

CNAF: stato Tecnopolo, Pledge 2024, Esito Gare, CINECA

D. Cesini – INFN-CNAF

Resources@T1 2024-2025



ALL VO No Cloud	2024	Delta 2025-2024 (Preventivi)	2025 (preliminary)
Pledge CPU (HS06)	792000 (plan) 703000(with OF) 844000 (w/o OF)	CSN1-LHC: 127210	1022780 (no OF)
		CSN1-NoLHC: 8000	
		CSN2: 12970	
		CSN3-Alice: 22500	
		CSN3-NoLHC: 8100	
		TOTALE: 178780	
Pledge disk (TBN)	82949	CSN1-LHC: 13350	103627
		CSN1-NoLHC: 450	
		CSN2: 4066	
		CSN3-Alice: 2700	
		CSN3-NoLHC: 112	
		TOTALE: 20678	
Pledge tape (TB)	193581	CSN1-LHC: 45080	254026
		CSN1-NoLHC: 1060	
		CSN2: 5750	
		CSN3-Alice: 6990	
		CSN3-NoLHC: 65	
		TOTALE: 60445	

+ cloud e HPC da CSN2,3,5

Richieste 2025 – Cloud e HPC

[DarkSide] CPU-Cloud: 1000 HS06	10.00
[Limadou] CPU-Cloud: 200 HS06	2.00
[QUAX] CPU-Cloud: 300 HS06	3.00
[DarkSide] DISK-Cloud: 100 TB	10.00
[Limadou] DISK-Cloud: 10 TB	1.00
[Auger - DataCenter] GPU: 8640 GPU hours	6.00
[CYGNO] GPU: 2400 GPU hours	1.50
[Limadou] GPU: 2037 GPU hours	1.50
[XRO] GPU: 4320 GPU hours	3.00
[ET] HPC: 100k core*hours	0.50
[Euclid] HPC: 7M core*hours	26.00
[LSPE] HPC: 500k core*hours	2.00
[QUBIC] HPC: 200k core*hours	0.50
SPES-MED - CPU 3000HS06 (Cloud?)	30.00

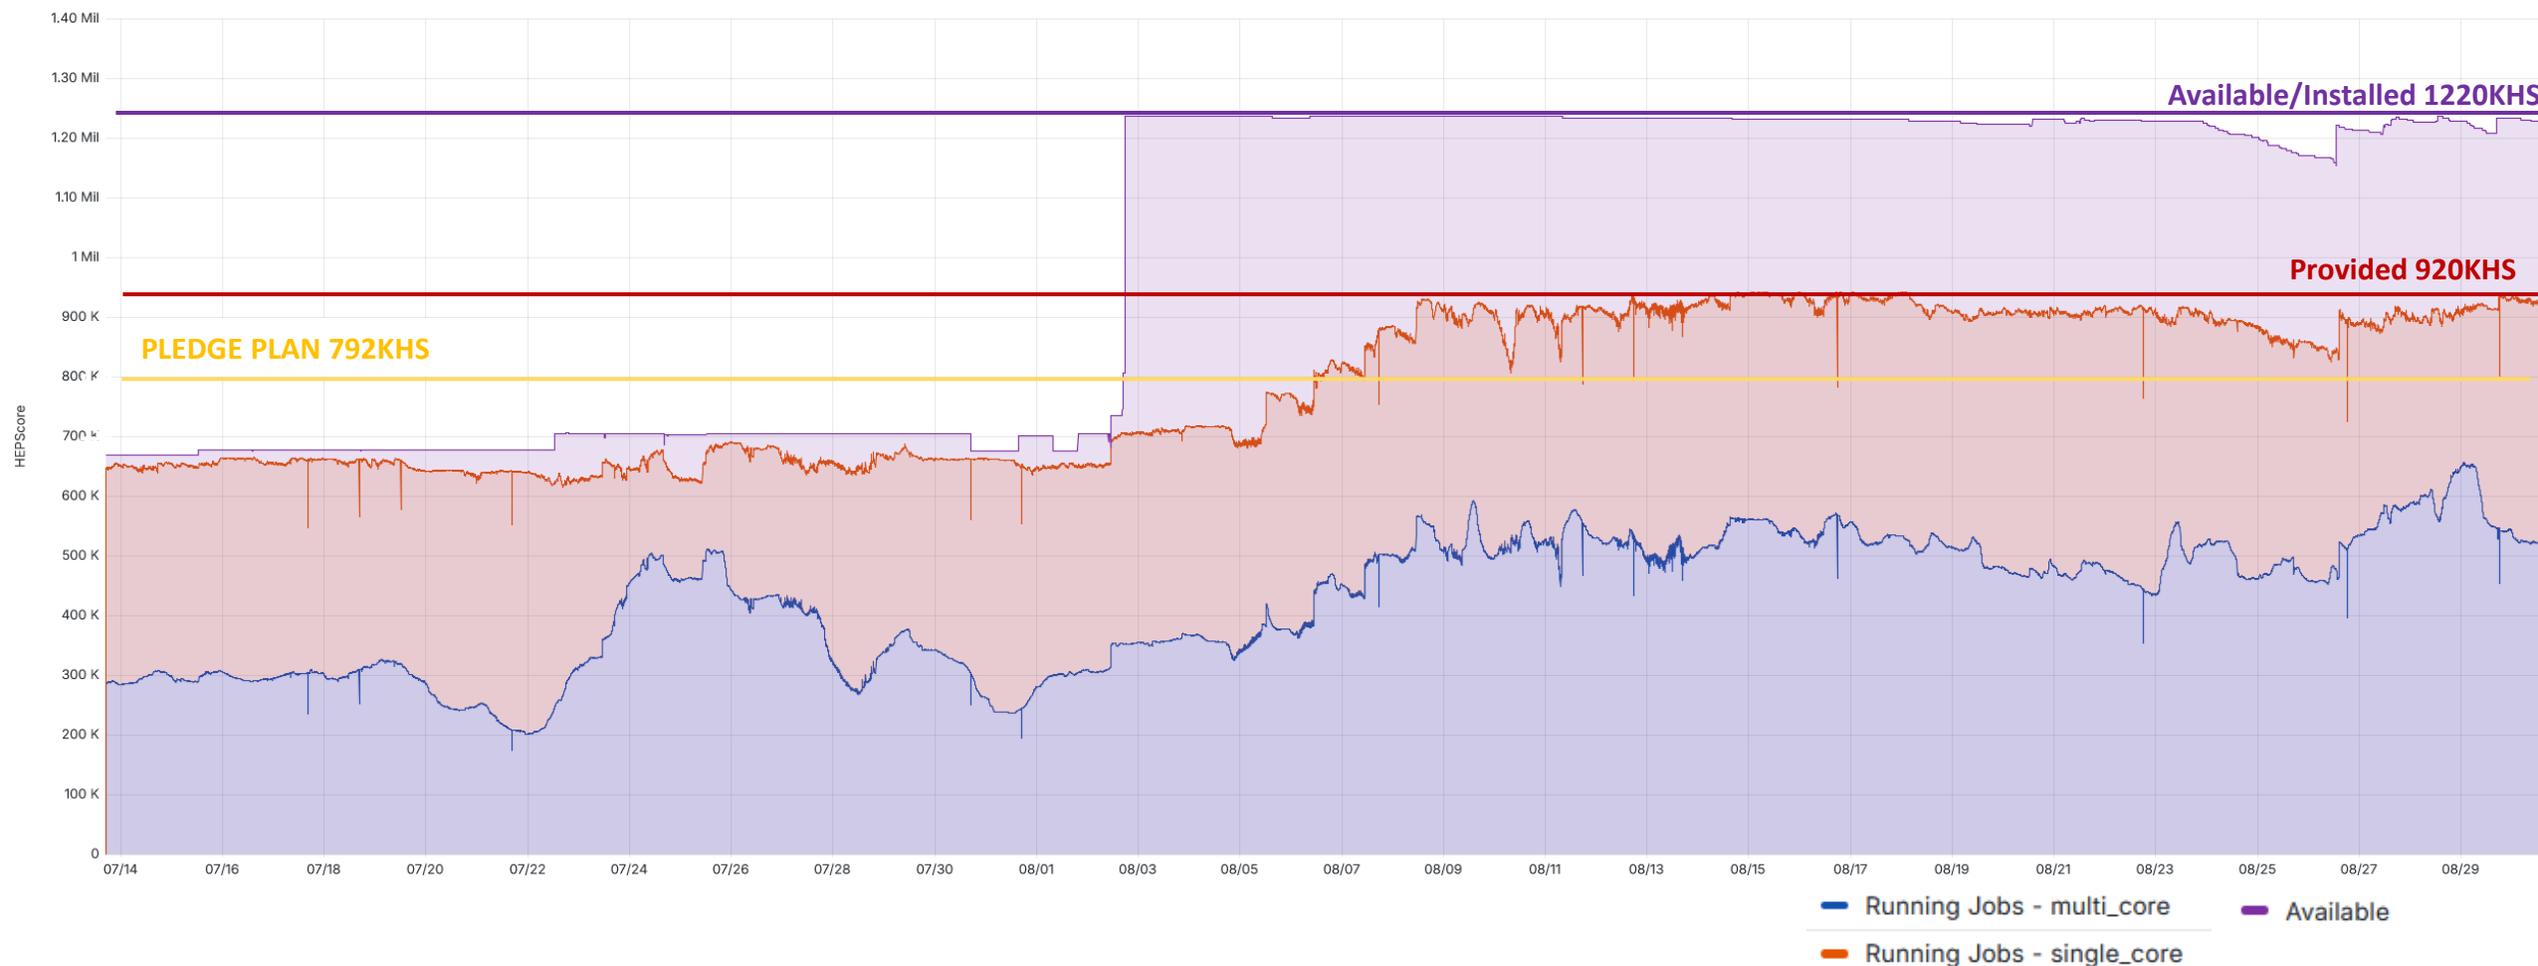
ARTEMIS - GPU: 2000 GPU-hours GPU A100 (> 32 GB di VRAM) per training modelli AI	1.50
AIM_MIA - GPU: 9000 GPU-hours suddivise su 2x GPU A100 (> 40GB di VRAM) per training modelli AI	6.50
Geant4INFN - GPU: 10000 GPU-hours tramite piattaforma AI_INFN	7.00
GEANT4INFN - CPU: 120k core-hour per simulazioni geant4_DNA richiesta una macchina con almeno 128 GB di RAM e accesso tramite coda condor su tier1	1.50
GEANT4INFN - Storage 2 TB accessibile posix da infn cloud	0.50
BRAINSTAIN - CPU: 400k core-hours	4.50
BRAINSTAIN - GPU: 10k GPU-hours	7.00
BRAINSTAIN - Storage: 8 TB	1.00
FRIDA - CPU: 1M core-hours (2GB/core) per attivita' Roma1: 200k core-hours (6GB/core) per attivita' Roma3-TIFPA	13.50
FRIDA - GPU: 1440 GPU-hours (GPU NVIDIA A100 con VRAM ~ 10 - 20 GB) per simulaz. FAST MC	1.00
SPRITZ - CPU: 125000 core-hours per simulazioni multithread (40-80 cores) con shared-memory (256-512 GB).	1.50
SPRITZ - Storage: 150 TB con protocolli di accesso standard basati su ssh	15.00
PLASMA4BEAM2 - Storage: 100 TB	10.00
PLASMA4BEAM2 - CPU: 500000 core-hours	6.00
SEGNAR - CPU: 100000 core-hours	1.00
FUSION - CPU: 240000 core-hour	3.00
FUSION - GPU: 20000 GPU-hours	14.00
FUSION - Storage: 1 TB	0.50
VITA - CPU: 1400000 core-hours	16.00
VITA - GPU: 3000 GPU-hour	2.00
VITA - Storage: 700 TB (una parte per dati sensibili)	70.00
MIRO - CPU: 1.2M core-hours [500k core-hours per simulaz. MC (Catania); 500k core-hours per simulaz. dinamica molecolare (Pisa); 200k core-hours per simulaz. MC e analitiche multiscala (TIFPA)]	13.50
MIRO - GPU: 2200 GPU-hours GPU NVIDIA A100 (> 32 GB di VRAM) per training modelli AI	1.50
SEGNAR - Storage: 10 TB	1.00

