

Attività di calcolo parallelo in LHCb PD

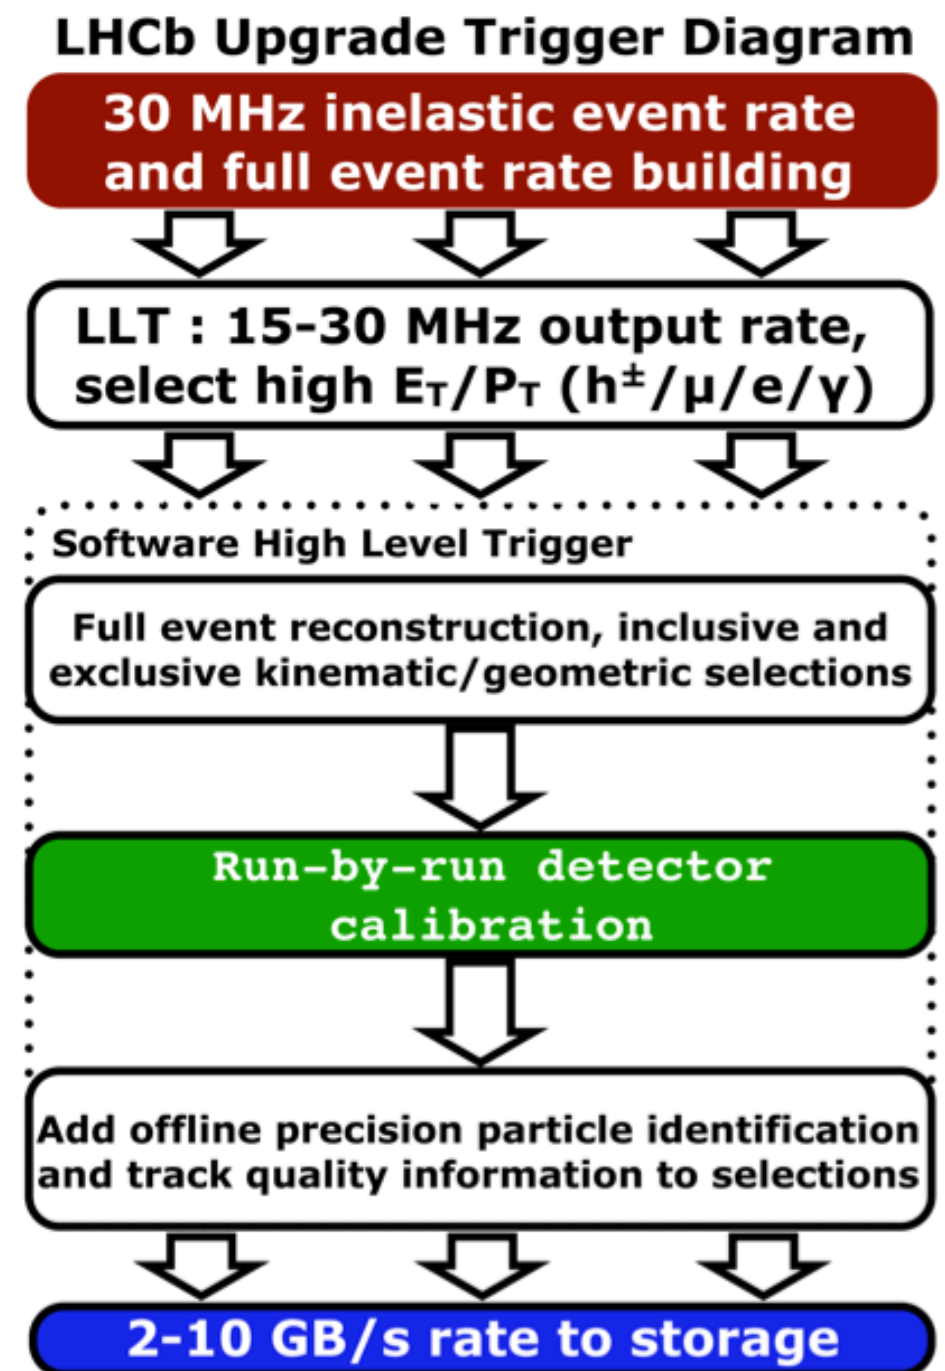
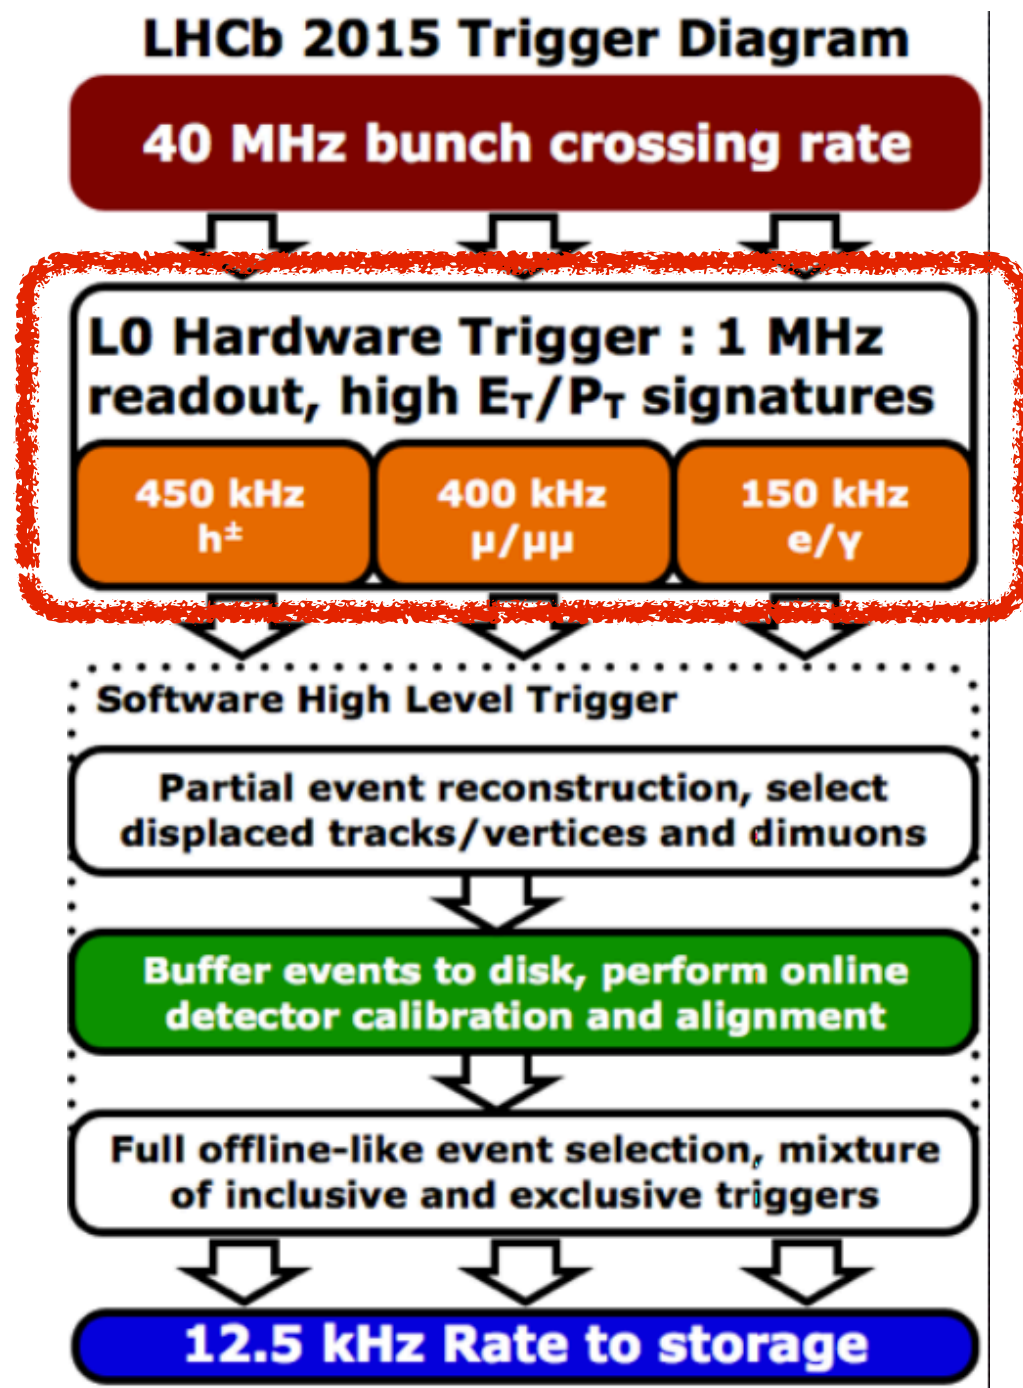
S. Gallorini, D. Lucchesi, A. Gianelle, S. Amerio, M. Corvo
Università e INFN Padova
Padova - 26/09/2016

