

京コンピュータを用いた 宇宙プラズマの第一原理 ブラソフシミュレーション

梅田 隆行 (umeda@stelab.nagoya-u.ac.jp)
名古屋大学 太陽地球環境研究所

HPCI「京」若手人材育成利用
学際大規模情報基盤共同利用・共同研究(JHPCN)
九州大学 先端的計算科学プロジェクト
東京大学 大規模HPCチャレンジ
名古屋大学HPC計算科学連携研究プロジェクト
SS研マルチコアクラスタ性能WG

太陽地球環境(STE)のシミュレーション

○ プラズマシミュレーション

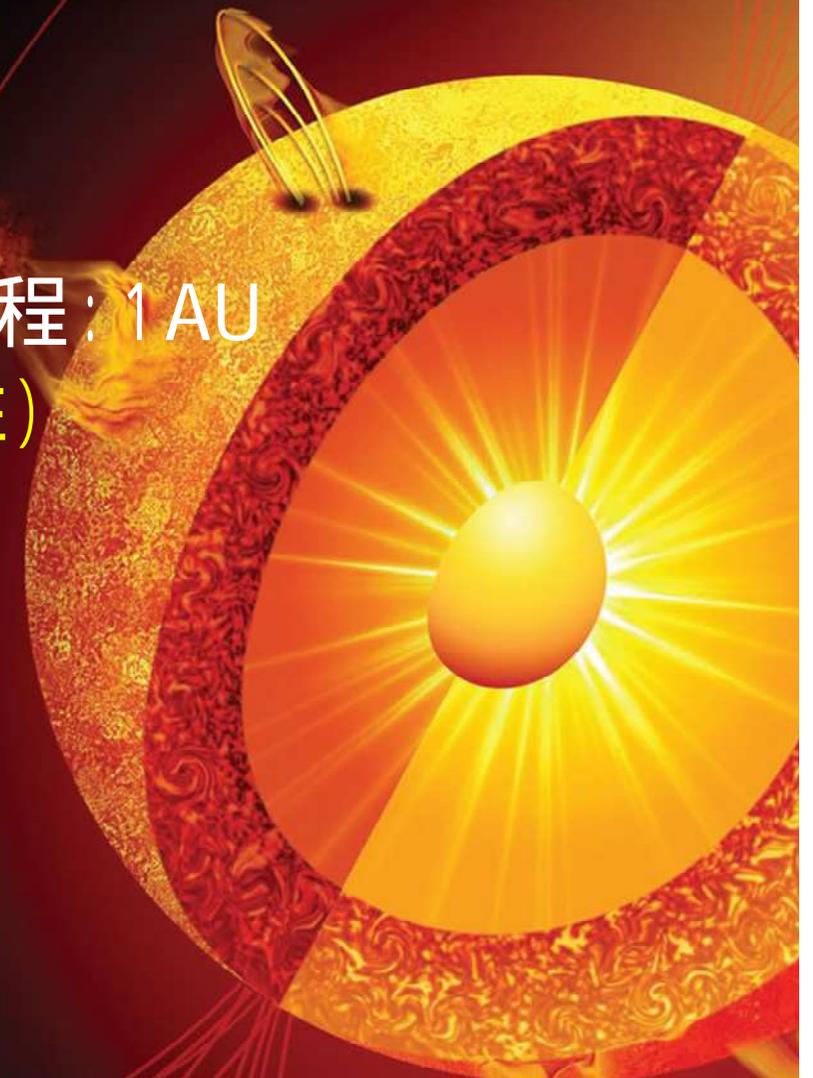
- 宇宙の99.99%はプラズマ
- 特に「無衝突」状態を扱う
ex. 太陽風プラズマの平均自由行程: 1 AU
- マルチスケール(流体性 + 粒子性)