T1 CPU

CPU - Farm

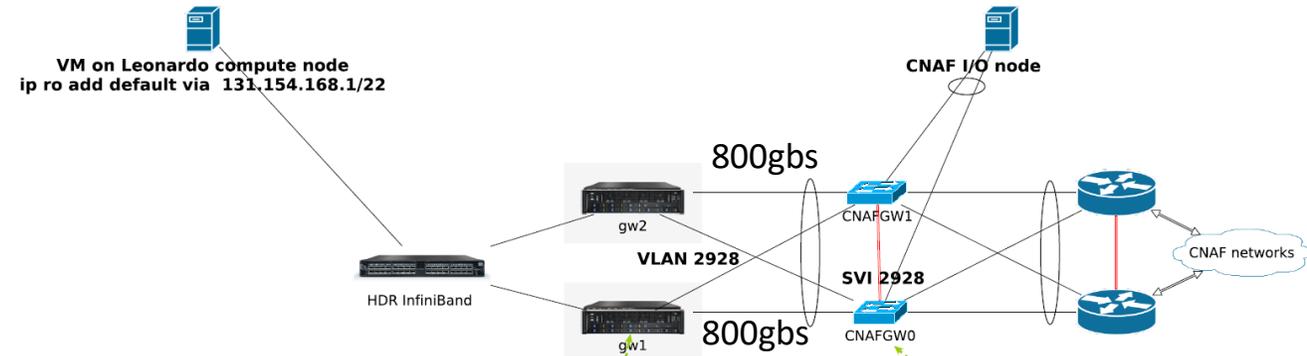
- Pledge 2024: 703kHS06 (w/o OVERLAP- 843k) → **CNAF TOTAL PLAN 792kHS06 - Potenza installata Totale: 1220KHS06**
- Da metà luglio abbiamo iniziato ad inserire i nodi Leonardo – 200 inseriti di cui 100 in draining (2880HS/nodo)
 - Per aggiungere altri nodi aspettiamo di potenziare il link da 200Gbit/s a 1600Gbit/s – in arrivo le ottiche , ordine effettuato a Luglio
- **Tutta la Farm ad HTCondor 23 – dal 20/09 partiamo con aggiornamento a Alma9+IPv6 sui WN**

HEPScore status for prod Cluster



Set-up Leonardo GP

- Strategia che abbiamo implementando:
 - WN creati tramite job SLURM “infiniti” che istanziano machine virtuali WholeNode gestite da noi
 - Immagini VM create da noi e disponibili via shared fs
 - PCI passthrough per scheda infiniband
 - IP pubblico su interfaccia infiniband
 - Accesso inbound/outbound via NVIDIA Skyway collegati direttamente a nostri apparati