Introduzione

- Con l'aumento di luminosità di LHC previsto per il Run3, è indispensabile un uso più efficiente delle risorse di calcolo per riuscire a processare gli eventi (sia online che offline)
- Architetture many-cores, come ad es. GPGPU, possono essere una valida alternativa alle CPU:
 - ▶ Per selezioni di trigger più raffinate e vicine all'offline
 - ▶ Per ottimizzare il rapporto costo/performance della farm di trigger
 - ▶ Per mitigare il rischio dovuto a possibili deviazioni dalla legge di Moore

Il trigger di LHCb upgrade

Full detector readout a 40MHz e full software trigger



Attività many-cores a LHCb Padova


- **Goal**

- Studiare la fattibilità dell'uso di GPU commerciali (o sistemi eterogenei, ...) nel trigger per l'upgrade di LHCb
- I Run2 fornisce un'opportunità unica per testare le performances delle GPU e la loro integrazione nel sistema online
- Per far ciò abbiamo sviluppato algoritmi di tracking su GPU per il detector attuale

- **Due algoritmi implementati:**

1. Ricostituzione delle tracce nel VELO (“FastVelo”)
2. Ricostruzione delle tracce nelle T-stations (“Automa”)

Tracking del VELO




Tracking del VELO su GPU (I)


- L'algoritmo originale per il tracking del VELO ("FastVelo") è stato adattato per sfruttare al meglio l'architettura delle GPU (GPU NVidia)
- Per fare ciò, sia la logica che le strutture dati dell'algoritmo sono state in parte modificate
- Le performances (efficienze e tempi di esecuzione) sono state confrontate con l'algoritmo originale (single/multiple CPU cores)
 - ▶ GPU: NVidia Titan (14 SMX, 192 CUDA cores/SM, 6GB di memoria)
 - ▶ CPU: **single core** (Intel i7, 3.40 GHz, nello stesso PC che ospita la GPU)

Tracking del VELO su GPU (2)

Efficienza vs P(true)




Timing performances




Performances compatibili con l'algoritmo originale (ottimizzato)

GPU testbed

- Con l'aiuto dell'online group di LHCb siamo riusciti ad installare un PC con una GPU nella monitoring farm
- Questo ci ha permesso di testare il nostro algoritmo in presa dati (seppur a rate moderato) e capire alcune problematiche legate all'integrazione GPU - online FW
- Ogni nodo dell'online farm agisce da client il quale manda l'evento al server GPU (nel nostro caso client = server e #clients = #logical cores)



Tracking delle T-stations su GPU (I)



Tracking delle T-stations su GPU (2)


- Attualmente, il tracking delle T-stations è responsabile del ~30% del tempo totale dell'HLT2 (anche nell'upgrade)
- Utilizzare il codice esistente in CPU adattandolo a sistemi many-cores è spesso molto complicato (uso estensivo di std library, AoS anzichè SoA, ...)
- Per il tracking delle T-stations abbiamo deciso di riscrivere l'algoritmo da zero, in modo da avere un codice il più possibile “embrassingly parallel”
- L'approccio è ispirato all'Automa Cellulare

Automata

- Efficienze di tracking abbastanza simili all'algo. ufficiale di tracking
- Algoritmo già riscritto su GPU
- La maggior parte del tempo è speso per fittare le tracce!

Automata (1000 evts)		Clones	Hit purity	Hit eff
all long	69.5%	0.1%	96.3%	86.9%
long, $p > 5$ GeV	63.1%	0.0%	96.1%	88.9%
all long, B daughters	73.4%	0.1%	96.6%	88.7%
long B daughters, $p > 5$ GeV	71.0%	0.0%	96.6%	89.8%
all long K_S/Λ	74.6%	0.0%	96.4%	85.0%
Ghosts	34.1%			

PatSeeding (1000 evts, $v=1.6$,		Clones	Hit purity	Hit eff
all long	73.9%	0.0%	95.1%	94.1%
long, $p > 5$ GeV	66.9%	0.0%	94.9%	95.4%
all long, B daughters	78.1%	0.0%	95.6%	95.5%
long B daughters, $p > 5$ GeV	75.6%	0.0%	95.5%	96.1%
all long K_S/Λ	78.0%	0.0%	95.1%	92.7%
Ghosts	22.9%			




Conclusioni

- In conclusione, GPU e altri acceleratori possono fornire un valida alternativa alle CPU (anche in termini economici) in applicazioni real-time come il trigger
- Ottenere speedups molto elevati mantenendo le **stesse performances** fisiche è però tutt'altro che banale
 - ▶ Comunque il metro di giudizio è il throughput/costo HW!
- Il Run2 fornisce un'opportunità unica per testare le performances delle GPU e la loro integrazione nel sistema online
- Altri algoritmi, ad es. la ricostruzione del RICH, sono buoni candidati per architetture parallele e verranno esplorati in futuro