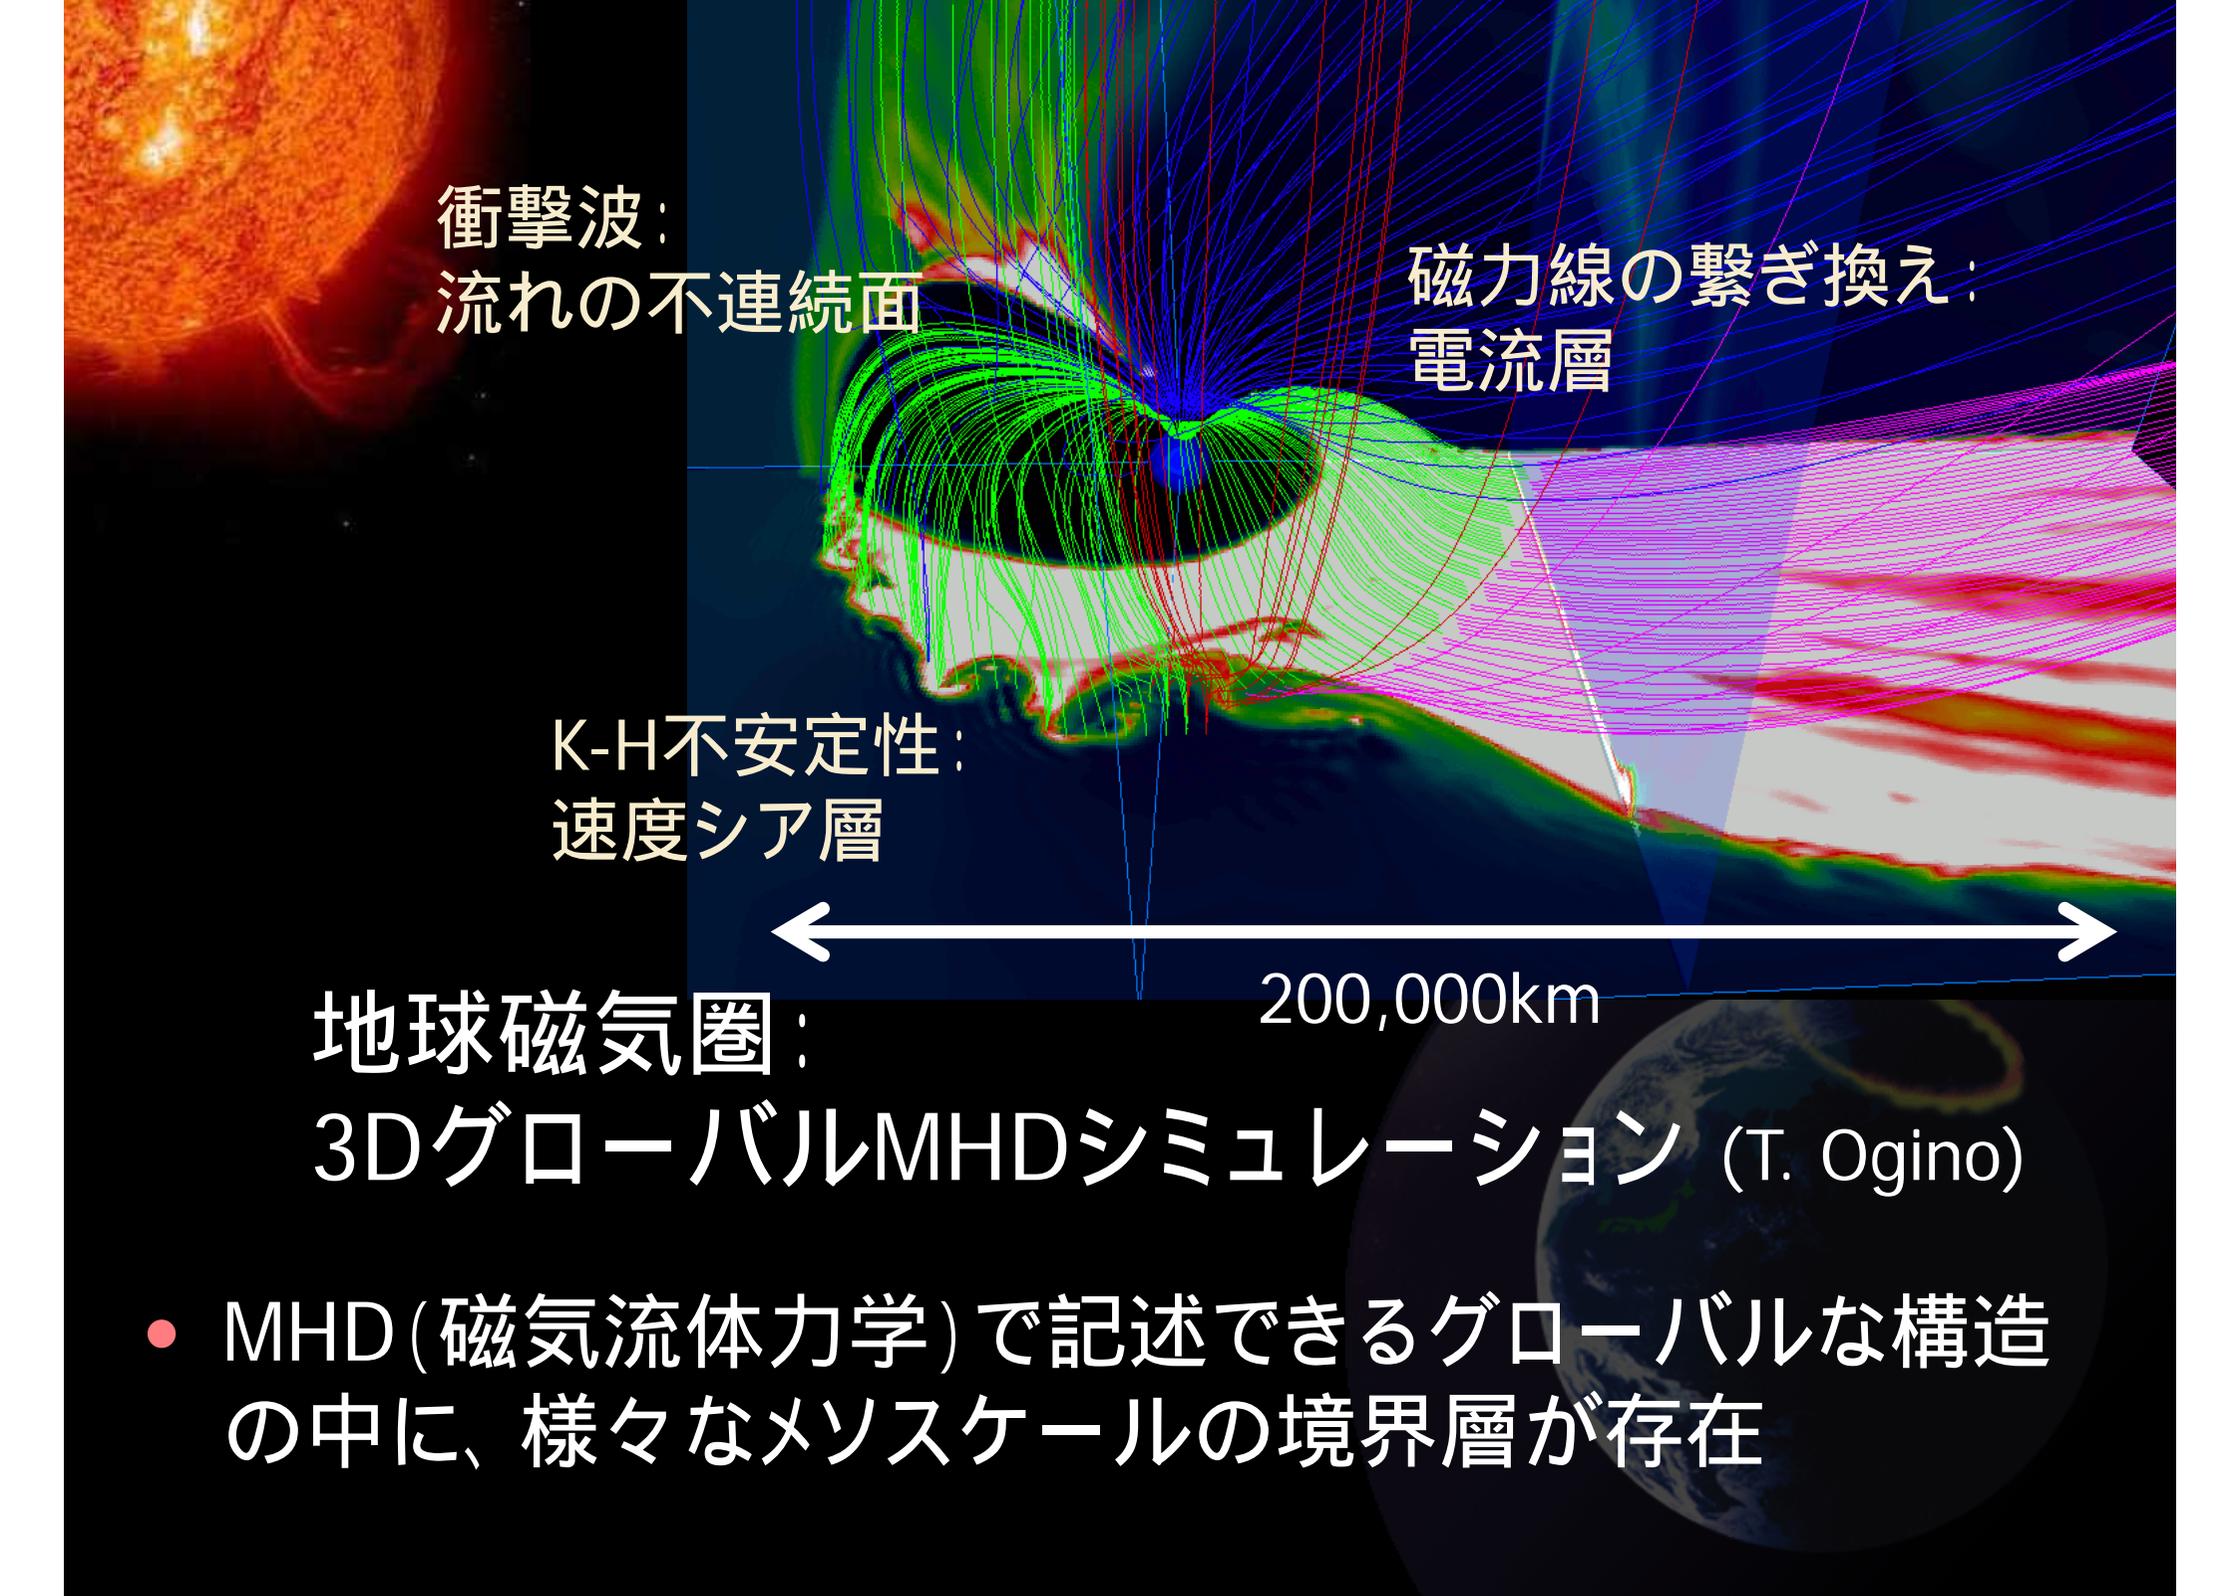
○ 惑星大気シミュレーション

- 高密度中性大気
- 流体 + 化学反応

○ 天文・天体シミュレーション

- 恒星近傍: 高温・高圧・高密度
- 基本的にMHD + α





衝撃波：
流れの不連続面

磁力線の繋ぎ換え：
電流層

K-H不安定性：
速度シア層

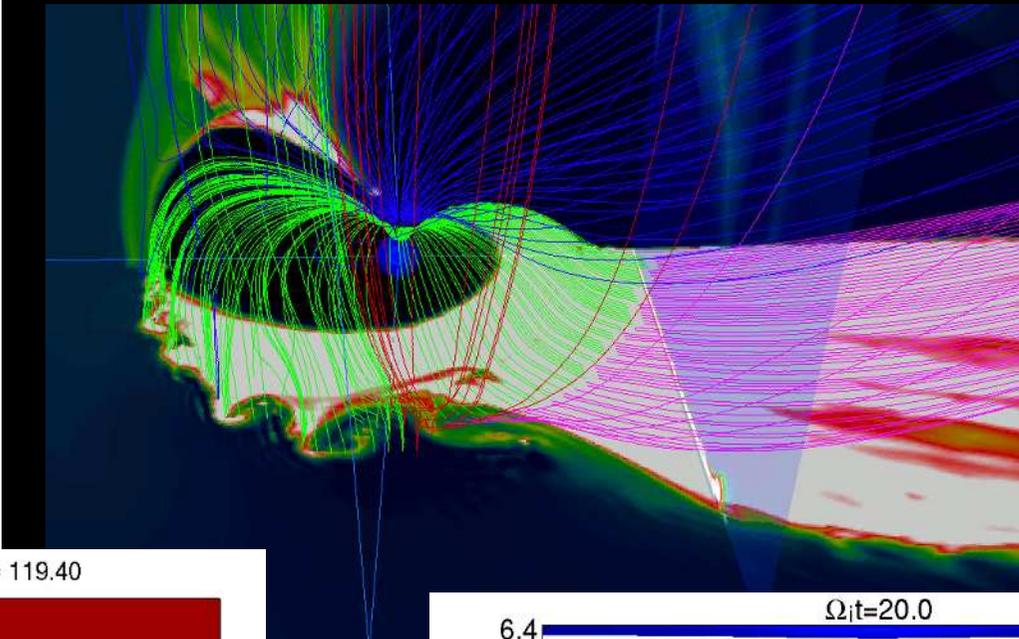
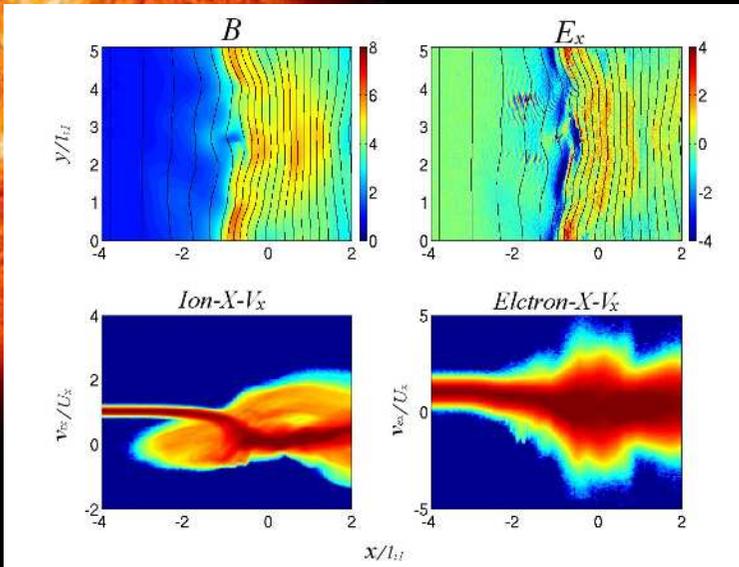


