

Databehandling af LHC-data med GRID

Af Frederik Orellana, Niels Bohr Institutet, Københavns Universitet.

Behandlingen af data fra LHC kræver et verdensomspændende netværk af computere. I denne artikel gennemgås nogle af udfordringerne ved konstruktionen og brugen af dette.

Introduktion: partikelfysik og grid

Begrebet 'grid computing' hænger uløseligt sammen med partikelfysik og i særdeleshed med "Large Hadron Collider" (LHC) ved den Europæiske Organisation for Forskning i Kernefysik (CERN).

Da den konkrete planlægning af LHC-databehandlingen startede i slutningen af 1990'erne, var det klart for de fleste at der var brug for en radikalt anderledes infrastruktur end den der havde været anvendt i forbindelse med tidligere tiders CERN-eksperimenter. De mængder af data LHC vil levere er ganske enkelt langt større og der er langt flere forskere – fordelt over hele verden, der vil analysere dem.


Samtidig var der på amerikanske og europæiske universiteter nye softwareprodukter under udvikling, som ville tillade etableringen af virtuelle arbejdsgrupper samt deling af computere og store mængder af data på tværs af organisations- og landegrænser [1].

Det blev besluttet at anvende disse softwareprodukter til etableringen af et verdensomspændende 'LHC-grid', som efter planen skulle give forskere fra alle CERN's medlemslande adgang til at analysere LHC-data direkte fra deres hjemmestitutter.

Inden vi vender os imod realiseringen af dette projekt, vil vi nu se på hvad det er for datamængder vi har med at gøre og hvor de kommer fra.

LHC data i tørre tal

Ved LHC vil man i efteråret 2008 begynde at sende protoner rundt i acceleratoren. Dette vil i starten blot være testkørsler med relativt få protoner ved 'lave' energier. Senere forventer man at nå op på 800 millioner proton-protonkollisioner per sekund ved energier på 14 TeV. For blot én af de 4 detektorer – ATLAS, vil det resultere i en datastrøm fra selve detektoren til det såkaldte begivenheds-filter på op imod 100 Gb/s. Så meget data er det umuligt at studere i detalje og filtrets opgave er at bruge nogle meget hurtige test til at frasortere 'uinteressante' begivenheder. Efter denne frasortering vil en datastrøm på 320 MB/s bevæge sig fra de underjordiske faciliteter til CERN's computercenter – det såkaldte Tier-0-center, hvor disse 'rå data' vil blive opbevaret permanent og viderebehandlet til såkaldte "Event Summary Data" (ESD) og "Analysis Object Data" (AOD). Dette er vist i figur 1. Flere informationer om LHC kan findes i [2].




Figur 1. Dataenes vej fra detektorer til CERN's computer-center. Kilde: [3].

LHC-grid'et

Det nye, i forhold til tidligere CERN-eksperimenter, er ikke kun mængden af data, men også at alle rå data, ESD og AOD kontinuerligt vil blive kopieret væk fra CERN og ud til 10 såkaldte Tier-1-centre rundt omkring i verden hvor de vil blive viderebehandlet. Disse Tier-1-centre har hver en dedikeret netværksforbindelse på 10 gigabits per sekund til CERN's computercenter.

For ATLAS alene vil hvert Tier-1 center (se figur 2) modtage og opbevare 1/5 af de rå data samt al ESD. Dette svarer til ca. 8 TB per dag og ca. 2 PB per år!



Figur 2. Illustration af de forskellige niveauer i LHC-grid-arkitekturen. Kilde: [3].

Udover at opbevare data og stille dem til rådighed for forskerne har Tier-1 centrene til opgave at reprocessere data med opdaterede kalibreringsparametre og nyere softwareversioner.

Tier-2 centrene har til opgave at producere simulerede data, som kopieres 'op' til Tier-1 centrene. Derudover er det Tier-2-centrenes opgave at 'servicere' forskerne. Forskernes dataanalyse vil netop foregå under anvendelse af AOD data lagret på Tier-2 centrene og med Tier-2 centrene computerkraft. De over 150 Tier-2- centre er af vekslende sammensætning. Deres lagringskapacitet, computerkraft og båndbredde til CERN og Tier-1-centrene afhænger typisk af hvor megen vægt der bliver lagt på partikelfysik og grundforskning i de givne lande og regioner.

