p +`

`special_p`

Bevorzugung:

Großer Jobs

Lange wartender Jobs

Jobs in High Prio Queues

Bestimmter User

„Admin-Knopf“

Flexible Jobprioritäten mittels Formel: Selbstdefinierte Ressourcen

```
job_sort_formula =  
  
Wsize * mppwidth  
*mppdepth +  
  
Wwait * eligible_time /  
3600.0 +  
  
Wqueue * queue_priority +  
  
Wuser * user_p +  
  
special_p
```

Berücksichtigung selbst-definierter
Ressourcen
(server_priv/resourcedef)

- Flags r und i für read-only und invisible Ressourcen
- Setzen per Queue- oder Server-Defaults
- Setzen per qsub-Hook (Python):
Nachschlagen von user_p, z.B.
aus Allocation Management-
System

Admin-Knopf:

```
qalter -l special_p=1000000 jobid
```

Flexible Jobprioritäten mittels Formel: Information

Information für Admins und User:

```
% qstat -T
```

Job ID	Username	Queue	Jobname	SessID	NDS	TSK	Req'd Memory	Req'd Time	Est S	Est Start
5.quark	bill	workq	foo	12345	1	1	128mb	00:10	R	-
9.quark	bill	workq	bar	--	1	1	128mb	00:10	Q	11:30
10.quark	bill	workq	gril	--	1	1	128mb	00:10	Q	11:40
7.quark	bill	workq	baz	--	1	1	128mb	00:10	Q	Tu 18

```
% qstat -f
```

```
. . .  
estimated.exec_vnode = (pepsi:ncpus=1)  
estimated.start_time = Tue Apr 27 11:52:44 2010
```

Wenn die Startzeit nicht ausreicht, kann mittels der Gewichte oder special_p nachjustiert werden.

Flexible Jobprioritäten mittels Formel: Weitere Konfiguration

Weitere Server- und Scheduler-Konfiguration unterstützt die Formel

- Ressourcen-Definition in `server_priv/resourcedef`
- Queue-Definition mit Limits, ACLs, Defaults, Queue-Priorität
- Scheduler-Konfiguration
 - Wartezeit (`eligible_time_enable`)
 - Backfill (`backfill_depth`)
 - Startzeit-Vorhersage (`est_start_time_freq`)
 - Gleitende Berücksichtigung der Queue-Priorität (`round_robin: false` und `by_queue: false` und `sort_queues: false`)
- `qsub/qalter`-Hook: Abfrage eines externen Tools für Allocation Management o.ä. zur Ermittlung der User-Priorität

HPC-Scheduling mit PBS Pro

- Ressourcen-Engine
- Scheduling-Optionen
- Numerische Formel für Jobprioritäten
- Python-Hooks

erlauben flexibles und verlässliches Scheduling mit PBS Pro