200,000km

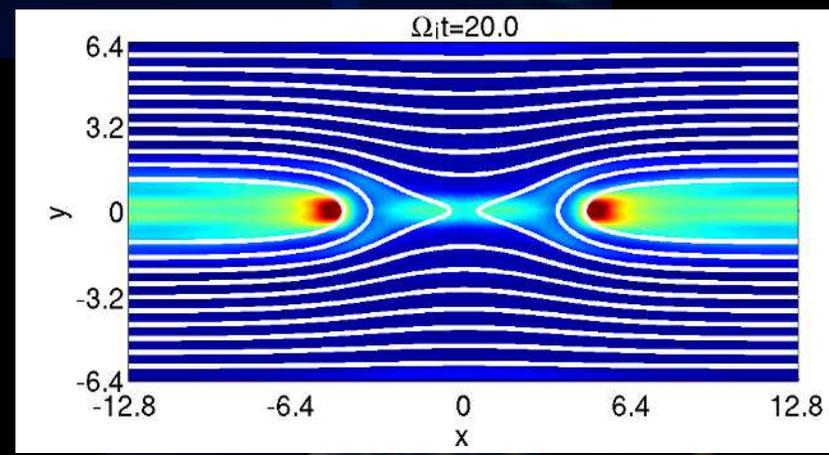
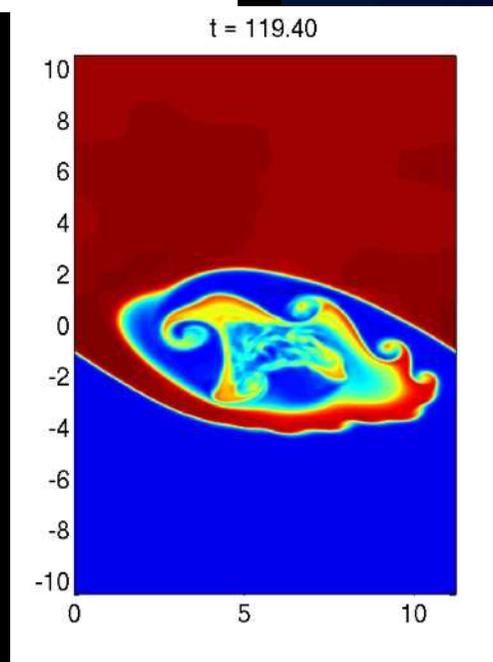
地球磁気圏：

3DグローバルMHDシミュレーション (T. Ogino)

- MHD(磁気流体力学)で記述できるグローバルな構造の中に、様々なメソスケールの境界層が存在



衝撃波



“グローバル”運動論シミュレーション

目的:

- 宇宙プラズマ科学的観点から、太陽地球系の変動(宇宙天気)を理解・予測する。
- 多スケール(磁気流体力学 - 境界層 - 粒子運動論)間の相互作用を理解する。
 - 磁気圏グローバル構造は基本的にはMHDで記述
 - ローカルな境界層(不連続面・シア層・電流層など)における粒子運動論の重要性??

究極のゴール:

磁気圏全てをシームレスに運動論で解く

ゼタ or ヨタスケールコンピューティング! (20 or 30年後)

第一原理 Full Vlasov Model 基礎方程式

位相空間分布関数

$40^5 \sim 4\text{GB}$

$$f_s(x, y, \cancel{z}, v_x, v_y, v_z)$$

6D!

5D

$40^6 \sim 160\text{GB}$

Vlasov equation

Charge continuity equation

$$\frac{\partial f_s}{\partial t} + \mathbf{v} \cdot \frac{\partial f_s}{\partial \mathbf{r}} + \frac{q_s}{m_s} (\mathbf{E} + \mathbf{v} \times \mathbf{B}) \cdot \frac{\partial f_s}{\partial \mathbf{v}} = 0$$

$$\frac{\partial \rho}{\partial t} + \nabla \cdot \mathbf{J} = 0$$

Maxwell's equation

$$\nabla \times \mathbf{E} = -\frac{\partial \mathbf{B}}{\partial t}$$

$$\nabla \times \mathbf{B} = \mu_0 \mathbf{J} + \frac{1}{c^2} \frac{\partial \mathbf{E}}{\partial t}$$

$$\nabla \cdot \mathbf{E} = \frac{\rho}{\epsilon_0}$$

$$\nabla \cdot \mathbf{B} = 0$$

cf. Particle code

$$\frac{\partial \mathbf{r}_n}{\partial t} = -\mathbf{v}_n \quad \mathbf{r} \equiv (x, y, z)$$

$$\frac{\partial \mathbf{v}_n}{\partial t} = \frac{q_n}{m_n} (\mathbf{E} + \mathbf{v}_n \times \mathbf{B})$$

ブラソフコード概要1:スキーム

- プラズマ物理からの制約

 - 保存性

 - 正值性

 - 無振動性 (新たな極値は発生しないが、既存の極値は保つ)

 - × TVDスキーム

- **メモリ消費量が少ない**

 - × 多段時間積分法 (e.g., R-K)

 - × マルチモーメント(マルチデータ)法 (e.g., CIP)