Det samlede netværk indbefatter både dedikeret båndbredde på fiberoptiske kabler stillet til rådighed af diverse nationale forskningsnetværk samt båndbredde allokeret på det offentlige internet.

I og med at f.eks. en forsker i princippet kan køre beregninger på alle de computercentre der er sammenkoblede via dette netværk, kan LHCgrid'et i og for sig betragtes som én gigantisk computer med mere end 50.000 CPU'er og mere end 20 PB lagringskapacitet.

Flere informationer om anvendelsen af LHC-grid'et af de to LHC-eksperimenter Danmark er med i via Niels Bohr Institutet, nemlig ATLAS og ALICE, kan findes i [4] og [5].



Figur 3. Oversigt over NDGF's tjenester og ressourcer ved de nordiske computercentre. Symbolforklaring: *Rektangler* angiver CPU-kapacitet i "Kilo Specmarks Integer year 2000", svarende til 1 standard-CPU anno 2004. *Cylindre* angiver Disk-kapacitet i TB. "Talebobler" angiver Båndkapacitet i TB. Alle tallene vokser hurtigt og skal ganges med en faktor 2-3 i dag. "Preproduction" hentyder til de test NDGF laver af ny software før de installerer den på "Production"-infrastrukturen. Kilde: [7].

Det nordiske grid

Nordiske fysikinstitutter deltog fra LHC-grid'ets start i udviklingen af den software der anvendes til at sammenkoble computerklynger. I 2001 blev dette samarbejde formaliseret ved dannelsen af NorduGrid [6] – et forskningsnetværk finansieret af Nordisk Ministerråd via Nordunet2-programmet. NorduGrid har siden udviklet sin egen selvstændige grid software, som anvendes af de nordiske institutioner der deltager i LHC-grid'et. I særdeleshed anvendes denne software

af "Nordic DataGrid Facility" (NDGF), som er den organisation der varetager den praktiske udrulning og vedligeholdelse af grid-software på de nordiske computerklynger der udgør det nordiske Tier-1-center (se figur 3).

Fra produktion til analyse

Hele den beskrevne infrastruktur har fra forskernes synspunkt ét formål, nemlig at muliggøre nye opdagelser. De data der vil komme blot fra ATLAS er der flere end 2100 fysikere verden over, som venter på.

For at forstå hvorfor analysen af LHC-data er imødeset med så stor spænding af fysikere verden over, vil vi tage en kort afstikker omkring teoretisk fysik.


De sidste 30 år er der én model der har domineret partikelfysikken – nemlig den såkaldte Standardmodel. Ved alle de mange eksperimenter der hidtil er blevet udført ved accelerators verden over er der aldrig blevet målt noget der ikke var i overensstemmelse med denne model. Som sådan må Standardmodellen betragtes som noget af en teoretisk bedrift. Standardmodellen opererer med 18 elementarpartikler, som alle pånær én er blevet detekteret ved tidligere eksperimenter. Den mystiske manglende partikel er den såkaldte Higgs-partikel, som er ansvarlig for genereringen af partiklers masse. Et af målene med LHC er at detektere denne partikel. Et andet mål er simpelthen at se hvad der ellers dannes af partikler ved ekstremt høje energier. På partikelfysikere regner Standardmodellen for at være det endelige svar på hvordan materie er opbygget. Modellen forklarer ganske vist de hidtidige data, men samtidig rejser den en række fundamentale spørgsmål, som f.eks. hvorfor elementarpartiklerne har de masser de har. Derfor håber de fleste faktisk at der ved LHC vil blive fundet fænomener der ikke kan forklares af Standardmodellen og som vil afklare om nogle af de foreslåede generaliseringer af Standardmodellen er korrekte.

Den metode der vil blive anvendt går i al sin enkelthed ud på følgende: Man starter med en teoretisk model for elementarpartikler, beregner hvad der i følge denne model vil ske når to protoner støder sammen med en hastighed på 99,9999991 % af lysets og beregner hvad det bør give af målinger ved ATLAS. Dernæst sammenligner man dette med hvad man rent faktisk har målt.

Det er disse beregninger der kræver den megen computerkraft som leveres af LHC-grid'et. Dette skyldes for det første at dataanalysen er en statistisk analyse, som kræver mange data for at være signifikant. For det andet er simuleringen af partiklernes bevægelse i detektoren yderst kompliceret.

