

HTCondor As A Service

Batch System

STEFANO DAL PRA



Perugia 28 Nov 2019,

Email: stefano.dalpra@cnafe.infn.it


Premessa e disclaimer

- Molte parti di queste slides si rifanno in modo diretto a presentazioni date agli “HTCondor week” o simili eventi, su temi attinenti. Si consiglia di fare riferimento a questi per approfondimenti
- HTC week 2019: <https://agenda.hep.wisc.edu/event/1325/> (User oriented)
- HTC week 2018: <https://agenda.hep.wisc.edu/event/1201/>
- HTC workshop 2019: <https://indico.cern.ch/event/817927/> (Admin oriented)
- <https://htcondor.readthedocs.io>

Conoscenza introduttiva



Panoramica per orientarsi all'ambiente



Panoramica Per HTCondor

Conoscenza dettagliata, “offroad”



L'ambiente, dettagli

```
10/23/19 18:16:15 (D_SECURITY) SECMAN: command 60
19> from TCP port 1747 (non-blocking).
10/23/19 18:16:15 (D_SECURITY) SECMAN: waiting fo
9>.
10/23/19 18:16:15 (D_ALWAYS:2) DaemonKeepAlive: L
10/23/19 18:16:15 (D_ALWAYS:2) SharedPortClient:
.35:9619> for shared port id 20786_3e80
10/23/19 18:16:15 (D_SECURITY) SECMAN: resuming c
.11.35:9619> from TCP port 1747 (non-blocking).
10/23/19 18:16:15 (D_SECURITY) SECMAN: using sess
a6a6 for {<192.135.11.35:9619?addr=192.135.11.35
10/23/19 18:16:15 (D_SECURITY) SECMAN: successfu
10/23/19 18:16:15 (D_SECURITY) SECMAN: startComm
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: Subsystem
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: Permissi
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: Subsystem
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: Permissi
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: allow RE
10/23/19 18:16:15 (D_SECURITY) ipverify: READ opt
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: Subsystem
10/23/19 18:16:15 (D_SECURITY) IPVERIFY: Permissi
```

HTCondor, dettagli

Introduzione. Il problema del calcolo

Devo elaborare dei dati con alcuni software di calcolo.

Approccio ingenuo. Uso ssh:

1. con ssh mi collego a un host remoto, copio dati necessari (**input**)
2. lancio un programma (**executable**)
3. seguo l'esecuzione
4. alla fine recupero i risultati (**output**)

Per poche esecuzioni, diverse tutte diverse può anche andar bene così.

- Se devo eseguire molte volte lo stesso task
- Se ci sono molti host disponibili (non sempre liberi)

l'approccio ingenuo diventa presto impraticabile

Serve un tool che esegua i passaggi 1, ..., 4 al nostro posto

Alcuni dettagli “impliciti”:

1. Quale host? È libero?
2. È adatto per quel che devo fare? C'è il necessario per eseguire il mio task?
3. E se qualcosa va storto? Chi preme CTRL-C ? E quando?

Intuizione. Servono:

- un “linguaggio” per descrivere il task
- un “intermediario” che riceve la richiesta
- la accoda con eventuali altre
- la serve “quando possibile” → (conosce lo stato degli host disponibili)

Un tool siffatto si chiama “Batch System”

HTCondor è un batch system

- Gestisce ed esegue lavori (**Job**) al nostro posto.
- Li schedula sequenzialmente (per non sovraccaricare) su un singolo computer
- oppure su gruppi di computer (**pool**, in gergo HTCondor) anche non direttamente accessibili all'utente
- Gestisce task sottomessi da più utenti, da un host detto **Submit Node**
- Interpreta files di testo che descrivono i task (**submit files**)

Submit file

1.	<code>executable = my_program</code> <code>arguments = inp1.dat inp2.dat result.out</code>	Eseguibile e argomenti
2.	<code>should_transfer_files = YES</code> <code>transfer_input_files = us.dat, wi.dat</code> <code>when_to_transfer_output = ON_EXIT</code>	trasferimento IN e OUT
3.	<code>log = job.log</code> <code>output = job.out</code> <code>error = job.err</code>	log, stdout, stderr
4.	<code>request_cpus = 1</code> <code>request_memory = 20MB</code> <code>request_disk = 20MB</code>	Resource requests
5.	<code>queue 5</code>	istanzia 5 copie