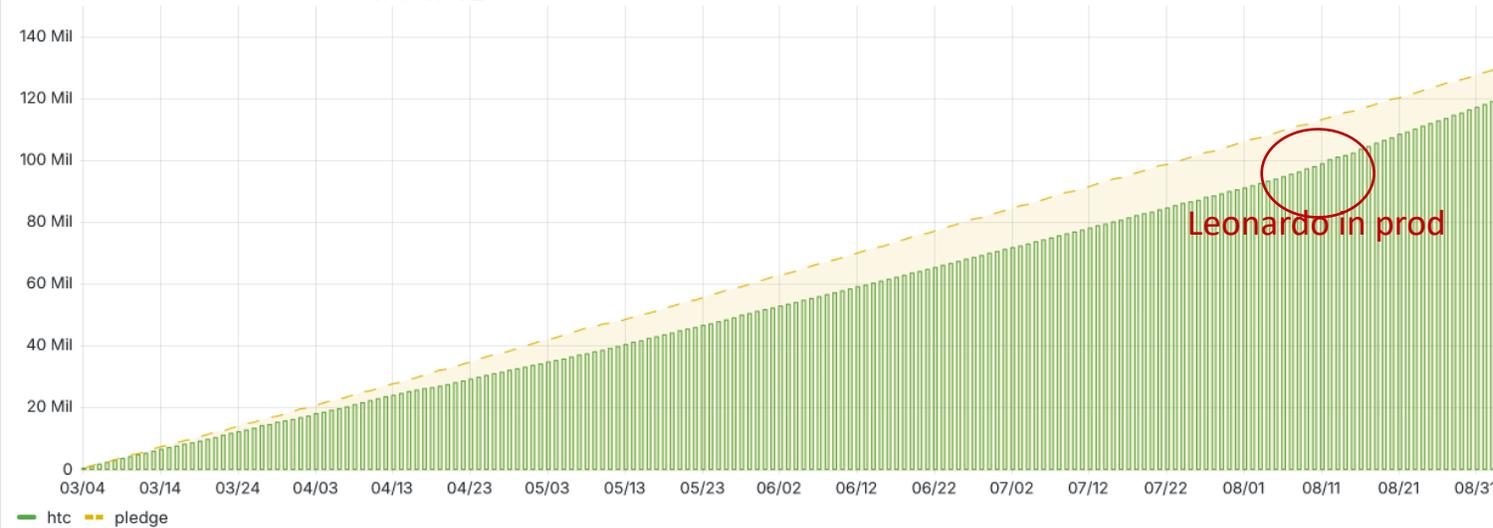


- **Come sta andando la produzione su Leonardo?**
 - Da Luglio non ci sono più stati down globali della GP, ma....
 - In media 6-7 machine al giorno si bloccano
 - Nodi random
 - Per cause sconosciute, sotto investigazione
 - Circa 1000 job/day che perdiamo senza motivo

HS06 Integrati – ultimi 6 mesi

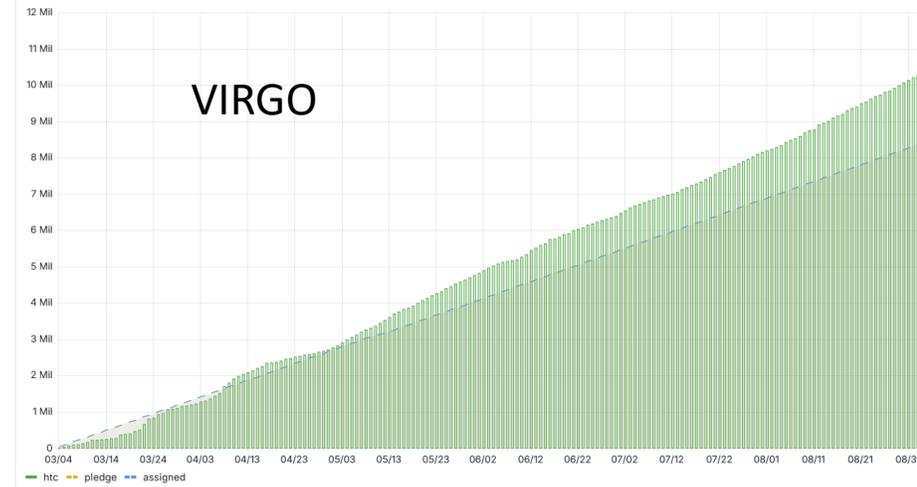
Total HS06 cumulative [HS06*day]

