

CALMIP (Calcul en Midi-Pyrénées) : pour ceux qui n'ont rien à ceux qui sont déjà bien équipés



Boris Dintrans (Président Comité de Programmes CALMIP)

Pierrette Babaresco* (Responsable Système)

Nicolas Renon* (Responsable Calcul Scientifique)

*DTSI - Université Paul Sabatier (nicolas.renon@univ-tlse3.fr)

<http://www.calmip.cict.fr>

- **CALMIP**
 - Structuration du Mésocentre de Calcul
 - Mode accès aux ressources
 - Les labos partenaires
- **Système de calcul**
 - Choix d'un système
 - Hardware / Software
- **Exploitation et Accompagnement**
 - Interface Utilisateur
 - Intégration projet de recherche
- **Perspectives**
 - EQUIP@MESO
 - ECA

Le Groupement Scientifique CALMIP : Historique

- ❑ Fondé en 1994 par 17 Laboratoires de Recherche Publics en Région Midi-Pyrénées
- ❑ Soutien des 6 établissements universitaires toulousains
 - ❑ Université Paul Sabatier (Sciences et Santé)
 - ❑ Institut National Polytechnique de Toulouse
 - ❑ Institut National des Sciences Appliquées
 - ❑ Université des Sciences Sociales
 - ❑ Université du Mirail , Lettres, Langues et Arts
- ❑ Positionnement : Mésocentre de Calcul
 - ❑ Promotion du calcul scientifique haute performance (contexte Multi-thématique)
 - ❑ Mise à disposition d'un environnement de Calcul Scientifique performant
 - ❑ Acquisition systèmes de calcul (contexte production)
 - ❑ Organisation de l'exploitation et du support aux utilisateurs



Le Groupement Scientifique CALMIP : Organisation

✓ Pilotage

Comité d'Orientation

6 Vice-Présidents des conseils scientifiques des établissements
Le Président du Comité de Programmes
Région
3 Représentants de la communauté des utilisateurs (Pôles de Recherche)
Représentants Pôles de compétitivité

✓ Attribution des ressources :
✓ 2 AO par an
✓ Animation scientifique

Comité de Programme



10 experts scientifiques issus des laboratoires
7 thématiques scientifiques

✓ Support aux utilisateurs
✓ Support projets de Recherche
✓ Exploitation du supercalculateur

Université Paul Sabatier D.T.S.I.


1 Ingénieur calcul scientifique
1,5 Ingénieurs système

Positionnement CALMIP : Mésocentre



- ✓ **Mésocentre CALMIP :**
 - ✓ **Proximité**
 - ✓ **Contexte fort de Production**
 - ✓ **Multi-thématique**

2010 : 3rd system in production



'HYPERION', CALMIP computational system

- ❑ HYPERION (config avant EQUIP@MESO)
 - ❑ 2912 cores Nehalem Intel©
 - ❑ 33,57 TF peak
 - ❑ 223rd TOP 500 (november 2009)

Altix ICE 8200 EX :