Back-up slides


Integrazione nel FW (I)

- Un aspetto critico per l'utilizzo di acceleratori è l'integrazione con il framework software del trigger ("Gaudi")
- In LHCb stiamo sviluppando un sistema di "offloading" usando un sistema client-server ("GPUManager")



Integrazione nel FW (2)

- Ogni nodo dell'online farm agisce da client il quale manda l'evento al server GPU (es. le hits di un rivelatore)
- Il server riceve gli eventi e le accumula in un buffer
- Il bunch di eventi viene processato in GPU e il risultato rispedito a ciascun client



Integrazione nel FW (3)

Esempio di utilizzo:

I dati input/output devono essere convertiti in SoA dal client:



```
// compute total size and allocate memory
uint8_t * dst = (uint8_t *)&buffer[0];
const size_t noSensorsSize      = sizeof(int);
const size_t noHitsSize        = sizeof(int);
const size_t sensorZsSize       = m_event.sensorZs.size() * sizeof(int);
const size_t sensorHitStartsSize = m_event.sensorHitStarts.size() * sizeof(int);
const size_t sensorHitsNumsSize  = m_event.sensorHitsNums.size() * sizeof(int);
const size_t hitIDsSize         = m_event.hitIDs.size() * sizeof(int);
const size_t hitXsSize          = m_event.hitXs.size() * sizeof(float);
const size_t hitYsSize          = m_event.hitYs.size() * sizeof(float);
const size_t hitZsSize          = m_event.hitZs.size() * sizeof(float);

// serialize container contents
dst = copy(m_event.sensorZs,      dst);
dst = copy(m_event.sensorHitStarts, dst);
dst = copy(m_event.sensorHitsNums, dst);
dst = copy(m_event.hitIDs,        dst);
dst = copy(m_event.hitXs,         dst);
dst = copy(m_event.hitYs,         dst);
dst = copy(m_event.hitZs,         dst);
```

Il client puo' quindi sottomettere i dati al server specificando il kernel:

```
gpuService->submitData("PrPixelCudaHandler", &m_serializedEvent[0], m_serializedEvent.size());
```

Tracking del VELO su GPU (3)



- ▶ Il VELO è un detector a strips di silicio, situato vicino alla regione di interazione
- ▶ R- ϕ layout, 21 stazioni, ognuna con 2 sensori R e 2 sensori ϕ


Tracking del VELO su GPU (4)

- La ricostruzione delle tracce nel VELO è suddivisa in due parti:
 1. **RZ tracking:** ricerca di tracce nel piano R-Z (solo sensori R)
 2. **Space tracking:** le tracce spaziali sono ricostruite a partire dalle tracce in RZ aggiungendo l'informazione delle hits nei sensori ϕ
- **Strategia di parallelizzazione:**
 1. Processare più eventi in parallelo (ovvio)
 2. Ricerca in parallelo delle tracce RZ (seeding + track following)
 3. Space tracking in parallelo per ogni traccia RZ (più dettagli in backup)

Tracking del VELO su GPU (5)

- **RZ tracking:**

- Only R-sensors are used
- The algorithm looks for quadruplets of hits in four contiguous R-sensors (seed) on both halves.
 - Each thread works on a set of four contiguous R-sensors and find all quadruplets.
- Then each quadruplet is extended in parallel as much as possible adding the remaining R-sensors



Tracking del VELO su GPU (5)


- **Space tracking:**

- Add hits on ϕ -sensors
- Each RZ track is processed concurrently by assigning a space-tracking algorithm to each thread:
 - Search for a triplet of hits: for each hit in the first two ϕ -sensors, the candidate hit in the third sensor is the one most compatible with predicted position (best χ^2)
 - The track is extended and its parameters are found by minimizing $\sum_{\text{points}} \chi^2$ (linear system solved by substitution)
 - This part is almost a re-writing in CUDA of the original space-tracking code


Tracking delle T-stations

- L'Automa Cellulare (AC) procede in 3 passi:
 - ▶ Generazione di tutti i segmenti tra layers adiacenti ("le cellule"). Ogni segmento possiede un contatore ("stato della cellula") inizialmente inizializzato a zero
 - ▶ Ricerca dei segmenti vicini (segmenti adiacenti compatibili con il modello di propagazione della traccia)
 - ▶ Evoluzione (in step temporali). Il contatore ($c1$) di ogni segmento è incrementato di $+1$ se uno dei suoi vicini ha il contatore $c2 \geq c1$


Step1



Step2



Step3



Step4