TOTAL

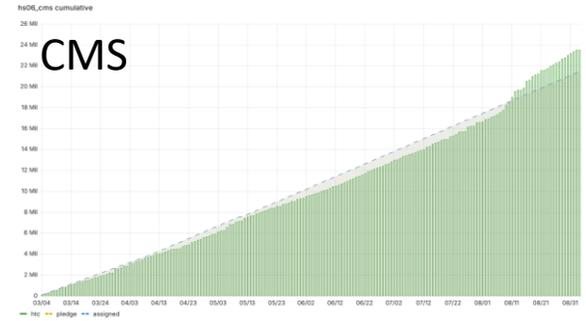


hs06_virgo cumulative

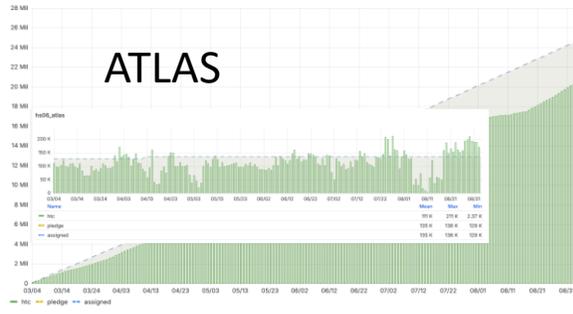
VIRGO



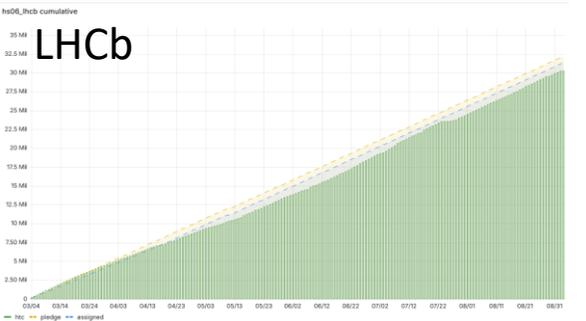
CMS



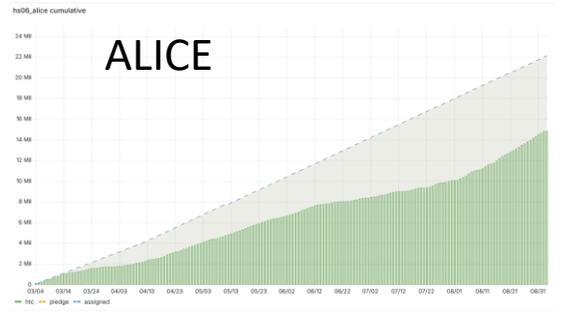
ATLAS



LHCb

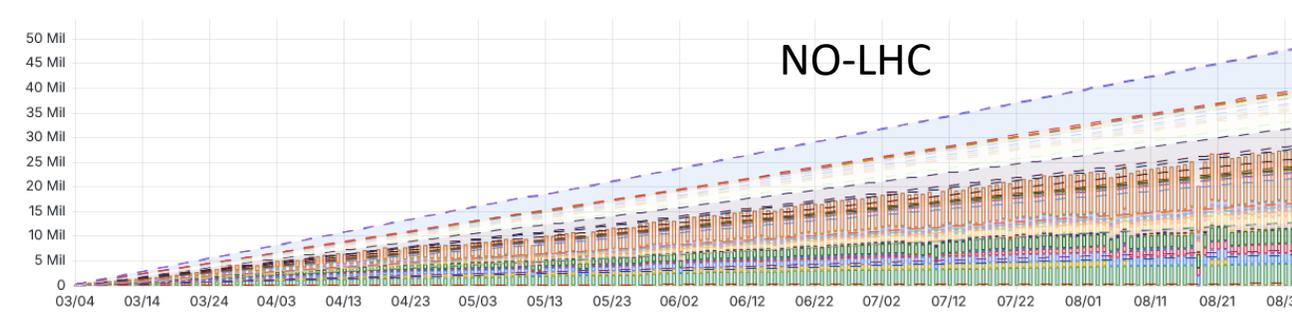


ALICE



HS06_per_group cumulative

NO-LHC

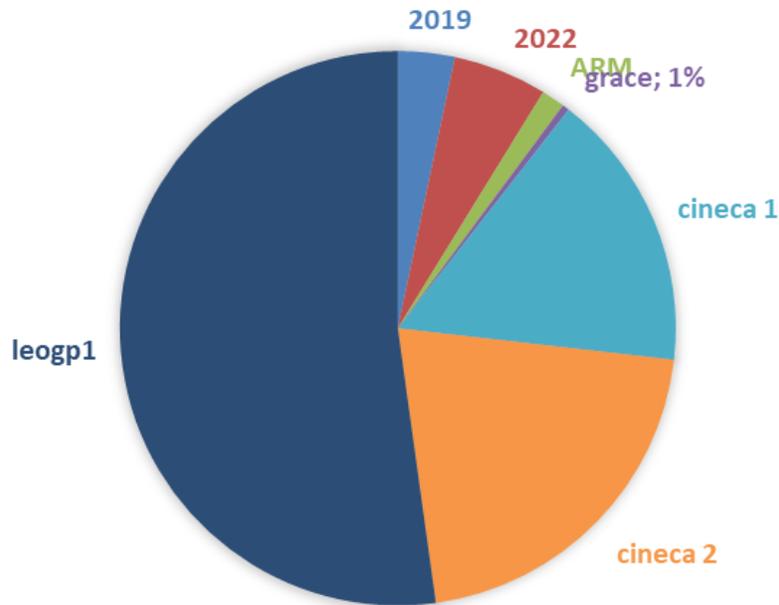


04/09/2024

CNAF: stato Tecnopolo, Pledge, Esito gare, CINECA

Composizione della farm vs Pledge 2025

FARM POWER PER TENDER



- Considerando 1.22MHS
 - Il 33% è installato a CINECA-Casalecchio
 - 411kHS
 - Il 46% è su CINECA-Leonardo
 - Il 9% va dismesso (gare 2015-2016)
 - 110 kHS
 - 12% al CNAF(TP)
 - 1% è su ARM
- Aggiunti i nodi ARM
 - Ampere (4 nodi)
 - 3754HS06/nodo
 - 3.74 hs06/W (vs 2.64 HS06/W gara2022)
 - Grace (1 nodo)
 - 4459 HS06/nodo
 - 4.67 HS06/W (vs 2.64 HS06/W gara2022)

} 79% su CINECA

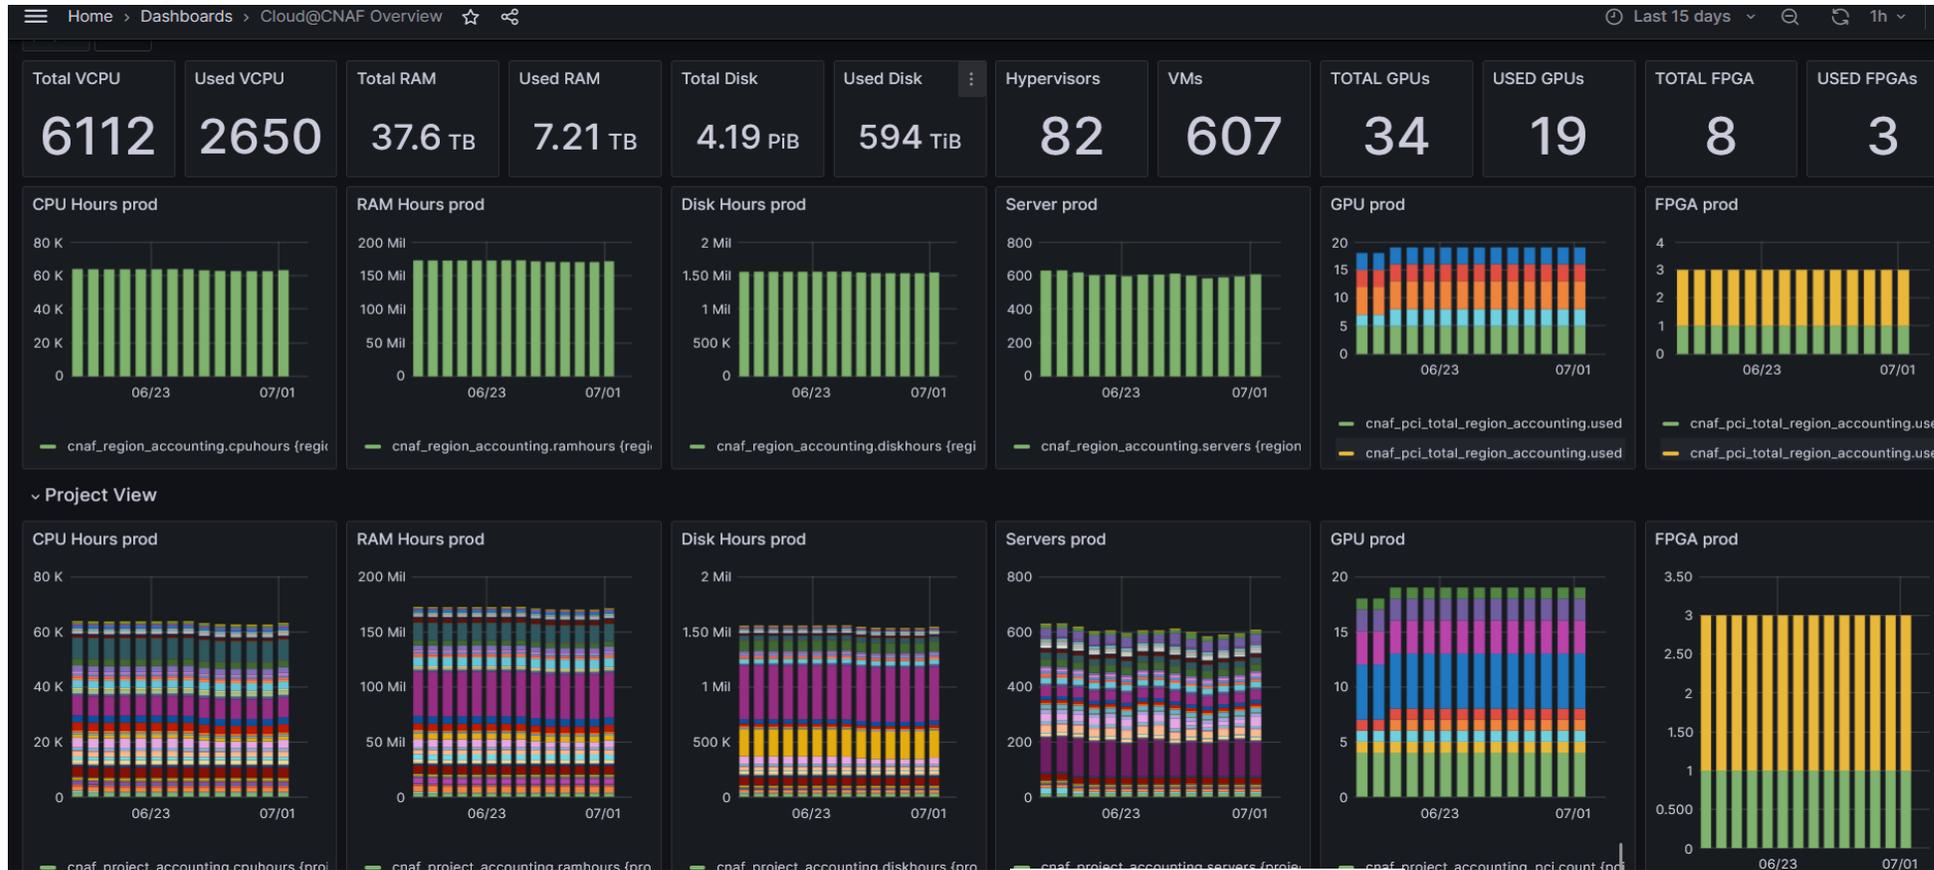
Gara 2022, 2019, 2017 portate al tecnopolo
2015 e 2016 speriamo di poterle dismettere

1220kHS – 411kHS(casalecchio) – 110kHS(dismisisoni) → 700kHS
Pledge stimato 2025 → 970kHS

Bubble CPU-Only non cosiderate

- Equivalenti a:
 - 270kHS da acquisire
 - 270KHS da non spegnere a Casalecchio (o spostare al tecnopolo)
 - altri 100 nodi Leonardo

Stato Cloud@CNAF



- Parte dei pledge «HTC» assegnati su Cloud@CNAF per accesso interattivo o piccoli cluster dedicati
 - AGATA, NTOF, etc..
- VIRGO Low Latency Cluster on K8s

- Circa 100 tenant configurati
 - Cloud@CNAF
 - INFN CLOUD
- Pledge assegnato a tutti gli esperimenti dei referaggi 2022 e 2023 con label "CLOUD"