Figur 4 viser et plot af simulerede ATLAS-data. Det viser fordelingen af den såkaldte invariante masse per begivenhed. Da der er tale om simulerede data er det muligt at identificere begivenheder der skyldes andre processer end den man søger ($H \rightarrow \tau\tau$). Simuleringerne er kørt af ATLAS' produktionsgruppe på LHC-grid'et. Det vil kræve 3 års datatagning at samle nok data til at lave et tilsvarende plot med rigtige begivenheder. Et sådant plot vil så kunne bruges til at give et bud

på om Standardmodellens Higgs-partikel rent faktisk findes ved en given masse (120 GeV i dette tilfælde).



Figur 4. Et plot af den invariante masse – simulerede ATLAS-data. Kilde: ATLAS-gruppen ved Niels Bohr Institutet.

De fleste af de danske fysikere der beskæftiger sig med LHC-fysik er tilknyttet Niels Bohr Institutet. Her sidder også et lille hold af grid-udviklere. Det er én af grid-udviklernes fornemste opgaver at gøre brugen af den omfattende infrastruktur så enkel og effektiv som muligt, for således at give fysikerne de bedst mulige betingelser for at skabe videnskabelige gennembrud.

Den generelle danske grid-udvikling foregår både på Institut for E-Science og Niels Bohr Institutet ved Københavns Universitet, samt på Ålborg Universitet og hos NDGF i Kastrup.

Litteratur

- [1] I. Foster and C. Kesselman, "The Grid: Blueprint for a New Computing Infrastructure" (1998), Morgan Kaufmann; 1st edition (November 1998), ISBN: 1558604758
- [2] Jos Engelen, "Physics at the LHC with ATLAS and CMS", Nuclear Physics B – Proceedings Supplements Volume 135, October 2004, Pages 3-8
- [3] LHC folier fra cern.ch/gridcafe – indeholder gode illustrationer og let forståelig tekst, se <http://gridcafe.web.cern.ch/gridcafe/animations/LHCdata/LHCdata.html>
- [4] G. Duckeck et al. (2005), "ATLAS computing: Technical design report", CERN-LHCC-2005-022, se <http://cdsweb.cern.ch/record/837738>
- [5] F. Carminati et al. (2005), "ALICE computing: Technical design report", CERN-LHCC-2005-018, se <http://cdsweb.cern.ch/record/832753>
- [6] The NorduGrid collaboration, "Nordugrid – the nordic testbed for wide area computing and data handling – final report", <http://www.nordugrid.org/documents/nordugrid-final.pdf>
- [7] NDGF web site, <http://www.ndgf.org/>



Frederik Orellana, har siden sine ph.d.-studier ved universitetet i Zürich beskæftiget sig med anvendelsen af computerteknologi i højenergifysik og beslægtede områder. Først ved CERN og universitet i Geneve og nu som postdoc ved Niels Bohr Institutet.

TOTAL SOLFORMØRKELSE I KINA

Viktors Farmor arrangerer to forskellige rejser til solformørkelsen i Kina
Den længste solformørkelse i dette århundrede

Begge rejser er kombineret med et program der præsenterer deltagerne for området omkring Shanghai.

Vores rejseleder assisteres af en astronomisk ekspert, som kan fortælle om hvad der sker under solformørkelsen og svare på spørgsmål.

Begge rejser begynder og slutter i Shanghai.

Vi bor fortrinsvis på 4- eller 5-stjernede hoteller.

Prisen er inklusive helpension og drikkepenge.

Solformørkelse ... med udvidet rundrejse

Vi har en heldags-udflugt til den hellige buddhistiske ø Putuoshan før solformørkelsen, hvor øboerne stadig lever som i 1800-tallets Kina. Vi rejser rundt i nogle af Kinas smukkeste landskaber samt de gamle landsbyer i Anhui-provinsen og den gamle fiskerby Tongli ved Yangtze-flodens delta.

17. til 31. juli 2009
Pris: 21.800 kr.

Ledere: Casper Tollerud og Mikael Svalgaard



Solformørkelse ... og Kina kort fortalt

Før og efter oplevelsen er der indlagt sightseeing og afslapning i byerne Shanghai, Tongli og Suzhou. I Suzhou oplever vi de smukke haver.

Vi sejler på Yangtze-floden og ser såvel moderne storbyer som landsbyer og oplever flotte shows og opvisninger.

18. til 27. juli 2009
Pris: 16.900 kr.

Ledere: Bozena Kaminska og Michael Cramer Andersen