Calcul Haute Performance : TOP 500 List


Top500 Novembre 2011

Rank	Site	Computer/Year Vendor	Cores	R _{max}	R _{peak}	Power
1	RIKEN Advanced Institute for Computational Science (AICS) Japan	K computer, SPARC64 VIIIfx 2.0GHz, Tofu interconnect / 2011 Fujitsu	705024	10510.00	11280.38	12659.9
2	National Supercomputing Center in Tianjin China	NUDT YH MPP, Xeon X5670 6C 2.93 GHz, NVIDIA 2050 / 2010 NUDT	186368	2566.00	4701.00	4040.0
3	DOE/SC/Oak Ridge National Laboratory United States	Cray XT5-HE Opteron 6-core 2.6 GHz / 2009 Cray Inc.	224162	1759.00	2331.00	6950.0
4	National Supercomputing Centre in Shenzhen (NSCS) China	Dawning TC3600 Blade System, Xeon X5650 6C 2.66GHz, Infiniband QDR, NVIDIA 2050 / 2010 Dawning	120640	1271.00	2984.30	2580.0
5	GSIC Center, Tokyo Institute of Technology Japan	HP ProLiant SL390s G7 Xeon 6C X5670, Nvidia GPU, Linux/Windows / 2010 NEC/HP	73278	1192.00	2287.63	1398.6
6	DOE/NNSA/LANL/SNL United States	Cray XE6, Opteron 6136 8C 2.40GHz, Custom / 2011 Cray Inc.	142272	1110.00	1365.81	3980.0
7	NASA/Ames Research Center/NAS United States	SGI Altix ICE 8200EX/8400EX, Xeon HT QC 3.0/Xeon 5570/5670 2.93 Ghz, Infiniband / 2011 SGI	111104	1088.00	1315.33	4102.0
8	DOE/SC/LBNL/NERSC United States	Cray XE6, Opteron 6172 12C 2.10GHz, Custom / 2010 Cray Inc.	153408	1054.00	1288.63	2910.0
9	Commissariat a l'Energie Atomique (CEA) France	Bull bulx super-node S6010/S6030 / 2010 Bull	138368	1050.00	1254.55	4590.0
10	DOE/NNSA/LANL United States	BladeCenter QS22/LS21 Cluster, PowerXCell 8i 3.2 Ghz / Opteron DC 1.8 GHz, Voltaire Infiniband / 2009 IBM	122400	1042.00	1375.78	2345.0

12 MW

CURIE
Machine
« PRACE »
(France)

CALMIP : Attribution des ressources pour la Recherche



□ Prochain Appel d'offres

- Mai 2012, (complément d'heure, nouveaux projets,...) ⇒ web : évaluation et attribution ressources jusqu'à **fin année 2012**

CALMIP : Les Labos utilisateurs

Pôle Science de la Matière :

CEMES - Centre d'Elaboration de Matériaux et d'Etudes Structurales (UPR 8011)
CIRIMAT - Centre Inter-universitaire de Recherche et d'ingénierie des Matériaux (UMR 5085)
IMRCP - Laboratoire des Interactions Moléculaires et Réactivité Chimique et Photochimique (UMR 5623)
LCC - Laboratoire de Chimie de Coordination (UPR 8241)
LNCMI - Laboratoire National des Champs Magnétiques Intenses (UPR 3228)
LCAR - Laboratoire Collisions Agrégats Réactivité (UMR 5589)
LCPQ - Laboratoire de Chimie et de Physique Quantiques (UMR 5626)
LPCNO - Laboratoire de Physique et Chimie des Nano-Objets (UMR 5215)
LPT - Laboratoire de Physique Théorique (UMR 5152)

Pôle Mathématiques Sciences et Technologies de l'Information et de l'Ingénierie :

ICA - Institut Clément Ader
IMFT - Institut de Mécanique des Fluides de Toulouse (UMR 5502)
IMT - Institut de Mathématiques de Toulouse (UMR 5219)
IRIT - Institut de Recherche en Informatique de Toulouse (UMR 5505)
LAAS - Laboratoire d'Analyse et d'Architecture des Systèmes (UPR 8001)
LGC - Laboratoire de Génie Chimique (UMR 5503)
LAPLACE - Laboratoire Plasma et Conversion d'Energie (UMR 5213)

Pôle Univers Planète Environnement Espace :


IRAP - Institut de Recherche en Astrophysique et Planétologie
CNRM/GAME - Centre National de Recherches Météorologiques (URA 1357)
LA - Laboratoire d'Aérodynamique (UMR 5560)
LEGOS - Laboratoire d'Etudes en Géophysique et Océanographie Spatiale (UMR 5566)
LMTG - Laboratoire des Mécanismes et Transferts en Géologie (UMR 5563)

Pôle Sciences du Vivant


IPBS - Institut de Pharmacologie et de Biologie Structurale (UMR 5089)
LIPM - Laboratoire des Interactions Plantes Micro-organismes (UMR 2594)
EDB - Evolution et Diversité Biologique (UMR 5174)
INSERM U563, dept. oncologie