	CPU (HS06)	Disk (TB-N)
QUAX	100	130
AMS-02	200	
HERD	1.000	100
SWG0	40	
Fermi	1.100	
AUGER	80	
Cygn0	160	10
Totale	2.680	240

	Crescita netta	
	CPU (HS06)	Disk (TB-N)
Cygn0	2.800	125
Darkside	200	100
NEWS	50	10
QUAX	400	130
Totale	3.450	365
Totale effettivo	2.760	365



Il totale effettivo con OF per ora non implementato

T1 DISK and TAPE

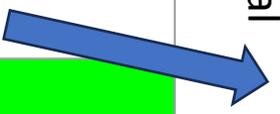
Disk storage in produzione

Installed: 113PB-33 da dismettere=80PB, Pledge 2024: 82.1 PB, Used: 61.7 PB

	Storage system	Model	Net capacity, TB	Experiment	End of support
2015	ddn-10, ddn-11	DDN SFA12k	10120	ALICE, AMS	12/2022
	os6k8	Huawei OS6800v3	3400	GR2, Virgo	07/2024
2016	md-1,md-2,md-3,md-4	Dell MD3860f	2308	DS, Virgo, Archive	12/2024
	md-5, md-6 e md-7	Dell MD3820f	50	metadati, home, SW	11/2023 e 12/2024
2017	os18k1, os18k2	Huawei OS18000v5	7800	LHCb	7/2024
2018	os18k3, os18k5, os18k5	Huawei OS18000v5	11700	CMS	6/2024
	ddn-12, ddn-13	DDN SFA 7990	5840	GR2,GR3	2025
	ddn-14, ddn-15	DDN SFA 2000NV	24	metadati	2025
	os5k8-1,os5k8-2	Huawei OS5800v5	8999	ATLAS	2027
	Cluster CEPH	12xSupermicro SS6029	3400	ALICE, cloud, etc.	2027
	od1k6-1,2,3,4,5,6	Huawei OD1600	60000	ALICE,ATLAS,LHCb, CMS	2031

Da Rimpiazzare con AQ 23-24

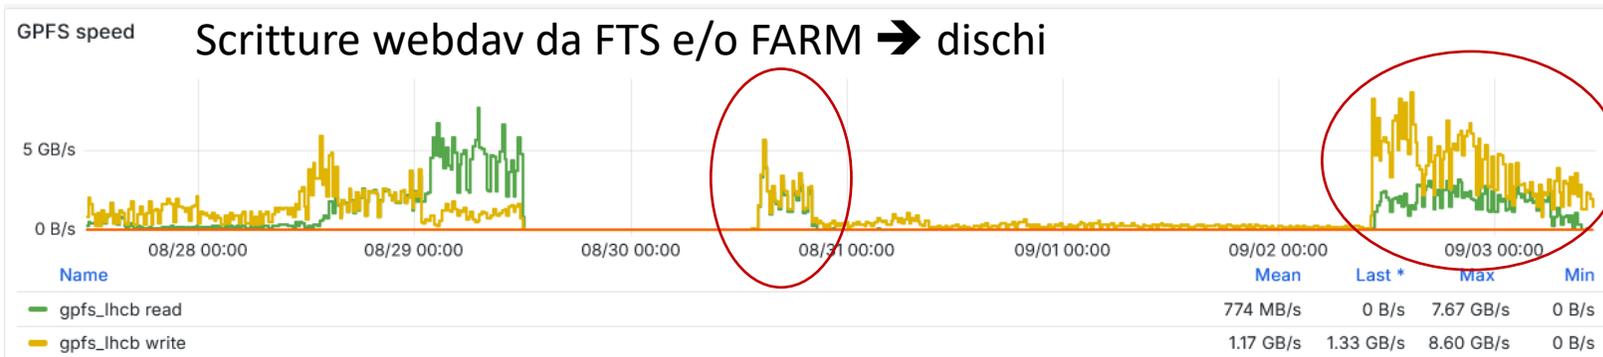
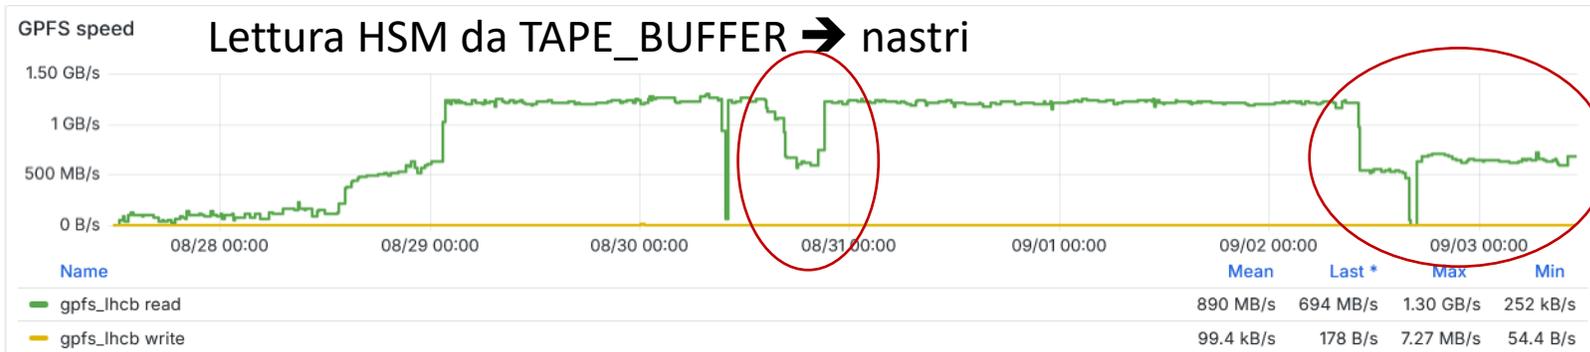
Da spostare al Tecnopolo



Svuotato e riportato su GPFS

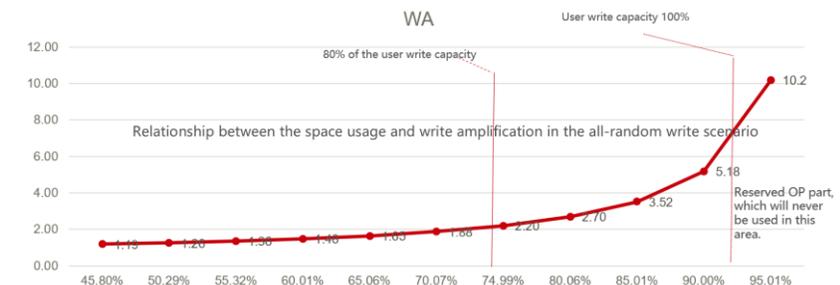
Mancano 14PB da Pledge Storage 2022 – bloccati nella relativa Gara → In arrivo entro Settembre AQ 2023-2024 - fondi per secondo AS in arrivo a Settembre (ICSC) 16PB + eventuale 6/5 16PB

Problemi performance nuovo Storage Huawei



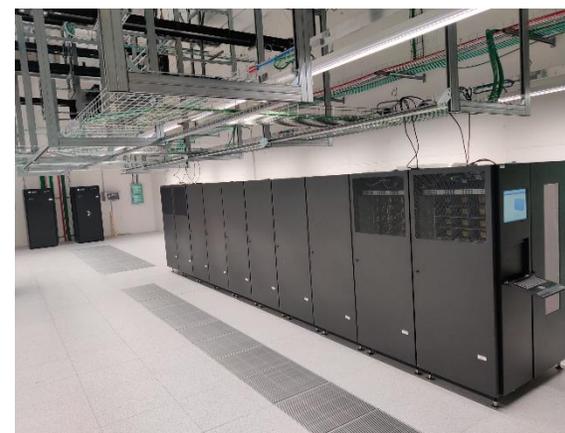
- Analisi in corso con vendor (HUAWEI)
- Soluzioni alternative in fase di valutazione se HUAWEI non risolve:
 - Spostare il buffer su sistemi NVMe
 - Ma troppi piccoli per le necessità di LHCB (2 settimane di dati)
 - Riutilizzare i vecchi sistemi HUAWEI estendendo la manutenzione
 - Almeno per parte delle necessità di LHCB (buffer_tape?)
 - Utilizzare i sistemi DDN/Lenovo che stanno per arrivare (metà-fine Settembre)