Sottomettere job, vederne lo stato e lo storico

Da un Submit Node (anche detto `schedd`)

```
[sdalpra@sn-01 p308]$ condor_submit p308.sub
```

```
Submitting job(s)...
```

```
5 job(s) submitted to cluster 142390.
```

```
[sdalpra@sn-01 p308]$ condor_q
```

```
-- Schedd: sn-01: <...:9618?... @ 11/24/19 21:56:28
```

OWNER	BATCH	NAME	SUBMITTED	DONE	RUN	IDLE	TOTAL	JOB_IDS
sdalpra	ID: 142390	11/24 21:56			5		5	142390.0-4

```
[sdalpra@sn-01 ~]$ condor_history 142389.
```

ID	OWNER	SUBMITTED	RUN_TIME	ST	COMPLETED	CMD
142390.5	sdalpra	11/24 21:45	0+00:00:02 C	11/24 21:46	htcp308 0 0 1 1	

Note nel submit file c'è **queue 5**. Il submit risponde con il ClusterId. (142390)

Nota2 Avremo cinque JobId = ClusterId.ProcId, ProcId=0,...,4.

Richiesta risorse

- È importante indicare risorse adeguate per il job.
- specificando limiti troppo bassi il job può essere fermato da HTCondor (HELD)
- Con limiti troppo alti è più difficile trovare host adeguati

Submit multiplo

```
executable = my_program
arguments = file$(ProcId).in file$(ProcId).out

log = job_$(ClusterId)_$(ProcId).log
output = job_$(ClusterId)_$(ProcId).out
error = job_$(ClusterId)_$(ProcId).err

queue 5
```

Usando `$(ClusterId)`, `$(ProcId)` si assegnano valori unici per i singoli job

Altri esempi

vedere file `submit_tutorial.txt`

ClassAd

HTC mantiene un elenco di informazioni **Key = Value** di stato per ogni Job e per ogni Nodo, dette **ClassAd** (condor_q -l <ClusterId> per vedere quelle di un job)

```
executable = compare_states
arguments = wi.dat us.dat wi.dat.out

should_transfer_files = YES
transfer_input_files = us.dat, wi.dat
when_to_transfer_output = ON_EXIT

log = job.log
output = job.out
error = job.err

request_cpus = 1
request_disk = 20MB
request_memory = 20MB

queue 1
```

+

HTCondor configuration*

=

```
RequestCpus = 1
Err = "job.err"
WhenToTransferOutput = "ON_EXIT"
TargetType = "Machine"
Cmd = "/home/alice/tests/htcondor_week/compare_states"
JobUniverse = 5
Iwd = "/home/alice/tests/htcondor_week"
RequestDisk = 20480
NumJobStarts = 0
WantRemoteIO = true
OnExitRemove = true
TransferInput = "us.dat,wi.dat"
MyType = "Job"
Output = "job.out"
UserLog = "/home/alice/tests/htcondor_week/job.log"
RequestMemory = 20
...
```


Host ClassAd



+

HTCondor configuration

=

```
HasFileTransfer = true
DynamicSlot = true
TotalSlotDisk = 4300218.0
TargetType = "Job"
TotalSlotMemory = 2048
Mips = 17902
Memory = 2048
UtsnameSysname = "Linux"
MAX_PREEMPT = ( 3600 * 72 )
Requirements = ( START ) &&
( IsValidCheckpointPlatform ) &&
( WithinResourceLimits )
OpSysMajorVer = 6
TotalMemory = 9889
HasGluster = true
OpSysName = "SL"
HasDocker = true
```

Il **Central Manager** ciclicamente confronta i ClassAd dei Job con quelli degli host. Quando c'è un match il job può essere gestito dal corrispondente host. Le interazioni successive avvengono tra **Submit Node** e **Worker Node**.

DAG Jobs



Esempio: Un task produce N files
Altri task lavorano sugli n files...
Un ultimo task combina gli N risultati.

DAG = Direct Acyclic Graph

Elementi:

Job Nodes, Parent, Child, Edges
Sono possibili DAG con cicli

Esempi: cfr. submit_tutorial.txt



Backup slides



Load Balancing



Priority Assessment