CALMIP : Attribution des ressources pour la Recherche


Répartition par pôles de recherche



CALMIP : Attribution des ressources pour la Recherche




Evolution demande H_CPU/nombre_projets



Distributed memory example in CFD : Industrial fluidised bed



- ❑ Neptune_CFD : 3 000 000 cpu hours used in Y2010 on HYPERION
- ❑ Number of cores range in production : 68c - 512c



❑ Courtesy of : O Simonin, H. Neau, Laviéville - Institut de Mécanique des fluides de Toulouse - Université de Toulouse/ CNRS

Distributed memory example in CFD : Industrial fluidized bed

Time-to-solution and speed-up



- C1 a : Altix ICE Harperton, Intel_MPI
- C1 b : Altix ICE Harperton, MPT
- C2 a : 'HYPERION' Altix ICE NHM, Intel MPI
- C2 b : 'HYPERION' Altix ICE NHM, MPT
- C3 : Cluster IB AMD Shanghai, OpenMPI

□ Courtesy of : O Simonin, H. Neau, Laviéville - Institut de Mécanique des fluides de Toulouse - Université de Toulouse/ CNRS

- ❑ Example in Life Science
 - ❑ Fish population fragmentation studies
 - ❑ Counting in fish in two Rivers near by Toulouse
 - ❑ fish population fragmentation studies
 - ❑ 12 000 cpu hour used
 - ❑ mostly data set exploring (code in C! Good !)



Chevaine



Gandoise



Vairon



- **CALMIP**
 - Structuration du Mésocentre de Calcul
 - Les labos partenaires
 - Quelques chiffres
- **Système de calcul**
 - Choix d'un système
 - Hardware / Software
- **Exploitation et Accompagnement**
 - Interface Utilisateur
 - Intégration projet de recherche
- **Perspectives**
 - EQUIP@MESO
 - ECA

CALMIP : Processus de renouvellement 2008-2009

- Troisième génération de supercalculateur
- Critères techniques:
 - Qualité:
 - Système performant pour tirer les applications vers le haut
 - Critères environnementaux: consommation électrique, mode de refroidissement, ...
 - Quantité:
 - Pallier la pénurie de ressources et anticiper leur augmentation
- Adhésion de la communauté scientifique:
 - Faire participer les utilisateurs à ce choix.
- Procédure : dialogue Compétitif

CALMIP : Processus de renouvellement 2008-2009

□ Groupe de test de performance : 10 benches, 11 codes, 20 personnes, 11 Labos

□ Participants

- Ch. Lepetit (LCC), R. Poteau (LPCNO), L. Maron (LPCNO), F. Jolibois (LPCNO)
 - code GAUSSIAN (Chimie Quantique), OpenMP
- H. Tang (CEMES), I. Gerber (LPCNO)
 - VASP (Physico-Chimie de la Matière), MPI
- J. Czaplicki (IPBS), P. Arnaud (LCC) et I. Andre (LISBP)
 - AMBER (Dynamique Moléculaire), MPI
- B. Dintrans (LATT, OBS-MIP)
 - Pencil Code (Astrophysique), MPI
- A. Pedrono (IMFT) H. Neau (IMFT)
 - JADIM(dev.), NEPTUNE, (Mécanique des Fluides), MPI
- S. Capponi (LPT-IRSAMC)
 - DO36(dev.) (Physique Théorique), OpenMP
- A. Scemama (LCPQ – IRSAMC)
 - QmcCHEM(dev.) (Physique théorique et Chimie Quantique), MPI
- E. Courcelles (LIPM) Génomique-Bioinformatique ProdomAlign (dev.) OpenMP
- I. Touche (LGC) Algorithmique - Filtrage Particulaire (Dev.), MPI

HYPERION (2009-2013)

CALMIP – Altix ICE 8200 EX & UV– 2960cores – 14 To RAM –

Altix ICE 8200 EX
352 nœuds
2816 cores
12.6 To mémoire

❑ Distributed Memory : Altix ICE 2816 (nodes)