- Calo drastico delle performance del sistema che ospita il TAPE_BUFFER
 - Quando il buffer è quasi pieno
 - Quando ci sono scritture concorrenti sul disco da FTS e/o Farm via StoRM-WebDAV
- Storm-WebDAV va in crisi per alto numero di thread concorrenti
- Innesca effetto valanga

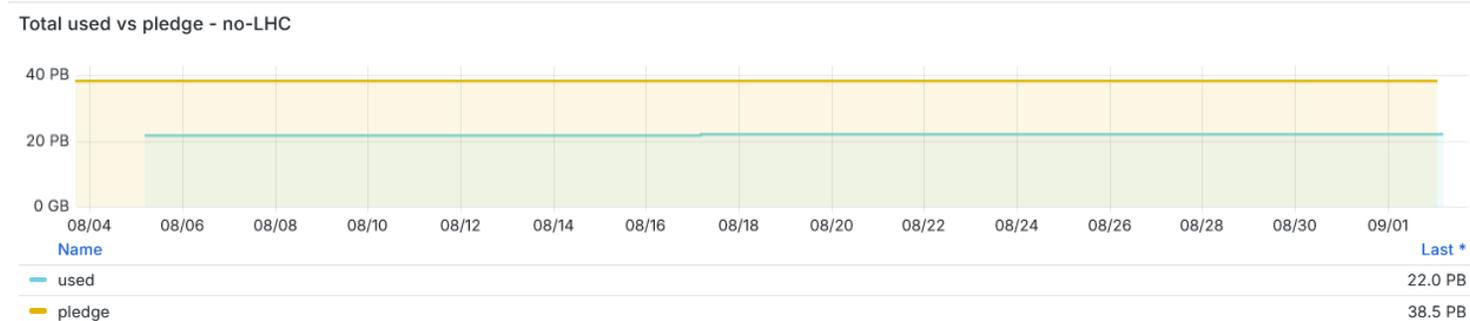
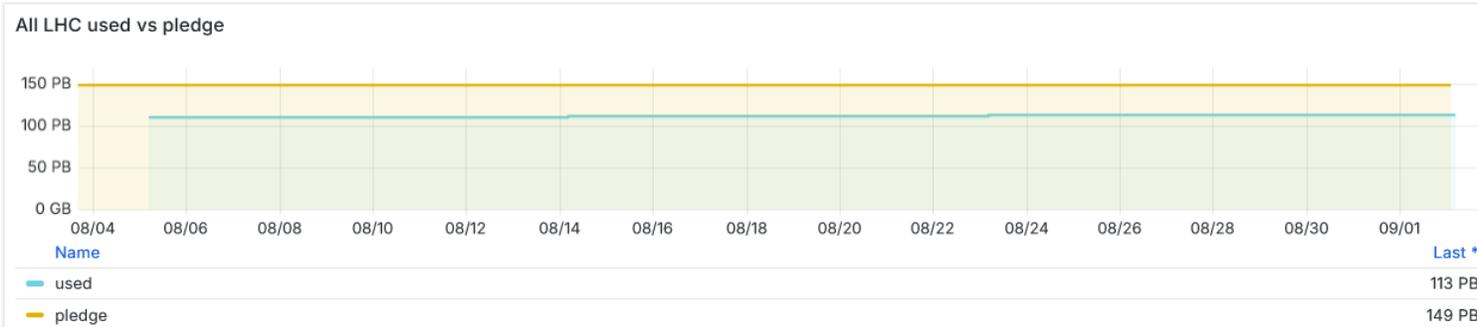
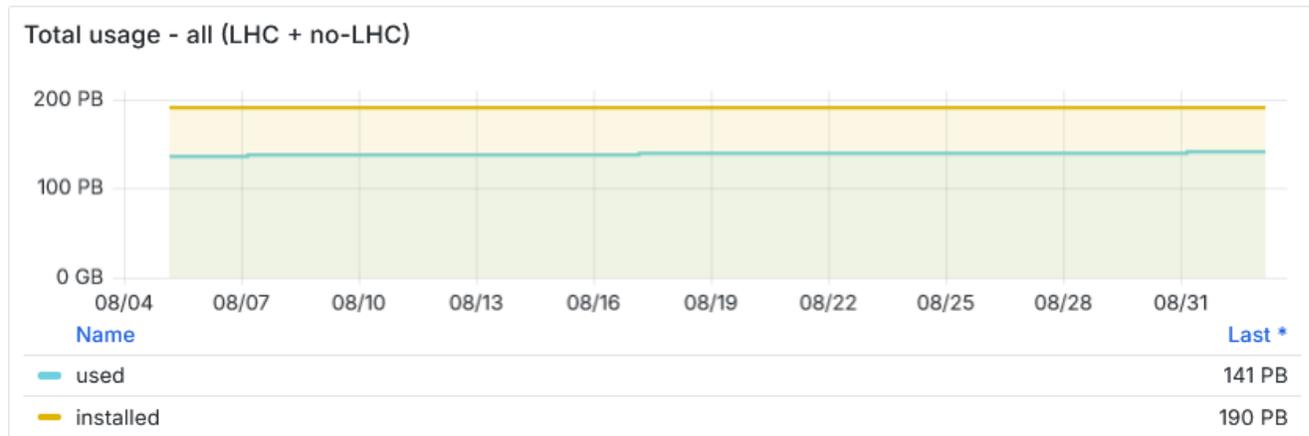


Acquisti storage recenti e futuri

- Gara storage 2022 (14PB netti)
 - Nuova proposta con apparati DDN SFA7990X
 - In attesa per la consegna **entro fine Settembre**
- AQ storage 2023-2024 (Terabit+ICSC)
 - Huawei OceanStore Micro 1500/1600
 - 8 sistemi di 10PB + 40 server
 - Installazione e collaudo del primo AS 64PB effettuato
 - 60PB in prod
 - In produzione da fine Luglio
 - **Secondo AS da 16 PB a Settembre/Ottobre??**
 - **6/5?? occorre decidere se acquistarlo su ICSC**
- Tape Library (ICSC)
 - Nuova libreria Installata
 - Da completare collaudo e messa in produzione
- Gare nastri (ICSC)
 - Acquistati 14PB (JE e JF)
 - **URGENTE: Nuova gara di acquisto tape JF da 96PB**
 - Spedita in AC a inizio Luglio
 - In attesa del bando
 - Fondi ICSC arrivati – RDA inserita
 - Pledge+Overpledge+ICSC+Repack (2024) vecchia Oracle da dismettere