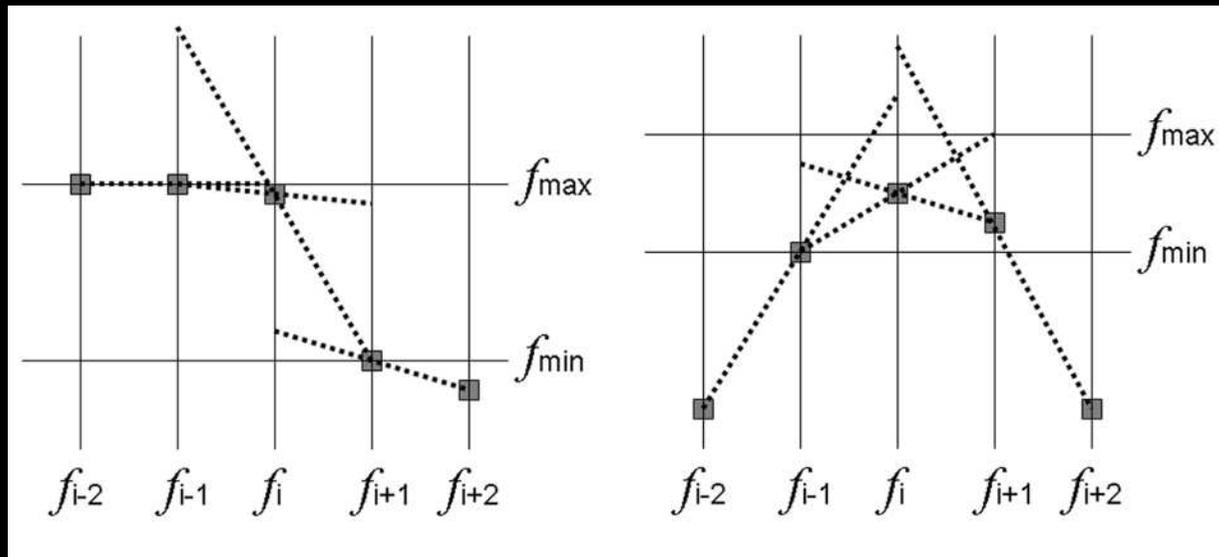
 - 高次補間

 - 高次・保存型セミラグランジュ法 + リミッタ

ブラソフコード概要 2: 無振動スキーム

$$\frac{\partial f}{\partial t} + V \frac{\partial f}{\partial x} = 0$$

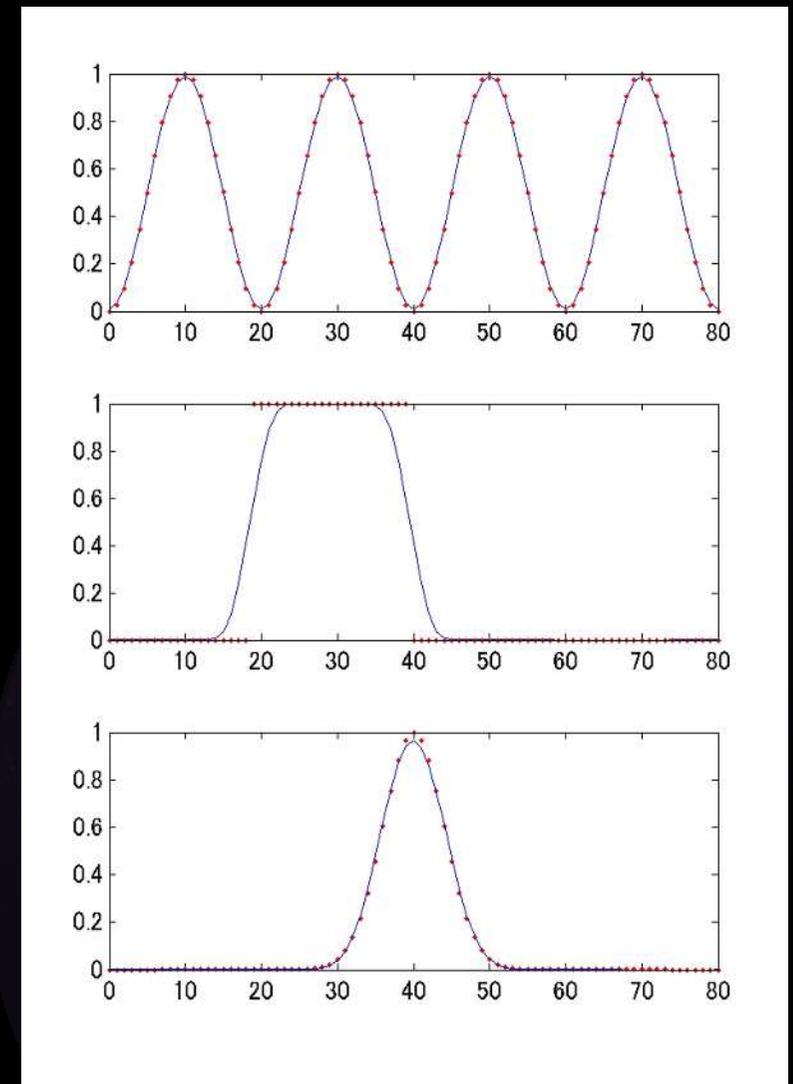
5次精度(保存型)ラグランジュ補間
+ “無振動”・正值性保証リミッタ



5点の情報から、不連続面(極大・極小)を
判定し、既存の極値を残す

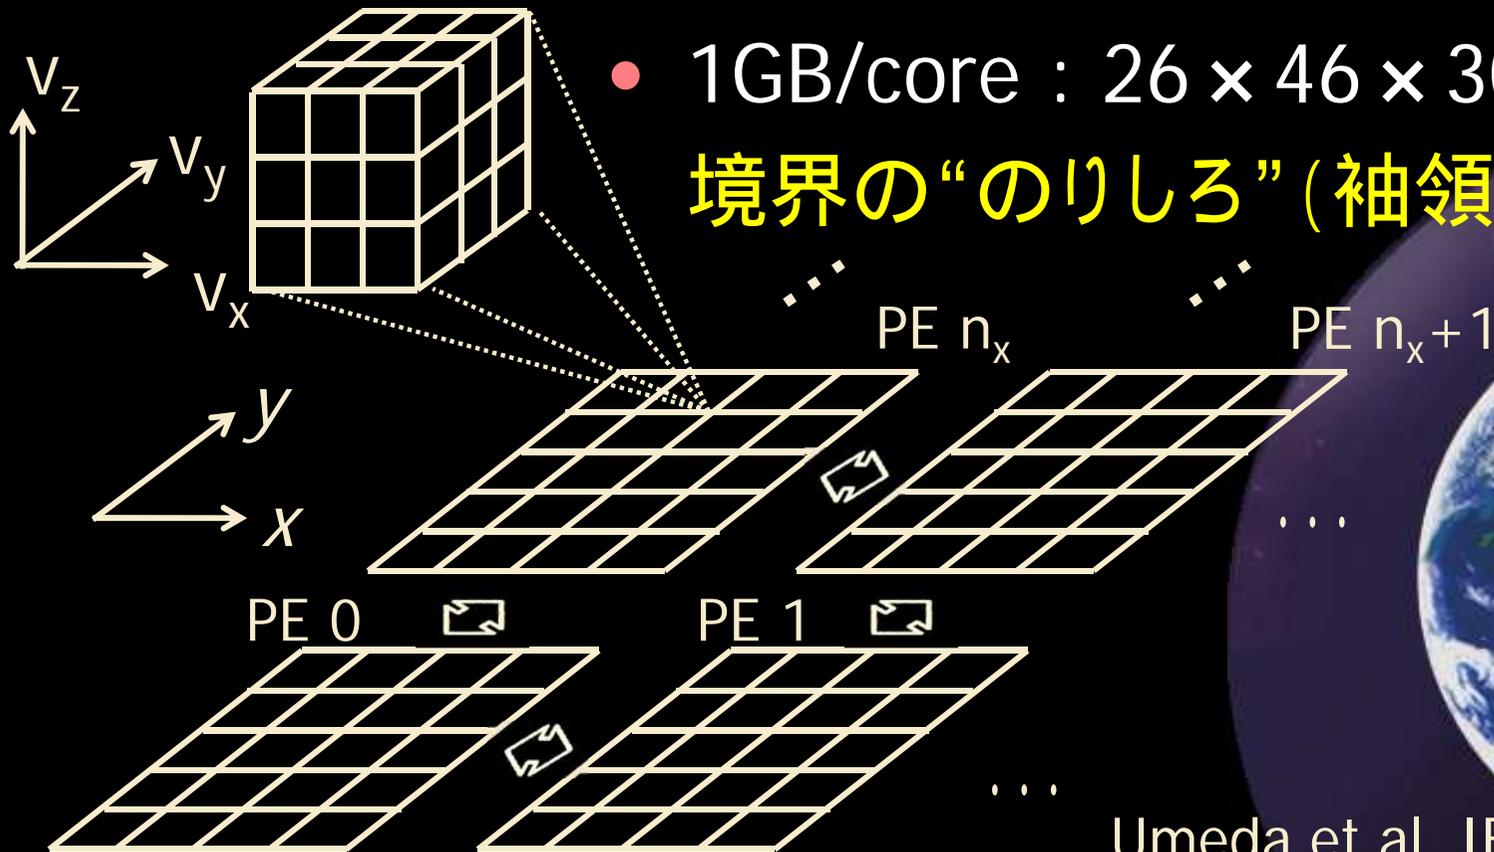
Umeda EPS 2008
Umeda et al. CPC 2012

Linear Advection Test:



ブラソフコード概要3: 並列化

- 実空間格子: MPI/OpenMP
 - 速度空間格子: OpenMP
- モーメント量 (J_x, J_y, J_z, ρ) の計算に reduction 処理が必要
- 1GB/core : $26 \times 46 \times 30 \times 30 \times 30$
境界の“のりしろ”(袖領域) は前後3点



ブラソフコード概要:まとめ

- ブラソフ方程式 (分布関数):
 - 自作の5次精度保存型・無振動スキーム
 - 通信: MPI_Sendrecv、のりしろ: 前後に3点
- マックスウェル方程式 (電磁場):
 - CG法 (陰解法)、だいたい30 iterationsで収束
 - 通信: MPI_Sendrecv、のりしろ: 前後に1点
MPI_Allreduce 収束レベルの確認
 - CPU負荷: 全体の0.1%以下
ただし、ノード数が増えると通信負荷が急増
- 粒子コードと比べて、ノイズレスかつ並列化が容易
ただし、必要メモリ量はケタ違いに多い

「京」でできること

- 20-30年先(実物大フル6次元計算)を踏まえつつ、今(京)でできることを考える。
- 小天体の低解像度6次元グローバルブラソフシミュレーション
 - ただし、ノードあたりのメモリが少ない「京」では、(16GB/node) 6次元コードは動作しない:30⁶~40GB
- 小天体の5次元(実空間2次元・速度空間3次元)高解像度グローバルブラソフシミュレーション
 - 低解像度計算は既に行った