- ❑ 2,8 Ghz Nehalem EP Quad core
- ❑ 36 GB ram /nodes
- ❑ Interconnect : IB, Dual-Rail, DDR
- ❑ topology : Hypercube

- ❑ Shared memory : Altix UV 96 cores
 - ❑ 2,6 Ghz Nehalem EX 6-cores
 - ❑ 1 TB ram
 - ❑ ccNUMA architecture
 - ❑ NUMALINK 5
 - ❑ topology : Tore2D

❑ permanent storage:

❑ Enhanced NFS : 38TB

Enhanced NFS sur IB

Service Administration :
1 admin node + console

❑ Remote Visualisation Solution :

❑ 4 nodes :

- ❑ 8 cores NHM, 48 go ram
- ❑ GPU nvidia FX 4800

❑ Virtual GL/ Turbo VNC

X 8 Infiniband 4X DDR X 4

Service Fichier Temporaire :

Lustre FS
2 MDS + IS220
4 OSS

Sto

❑ Temporary Storage
Lustre

- ❑ 2 MDS, 4 OSS
- ❑ 3 Gbytes/s
- ❑ 200 TB

Water cooling

CALMIP : Software environnement

Profils codes

- Langage : Fortran (77,90), C, C++
- Parallèle : MPI (70%), OpenMP (30%)
- Mémoire partagée : jusqu'à 600 Go (OpenMP)

Environnement de développement

- Compilo Intel (v10, 11, 12) (+ gnu)
- MPI : MPT (MPI SGI®, Intel MPI, Open MPI)
- Bibliothèques scientifiques
 - MKL intel® (BLAS, LAPACK, Scalapack, ...)
 - Petsc, MUMPS,...
- Débogueur // : ddt
- Tuning code
 - Intel Trace Analyzer
 - Profileur code parallèle
 - Outils placement processus

codes utilisés :

- VASP
- SIESTA
- NEPTUNE
- Gaussian
- AMBER
- SYMPHONIE
- WRF
- ABAQUS
- RADIOSS
- OPENFOAM
- MFIX
- VINA
- JADIM
- ORCA
- codes utilisateurs (dev.), etc ...

- OS : SUSE SLES 11 SP2
- Gestionnaire de batch : PBS Pro
- Outil d'administration système TEMPO (SGI®)

Projet EQUIP@MESO (AO EQUIPEX) : UPGRADING




Projet EQUIP@MESO (AO EQUIPEX) : UPGRADING

❑ Distributed Memory : 16 nœuds supplémentaires (nodes)

- ❑ 2,8 Ghz Nehalem EP Quad core
- ❑ 36 GB ram /nodes
- ❑ 128 cores supplémentaires

❑ Shared memory : Altix UV 384 cores

- ❑ 48 processeurs WestmereEX 8-cores
- ❑ 3 To RAM
- ❑ ccNUMA architecture



En Production


- **CALMIP**
 - Structuration du Mésocentre de Calcul
 - Les labos partenaires
 - Quelques chiffres
- **Système de calcul**
 - Choix d'un système
 - Hardware / Software
- **Exploitation et Accompagnement**
 - Interface Utilisateur
 - Intégration projet de recherche
- **Perspectives**
 - EQUIP@MESO
 - ECA

Exploitation

Queue	Nombre de cores	Nombre de nœuds	Walltime	Remarque
mono	< 8	1	400h	Non exclusif -non HT
noeud	8	1	300h	Exclusif - HT
noeud4	9 - 32	2 - 4	200h	Exclusif - HT
noeud16	33 - 128	5 - 16	150h	Exclusif - HT
noeud32	129 - 256	17 - 32	48h	Exclusif - HT
noeud64	257 - 512	33 - 64	36h	Exclusif -HT
UV*	1-384	1	240h	Non-exclusif - non HT
graphique	8 max.	1	2h	Non exclusif - HT