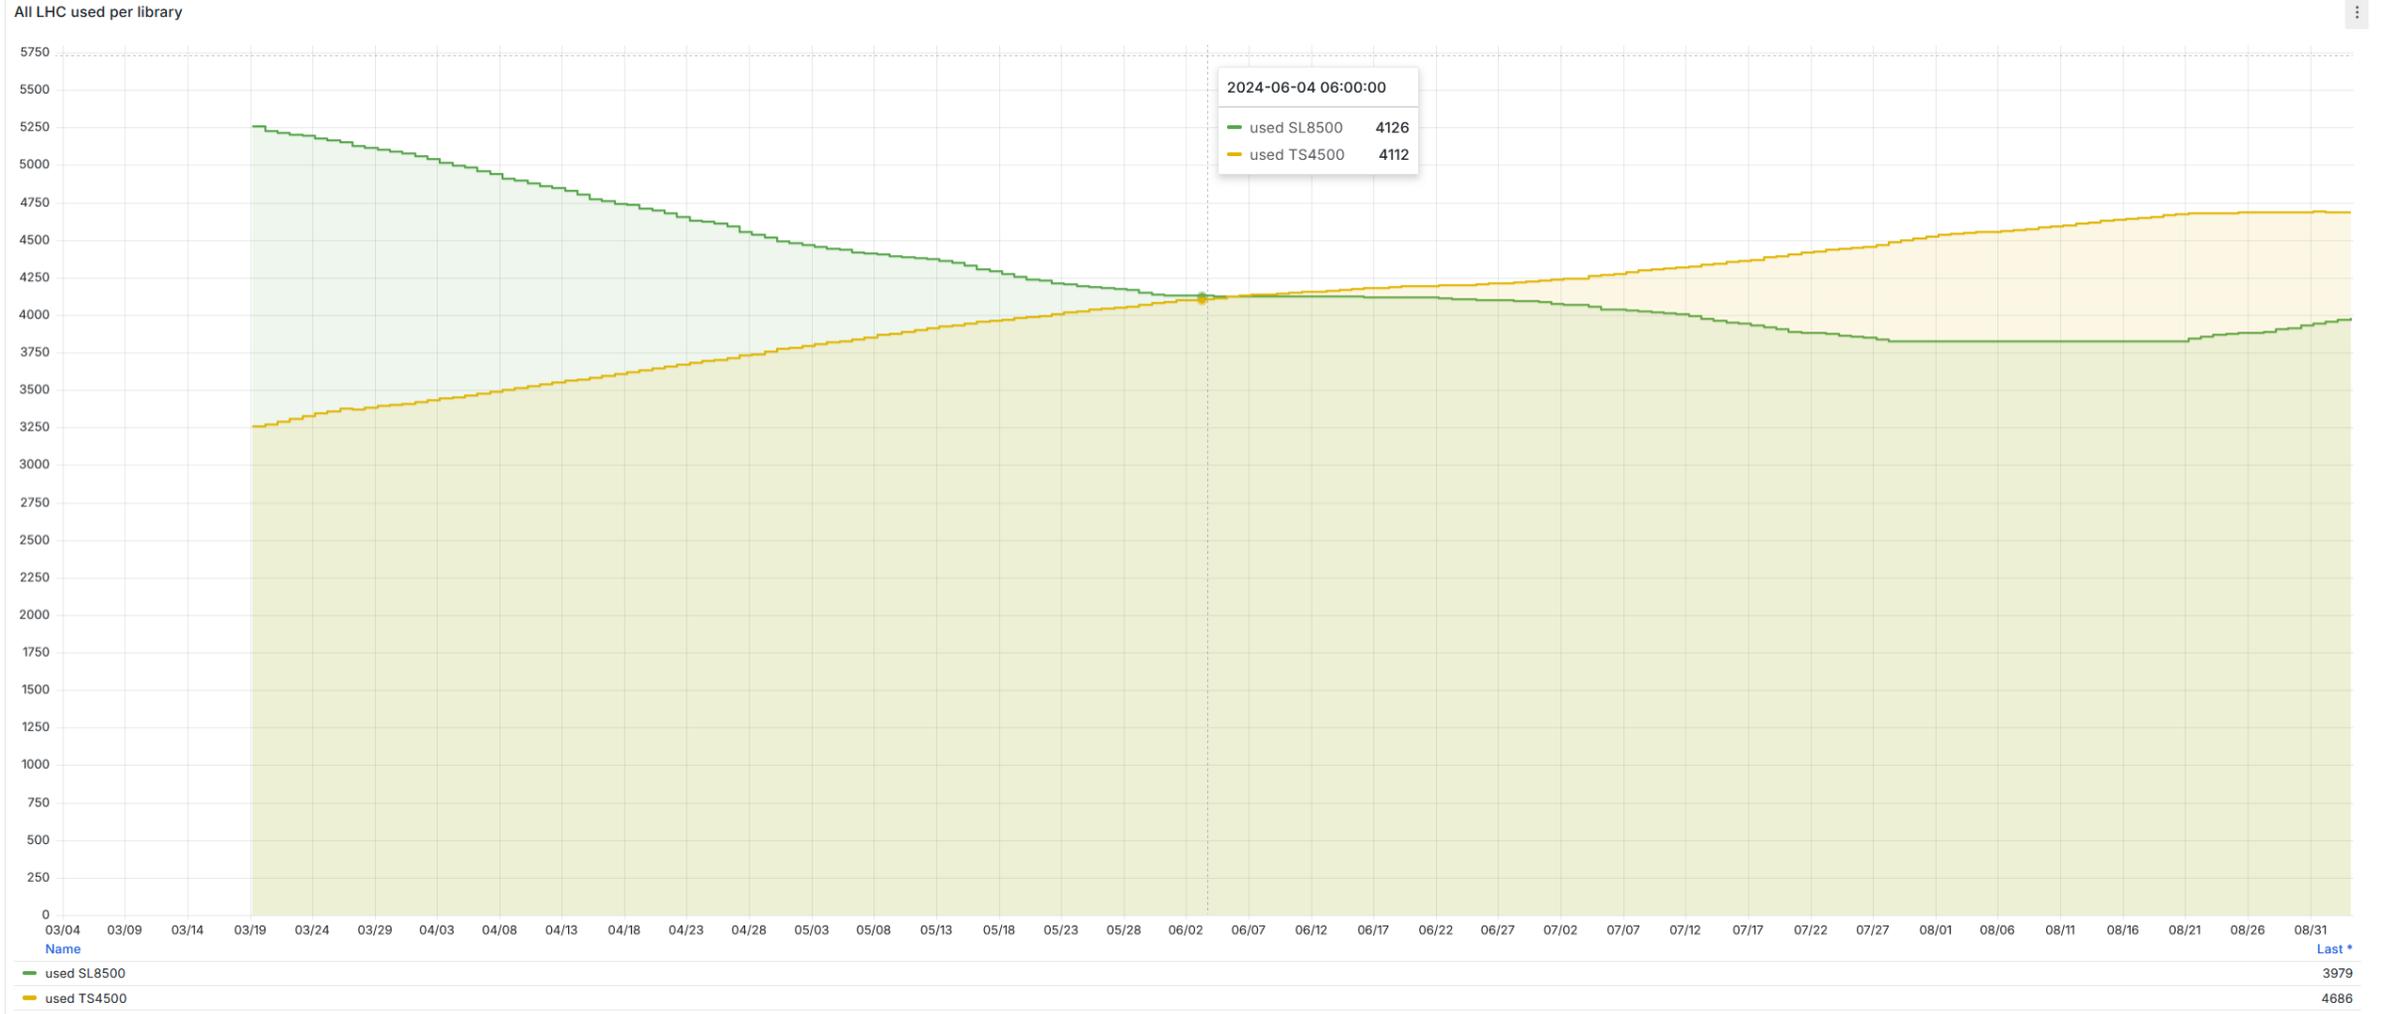


Stato Tape

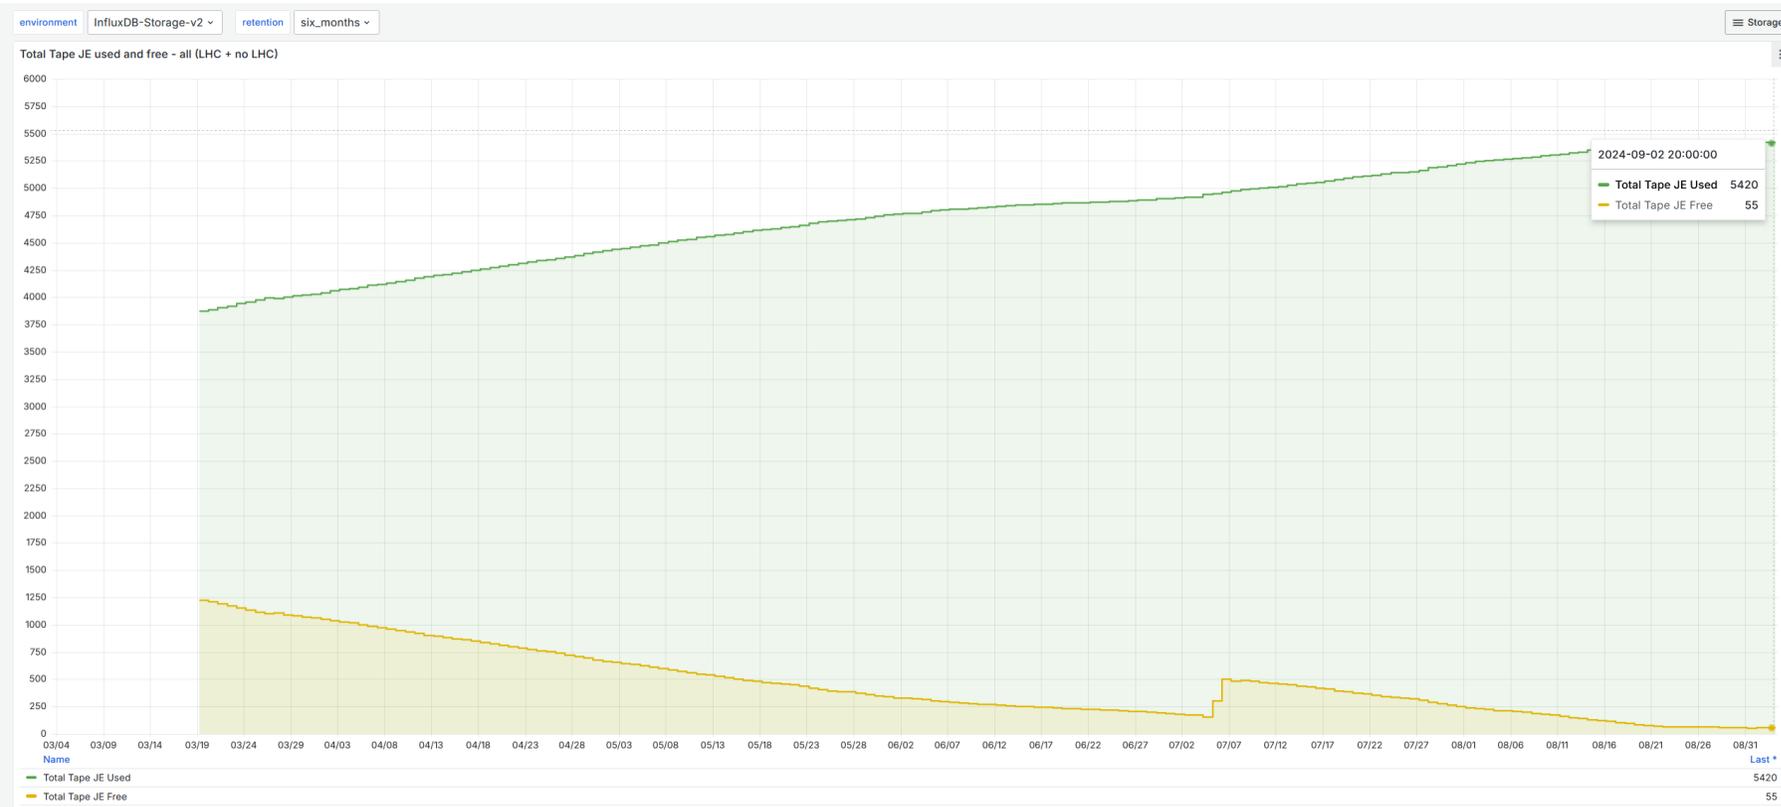


- Pledge 2024: 190PB
- Usato: 141PB
- Nuova Libreria già installata direttamente al Tecnopolo, non ancora in produzione → 8PB liberi
- Repack vecchia Oracle bloccato per risparmiare nastri
- Oracle di nuovo in produzione

Uso nastri per libreria



Cassette libere



- Pledge 2024: 190PB
- Usato: 141PB
- 8PB Liberi nella nuova Libreria
- 55 cassette da 20TB nella vecchia IBM in produzione
- + 8PB su nuova libreria
- **DIFFICILEMENTE ARRIVEREMO ALLA CONCLUSIONE DELLA PROCEDURA DA 96PB senza usare la Oracle**

Stato trasferimento al Tecnopolo

- Da spostare sistemi storage “svuotati” (Ottobre 2024)
 - TD in corso
- Da svuotare un sistema storage (5 PB, 1 rack – DDN12-13)
 - Serve sistema vuoto al Tecnopolo (Novembre 2024)
- Da rilocare 1 tape library - “vecchia IBM”
 - Spostamento entro Q4 2024 (da concordare down con esperimenti)
- Da migrare 3 rack zona certificata ISO (EPIC) + 3 rack SSNN
 - Dipendenza da rete dedicata Tecnopolo-LNL (GARR)
 - Q4 2024?
- Da spostare risorse in housing (gennaio 2025)
 - 8 rack di INGV 3 rack DiFA di UNIBO
 - 3 rack Sezione INFN-BO
 - 3 rack servizi GARR



Gara "HPC Bubbles"

- **Accordo Quadro Nazionale**
 - Listino prezzi per nodi + accessori
 - 2 anni di validità
 - Lotto1
 - CPU, GPU, FPGA
 - Lotto2
 - Storage
 - Sedi Coinvolte: CNAF, BARI, MI-BI, PI, TO, LNGS, NA, RM1, PD/LNL
- **Stato gara**
 - **Ordini inviati a parte 6/5**
 - **MI e LNL anticipati su capienza ordinaria**
 - **HW arrivato**
 - **CNAF**
 - **HW installato**
 - **PD, Torino**
 - **Mancano su 6/5**
 - **CT L1+L2, LNFESA L2, ROMA1 L1, NA L2**

Quantità nodi con fondi Terabit-ICSC-DARE

	Nodo CPU	Nodo GPU	Nodo FPGA Xilinx	Nodo FPGA Terasic	Nodo storage
BA	24 *	6	0	0	32 *
CNAF	26 *	30 *	2	2	52 *
MIB	0	0	2	2	0