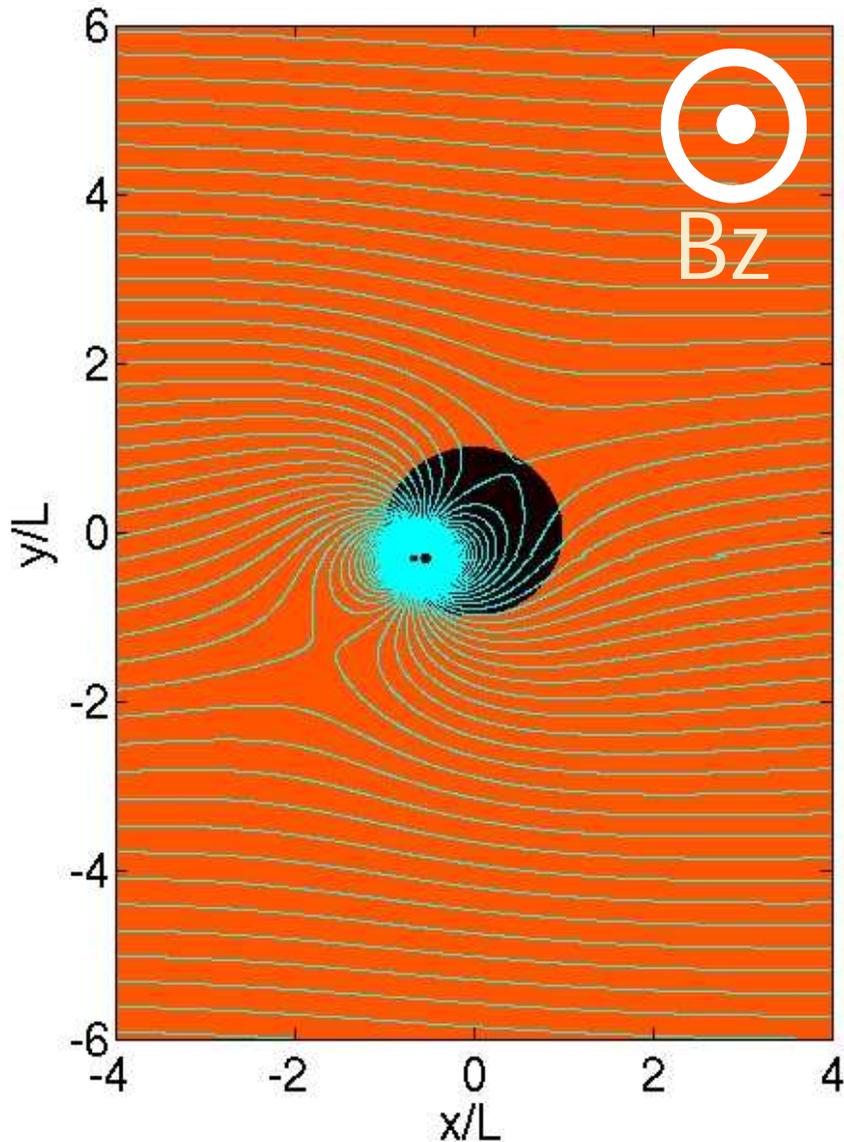
「京」による弱磁化小天体の5次元 “グローバル”ブラソフシミュレーション

	本研究	月
天体半径	2.72km	1738km
イオンジャイロ半径	1.36km	85km
イオンジャイロ周波数	9.36Hz	0.15Hz
マス比 m_i/m_e	25	1836
計算サイズ: ~50TB		~8GB/node
・Spatial grids: 1920 × 2560		20 × 40/node
・Velocity grids : 60 × 60 × 60		60 × 60 × 60/node
ノード数: 6144 (96 × 64)	全体の約14分の1	
FX10@東大では3072ノード必要		「京」でしかできない
時間ステップ数: 100,000 ($10/\Omega_{ci}$)		約100日

計算の途中結果：初期値

磁力線とイオン密度

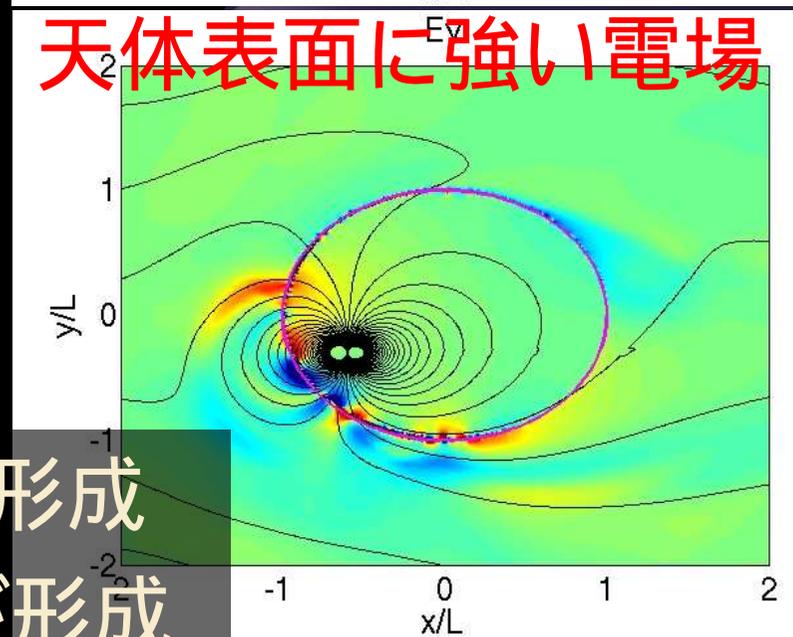
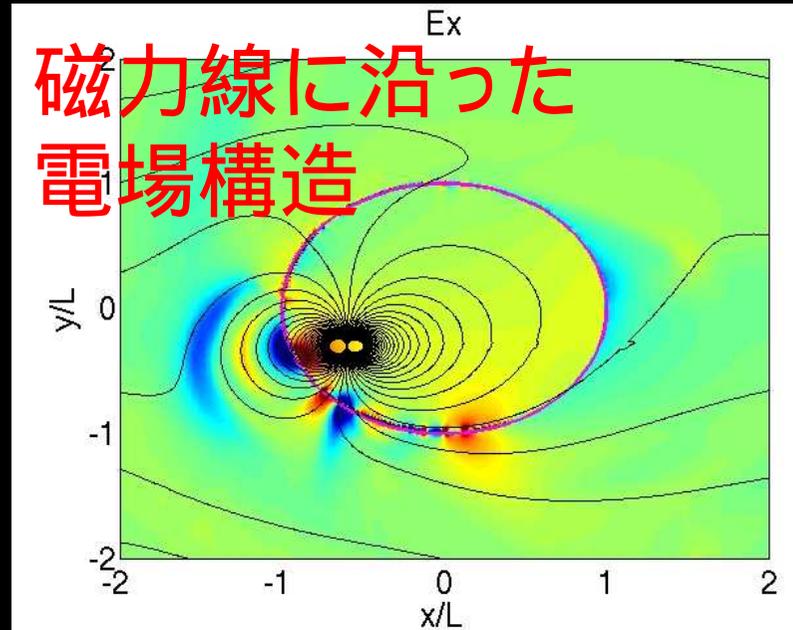
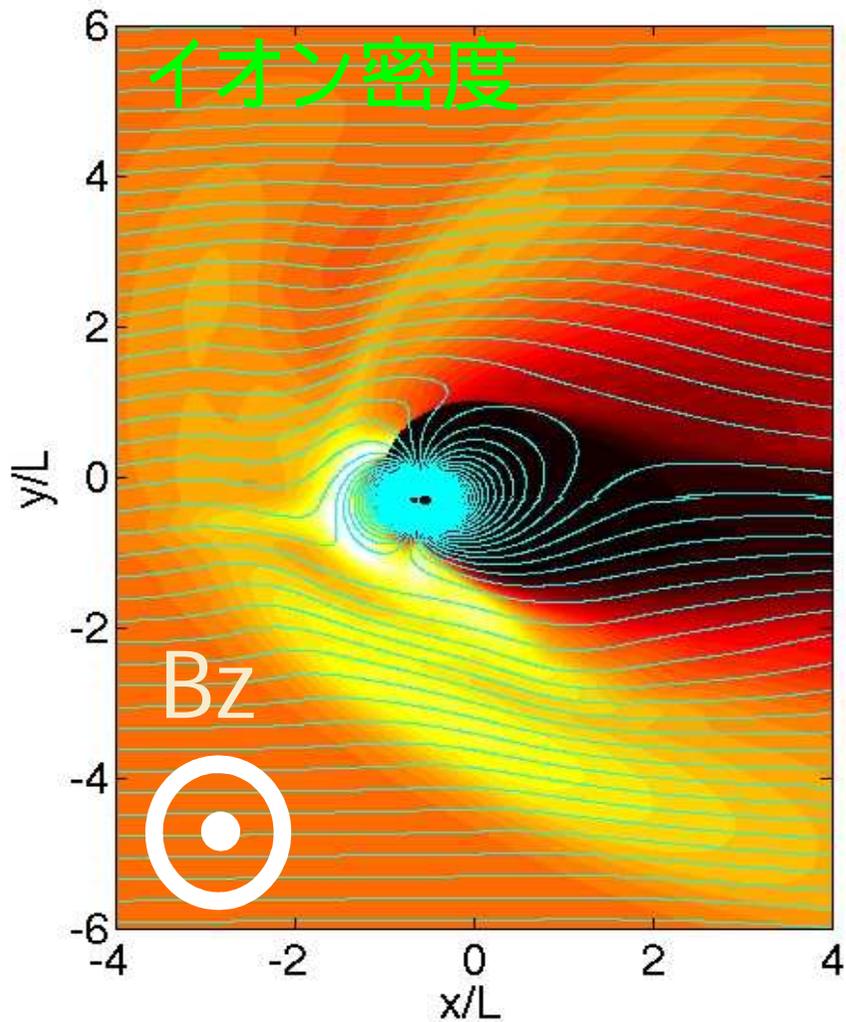
t = 0.0



- 昼側(左側)境界から太陽風プラズマが入射
- 昼側に弱いダイポール磁場を配置
- プラズマは天体表面に吸着、電磁波は透過
- 天体半径 = イオンジャイロ半径の2倍
- 昼側に、イオンジャイロ半径スケールの磁気圏(磁力線の閉じた領域)がある
- 夜側の磁力線は、基本的には開いている