Exploitation

Evolution consommation sur l'année 2011



Exploitation

Consommation h_cpu par file d'attente



CALMIP : Interface/ Accompagnement utilisateur

- Base :**
 - accueil / discussion / échanges problématique recherche
 - synergie(on essaye!) Ingé. Calcul / ASR dans les labos
- Interface 3 niveaux**
 - Niveau 1 : prise en main opérationnel du système, les calculs tournent
 - Site WEB (compilation, batch, debugueur) - Mise en autonomie
 - Niveau 2 : le code tourne, tourne-t-il de façon optimale ?
 - Outil de d'analyse, profiling, debugger
 - Optimisation des performances
 - Niveau 3 : Collaboration long terme/ récurrente
 - intégration dans le projet de recherche
 - Conseil expertise
- Formations :**
 - Formation récurrente : prise en main système CALMIP / Portage Optimisation des codes
 - 2011 : 3 sessions, 50 participants
 - Formations Ponctuelles (HMPP)
 - On s'appuie sur : CUTIS, Groupe Calcul (National), Cerfacs, EQUIP@MESO

CALMIP : Interface/ Accompagnement utilisateur Niveau 1



calmip

Vous êtes ici : Accueil > Espace Utilisateurs CALMIP > Utilisation du système de calcul

- Accueil
- ▶ Accès aux ressources
- Actualités
- Contacts
- ▼ Espace Utilisateurs CALMIP
 - ▼ Utilisation du système de calcul
 - Comment compiler un programme ?
 - Programmation parallèle (MPI & OpenMP)
 - ▶ Logiciels installés
 - ▶ Amélioration des performances et Outils de développement : Debuggage, Optimisation et Modules
 - ▶ Comment lancer un calcul sur HYPERION ?
 - Ressources graphiques et Visualisation à distance
 - Comment se connecter au supercalculateur ?
 - Espace disque
 - ▶ Formation
 - FAQ
- ▶ Le Groupement Scientifique CALMIP
- Le Supercalculateur HYPERION
- Liens Utiles

- ▶ Comment se connecter au système de calcul *Hyperion* ?
- ▶ Comment lancer un calcul sur le système de calcul *Hyperion* ?
- ▶ Espace Disque
- ▶ Comment utiliser les ressources graphiques ?
- ▶ Environnement de développement
 - Compilation
 - Programmation Parallèle
 - Bibliothèques Scientifiques
 - Amélioration des performances, Optimisation, Debuggage et Module (outils d'optimisation et de debuggage des applications).
- ▶ Logiciels Scientifiques

Articles

- [AltixUV en production : réponse à quels besoins ? - 28 février](#)
- [Installation PARAVIEW \(module\) - Octobre 2010](#)
- [Ressources graphiques et Visualisation à distance - Mars 2010](#)


CALMIP : Interface/ Accompagnement utilisateur Niveau 2

Les principaux outils d'optimisation disponibles sur HYPERION sont :

- NUMATools : outils propres aux architectures Altix : meilleures performances des jobs
 - exemple utilisation
- Accélérer les communications MPI : Perfboost
- Outil d'aide à l'analyse du parallélisme des codes :
 - outil d'analyse de code MPI Intel(c) Trace Collector et Intel Trace Analyser
 - MPI_INSIDE
- PerfSuite : Analyse de performance des codes :
 - savoir facilement quel(s) est(sont) la(es) zone(s) du





UVCALMIP EVAL WAIT COLLECTIVE



CALMIP : Interface/ Accompagnement utilisateur Niveau 3


Exemple collaboration:

Projet CALMIP p0604 - Physique des Plasma - Laboratoire LAPLACE - O. Eichwald, O. Ducasse




CALMIP : Interface/ Accompagnement utilisateur Niveau 3

Code STREAMER - Temps moyen par itérations (sec)



PUBLIS...