NA	18	1	2	0	8
PD	6	6	0	0	0
PI	20	0	0	0	0
RM1	12	0	0	0	0
TO	14	6	0	0	0
LNGS	0	6	0	0	12
CT	12	0	0	0	8
LNF	12	0	0	0	0
LNFESA	8	6	0	0	6
LNL	4	0	0	0	0
MI	4	0	0	0	0
TOTALE	160	61	6	4	118

Core: 30 kcore fisici
Circa 34 HS/core

GPU: 244 NVIDIA H100
40 FPGA
InfiniBAnd 400Gbs

45 PB RAW

* Quantità nodi con fondi DARE – Terabit per Spoke8

	Nodo CPU	Nodo GPU	Nodo FPGA Xilinx	Nodo FPGA Terasic	Nodo storage
BA_DARE	12	6	0	0	6
BA_TerabitS8	0?	0?	0	0	0?
CNAF_DARE	10	9	0	0	16
CNAF_TerabitS8	8	8	0	0	6



HPC Bubbles



Nodo CPU

192 core fisici
1.5TB RAM DDR5
IB NDR 400G
20TBL (SSD) + dischi di sistema



Nodo GPU

Come CPU + 4x NVIDIA H100 SXM5 con minimo 80GB e memoria HBM2e



Nodo FPGA

32core
RAM 768GB DDR5
IB NDR 440G
4 x XILINX U55C o 4 x TerasicP0701



Nodo Storage (CEPH Bricks)

64 core fisici
1TB RAM DDR5
384 TBL HDD + 25.6 TBL NVMe



Accessori

Switch IB, Switch ETH
Cavi IB, Cavi ETH
Transceiver vari
Assistenza 3+2

Stato zona ISO27001 - EPIC

- Siamo in attesa della risorse HBD acquistate da ACC
 - Ritardi molti significativi – devono rifare tutta la procedura
- Il nuovo cluster virtualizzazione in fase di installazione (Pichat)
 - fondi per svecchiamento 2024 – contratto S.Orsola
- Nuovi ToR acquistati su consip (in consegna - TP)
 - Fondi HBD
- nuovi concentratori (RDA in corso- TP)
 - Fondi HBD
- Trasloco rimandato a Q4 2024
 - Dipendenza da configurazione rete
 - 10 rack già allocati e predisposti

Commenti/Richieste

- Per il 2025 sarebbe molto comodo avere le tabelle non solo dei delta ma anche del complessivo sul T1 per tutti gli esperimenti
- Anche per il 2024 I fondi referati non sono stati assegnati ad inizio anno
 - Fondi per OdF storage
 - Fondi per Nastri
- Avere il 90% delle risorse della farm HTC del T1 fuori dal T1 è sicuramente una strategia rischiosa
 - oltre che poco “gratificante”