計算の途中結果： $\omega_{ci}t=3.0$

t = 3.0



- 昼側に、高密度領域(衝撃波)が形成
- 夜側に、低密度領域(ウェイク)が形成

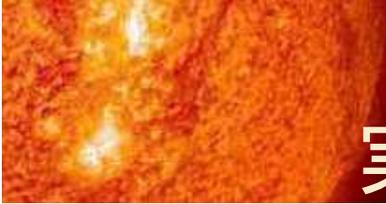
性能評価

- コアあたりのメモリ使用量を ~ 1GB
(26 x 46 x 30 x 30 x 30)
に固定した、弱いスケーリング
– 実際の計算に近い設定
- コンパイラオプション
 - FX10/K : `-Kfast,openmp,visimpact,simd=2 -x250`
 - FX1 : `-Kfast,OMP,impact -x250`
 - CX400 : `-Kfast,openmp,parallel,AVX -x250`
: `-ip -ipo -O3 -xAVX -openmp`

性能評価に用いたマシン

- 東京大学 HA8000 (H22/10/21実施)
- 名古屋大学 FX1 (H24/01/04実施)
- JAXA FX1 (H21/03/11実施)
- 東京大学 FX10 (H24/10/25実施)
- 九州大学 FX10 (H25/03/29実施)
- 九州大学 CX400 (H25/06/27実施)
- 理化学研究所 京 (H25/08/15実施)

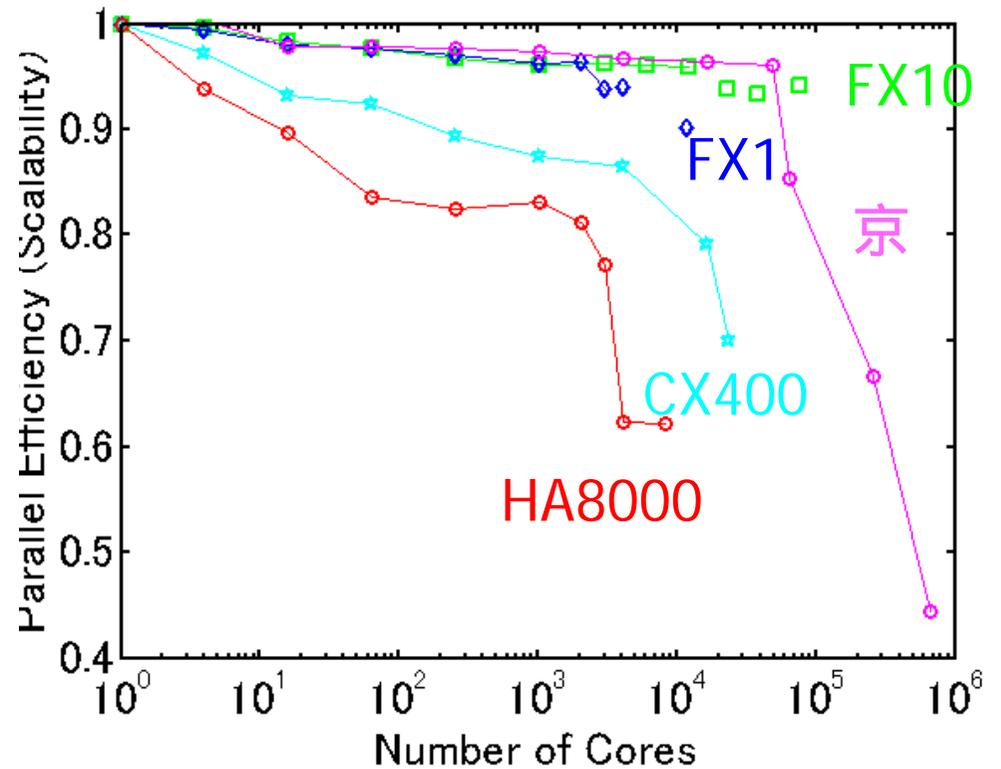
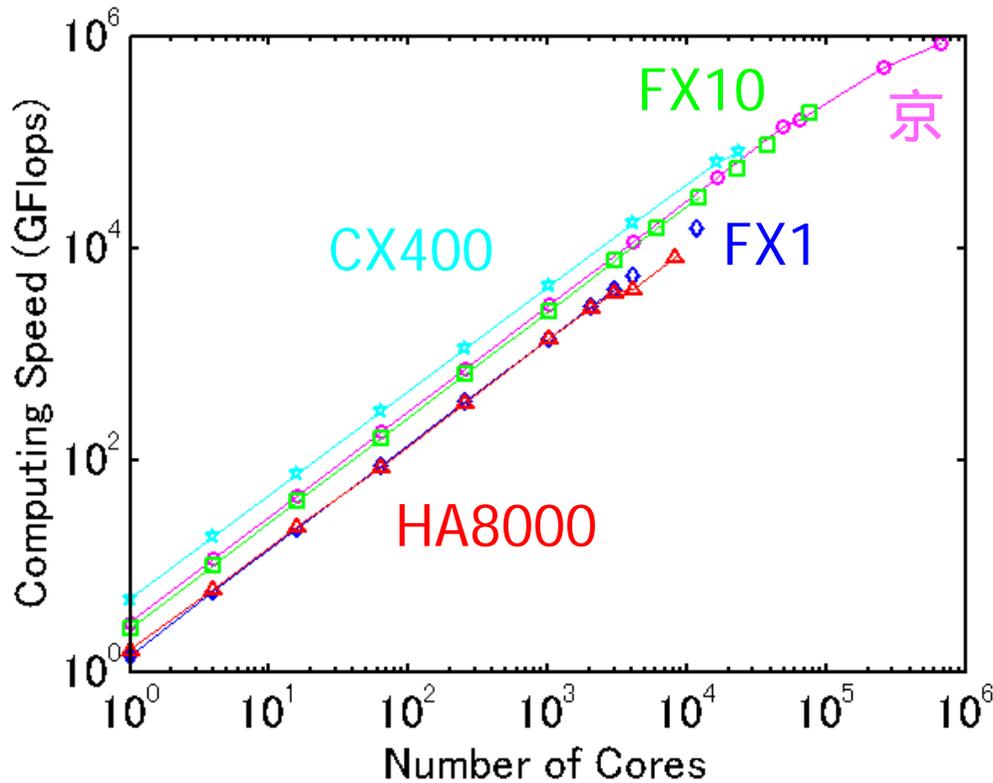




性能評価

実効速度

実効並列効率



HA8000(@東大、日立): 実効効率~14%

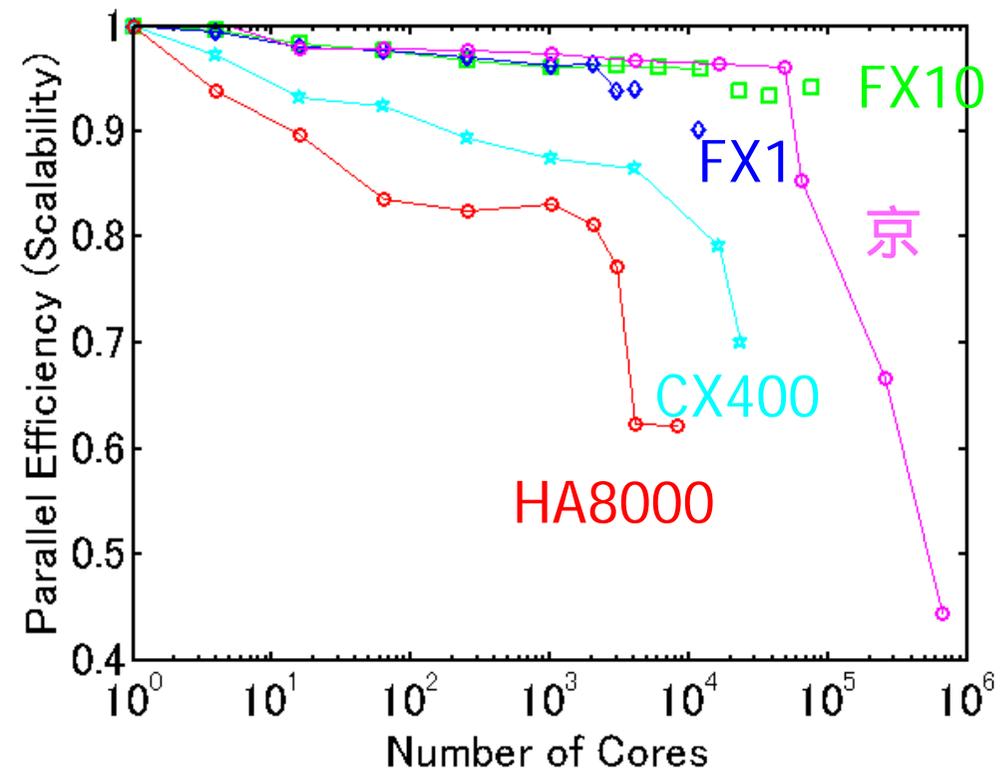
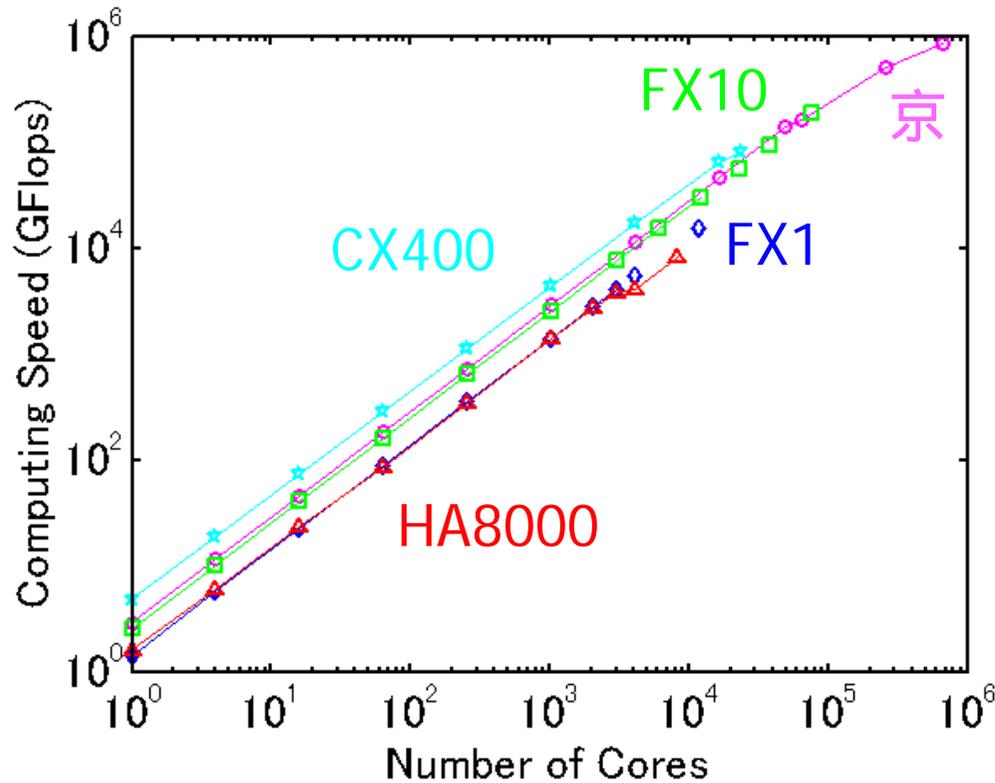
- 日立コンパイラ+フラットMPIが最速、ただしOpenMPがうまく動かなかった
- 256ノード(4096コア)以上で性能が低下、ただし512ノードと効率が変わらず ネットワークの飽和