- [1] S. Kacem, O. Ducasse, O. Eichwald, N. Renon, H. Bensaad and M. Yousfi, shock wave and gas dynamics simulation in Positive Point-to-plane air corona discharge, Conference Greifswald, (2010).
- [2] Full Multi Grid method for electric field computation in point-to-plane streamer discharge in air at atmospheric pressure, submitted at Journal of Computational Physics, in revision .




- **CALMIP**
 - Structuration du Mésocentre de Calcul
 - Les labos partenaires
 - Quelques chiffres
- **Système de calcul**
 - Choix d'un système
 - Hardware / Software
- **Exploitation et Accompagnement**
 - Interface Utilisateur
 - Intégration projet de recherche
- **Perspectives**
 - **EQUIP@MESO**
 - **ECA**

CALMIP Partenaire EQUIP@MESO


❑ Projet EQUIP@MESO

- ❑ 10 mésocentres partenaires, coordination GENCI (Grand équipements Nationaux en Calcul Intensif)
- ❑ Objectif : mise en niveau/amplification de 10 mésocentres (maillage mésocentre)
- ❑ Animation scientifique : conférence EQUIP@MESO 2012 « Chimie et Sciences de la vie : de la simulation numérique au HPC »
 - ❑ Conférencier CALMIP : M. Caffarel/A. Scemama (LCPQ-IRSAMC) (projet CALMIP p0510 - Méthodes Monte-Carlo Quantiques pour les Molécules) :
« Pyramide HPC : du labo au Pétaflop en passant par les mésocentres »



CALMIP : Renouvellement système pour 2014


- ❑ Renouvellement d'HYPERION (Procédure dialogue 2012-2013)
 - ❑ Fonds CPER 2007 - 2013
 - ❑ Installation Espace Clément Ader (Partie PCI) :
 - ❑ Infrastructure d'accueil Mutualisée avec Météo-France
 - ❑ Production visée : 2014



HPC en Europe (Partnership for Advanced Computing in Europe)



MesoNH Performance on HYPERION



HYPERION performance

Courtesy of : JP Pinty & J. Escobar Laboratoire Aérologie - Observatoire Midi-Pyrénées Université Paul Sabatier/ CNRS

Code STREAMER : Equation du problème et Algorithme

$$\left\{ \begin{array}{ll} \frac{\partial n_s}{\partial t} + \vec{\nabla} \cdot n_s \vec{v}_s \left(\frac{E}{N} \right) = \sigma_s \left(\frac{E}{N} \right) & s = e, p, n \quad (1) \\ n_s \vec{v}_s = n_s \mu_s \left(\frac{E}{N} \right) \vec{E} - D_s \left(\frac{E}{N} \right) \vec{\nabla} n_s & s = e, p, n \quad (2) \\ \Delta V = \frac{q_e}{\epsilon_0} (n_p - n_e - n_n) & (3) \\ \vec{E} = -\vec{\nabla} V & (4) \end{array} \right.$$

Bilan particule pour chaque espèce (equation de transport ou equation de continuité)


Approximation dérive-diffusion du transport de la quantité de mouvement

Equation de poisson calcul potentiel électrique

Relation champ-potential électrique

Domaine Ω semi-infini => condition dirichlet (plan) + Neuman (gradient nul)


Discretisation Volume fini (2D axis) /Schéma en temps explicite



Japon : K-computer (Y2011), 580 000 cores



- Fujitsu RIKEN 8 PFlop (Kobe Japan)
- efficiency 93%
- 548 k core Sparc
- 10 Mw, 825 Mflop/W
- Single socket, 8C socket, 8 flop per core
- 6D tore Interconnect



CALMIP : Processus de renouvellement 2008-2009

❑ Bilan de la procédure

- ❑ Long mais nécessaire et extrêmement bénéfique pour la communauté CALMIP
- ❑ Échanges directs avec les candidats dans un cadre administratif clair
- ❑ Participation des utilisateurs (préfigure une exploitation réussie...) :
 - ❑ Performance et adhésion (facilement exploitable)
 - ❑ Evolutions techniques (programme fonctionnel) : au plus près des besoins
 - ❑ Enrichissement : Visualisation à distance