実効速度

性能評価

実効並列効率



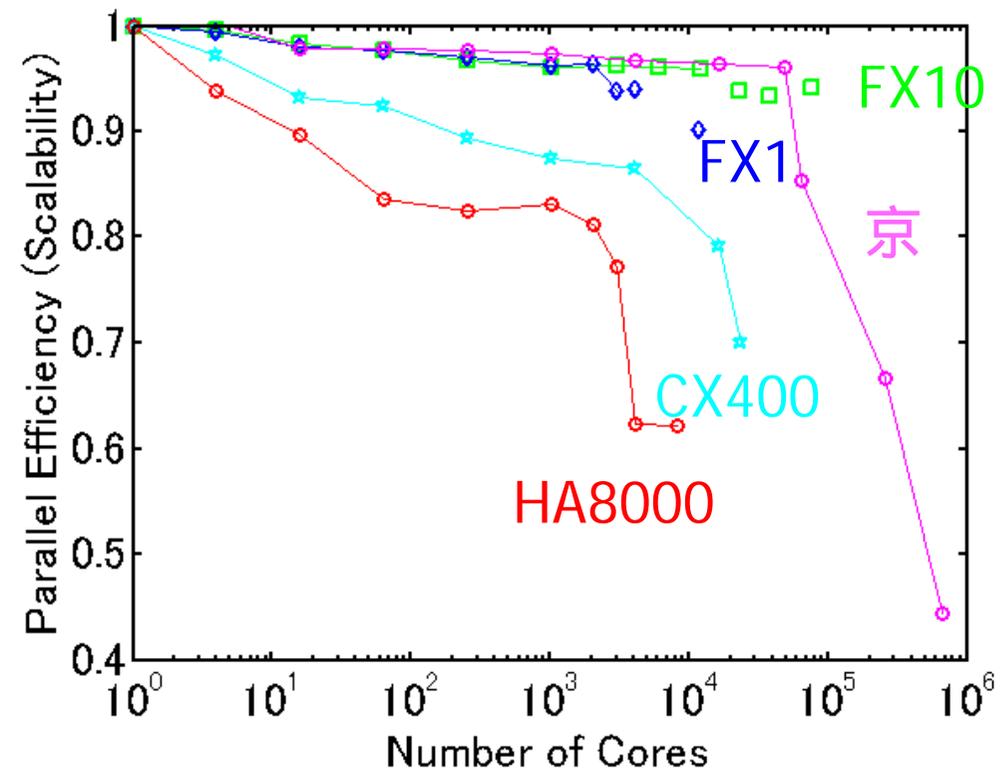
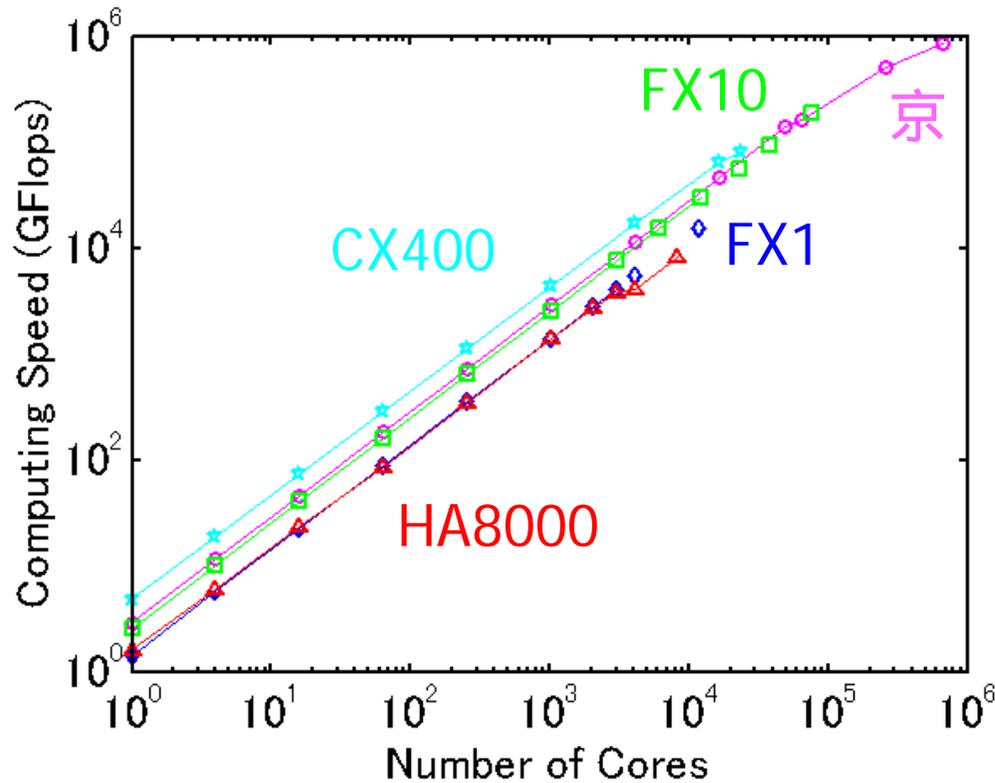
CX400@九大: 実効効率~21%

- Flat MPIが最速
- インテルコンパイラが富士通コンパイラよりも1.5倍高速
- 256ノード(4096コア)を超えると急激に性能が低下
ネットワークポロジの問題(全ノードFBBでない)

性能評価

実効速度

実効並列効率



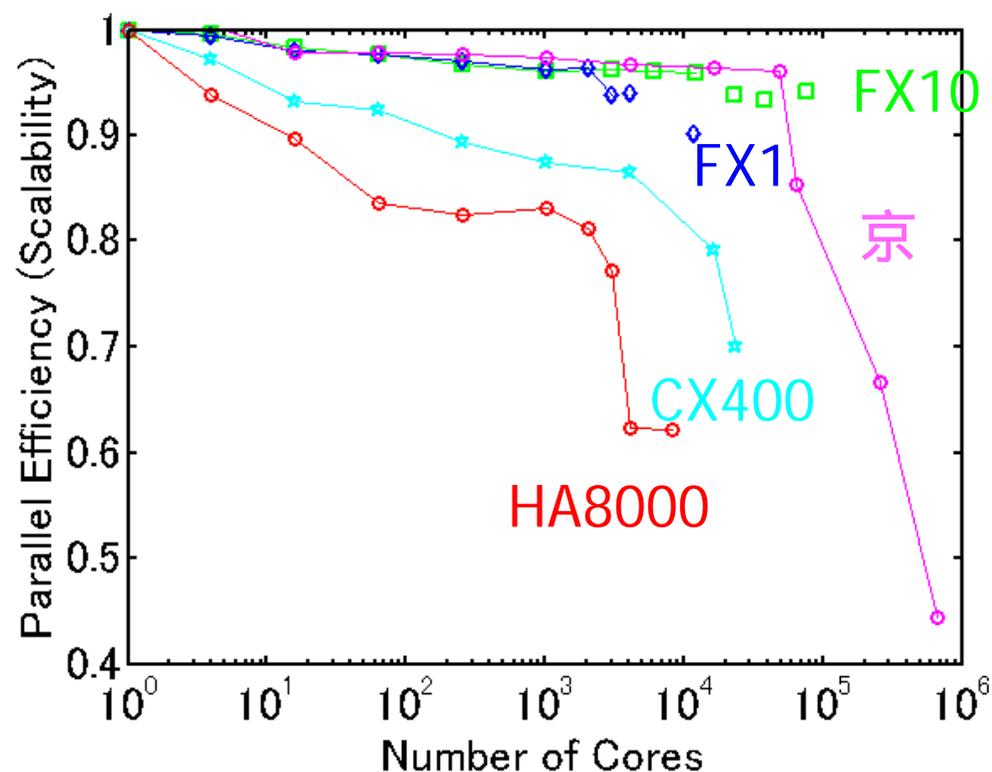
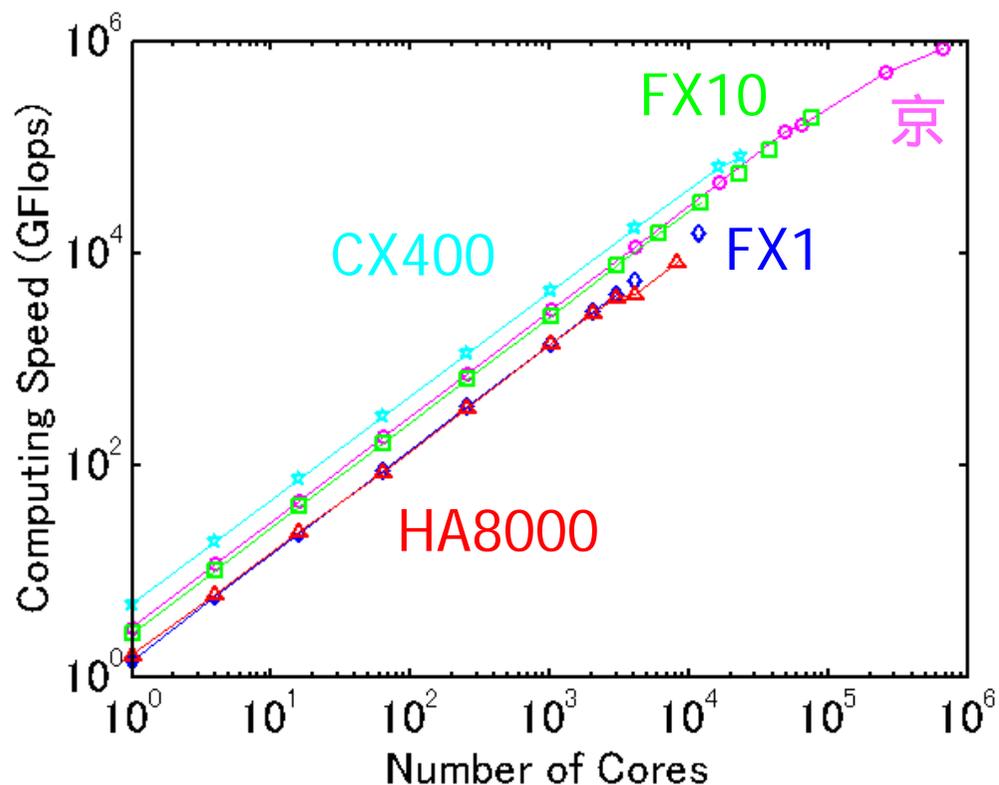
FX1@名大・JAXA : 実効効率~15%

- Flat MPIが若干ハイブリッド並列よりも速い
- 全ノードを使用した場合 (3008ノード@JAXA, 768ノード@名大) に、低下(実効効率~13%)

性能評価

実効速度

実効並列効率



FX10/京：実効効率~18%

- 2 or 4スレッドのハイブリッド並列が速い
- FX10では、4800ノード(76,800コア)まで性能を維持
- 京では、8192ノード(65,536コア)から急激に性能が低下
陰解法FDTDで使っているMPI_Allreduceの問題

性能チューニング

協力:SS研マルチコアクラスタ性能WG、富士通関係者様

- As-is コード: Xeon(Woodcrest-Nehalem)で開発
 - 768ノード@FX1(名大)で実効効率13%
 - 512ノード@HA8000(東大)で実効効率11%
 - ノード数があまり多くないOpteronで実効効率14~15%
 - ノード数があまり多くないXeon(Westmere)で実効効率20%
- FX10にそのまま移植すると...
 - 1440ノード@FX10(東大)で実効効率11%
 - 全ノード(4800ノード)計測に失敗

性能チューニング

- 配列のマージ

```
real(kind=8)::ax(ix,iy,iz),ay(ix,iy,iz),az(ix,iy,iz)
```

Type A

```
real(kind=8) :: array(ix,iy,iz,3)
#define array(i,j,k,1) ax(i,j,k)
#define array(i,j,k,2) ay(i,j,k)
#define array(i,j,k,3) az(i,j,k)
```

Type B

```
real(kind=8) :: array(3,ix,iy,iz)
#define array(1,i,j,k) ax(i,j,k)
#define array(2,i,j,k) ay(i,j,k)
#define array(3,i,j,k) az(i,j,k)
```

配列 ax,ay,az に対して連続的、i,j,kに対してストライド

性能チューニング

- Type A `array(i, j, k, 3)`
 - 配列アクセスのSIMD化を促進
 - 1次元目のサイズに注意
 - 2のn乗付近でパディングが必要
- Type B `array(3, i, j, k)`
 - ストリーム数 (配列(ax, ay, az)へのアクセス命令数) が減るが、SIMD化は無し
 - パディング不要
 - キャッシュデータの再利用性に注意
- **どちらが速いか、全ての配列について試す！**

性能チューニング

```
do nn=2,nvzp1
  uz1=vz(nn,ss)
  do mm=1,nvyp1
    uy1=vy(mm,ss)
    do ll=2,nvxp1
      ux1=vx(ll,ss)

      vv =ux1*bbx+uy1*bby+uz1*bbz
      mv =sign(1.0d0,vv)
      mp0=mm-floor(vv)
      mp2=min(max(mp0+mv+mv,1),nvyp2)
      mp1=min(max(mp0+mv,1),nvyp2)
      mm1=min(max(mp0-mv,1),nvyp2)
      mm2=min(max(mp0-mv-mv,1),nvyp2)

      hp2=ff(ll,mp2,nn,ii,jj,ss)
      hp1=ff(ll,mp1,nn,ii,jj,ss)
      hp0=ff(ll,mp0,nn,ii,jj,ss)
      hm1=ff(ll,mm1,nn,ii,jj,ss)
      hm2=ff(ll,mm2,nn,ii,jj,ss)
      dfy(ll,mm)=flux(hp2,hp1,hp0,hm1,hm2,vv)
    end do
  end do
end do
```

As-isコード:

FX1,RX200でチューニング済
実効効率:13%, 20%

ループ内で複数の組み込み
関数とユーザ定義関数を
呼ぶ

外側にさらに3重ループ

性能チューニング

```
do mm=1,nvyp1
  uy1=vy(mm,ss)
  do ll=2,nvxp1
    ux1=vx(ll,ss)
    vv(ll,mm) =ux1*bbx+uy1*bby+uz1*bbz
    mv =sign(1.0d0,vv(ll,mm))
    mp0(ll,mm)=mm-floor(vv(ll,mm))
    mp2(ll,mm)=min(max(mp0+mv+mv,1),nvyp2)
    mp1(ll,mm)=min(max(mp0+mv,1),nvyp2)
    mm1(ll,mm)=min(max(mp0-mv,1),nvyp2)
    mm2(ll,mm)=min(max(mp0-mv-mv,1),nvyp2)
  end do
end do
do mm=1,nvyp1
  do ll=2,nvxp1
    hp2=ff(ll,mp2(ll,mm),nn,ii,jj,ss)
    hp1=ff(ll,mp1(ll,mm),nn,ii,jj,ss)
    hp0=ff(ll,mp0(ll,mm),nn,ii,jj,ss)
    hm1=ff(ll,mm1(ll,mm),nn,ii,jj,ss)
    hm2=ff(ll,mm2(ll,mm),nn,ii,jj,ss)
    dfy(ll,mm)=flux(hp2,hp1,hp0,hm1,hm2,vv(ll,mm))
  end do
end do
```

ループを分割
floorとfluxを分ける

データ受け渡し用配列は
2次元

(1次元より若干速い
3次元にするとかなり遅くなる)

CX400とFX1で実効効率が1%向上
(FX10/京は0.5%向上)

性能チューニング

```
do mm=1,nvyp1
  uy1=vy(mm,ss)
  do ll=2,nvxp1
    ux1=vx(ll,ss)

    vv(ll,mm)=ux1*bbx+uy1*bby+uz1*bbz
    sv=sign(1.0d0,vv(ll,mm))
    mp0(ll,mm)=mm-floor(vv(ll,mm))
    wmp0=mp0(ll,mm)
    wnvyp2=nvyp2
    mp2(ll,mm)=min(max(wmp0+sv+sv,1.0d0),wnvyp2)
    mp1(ll,mm)=min(max(wmp0+sv,1.0d0),wnvyp2)
    mm1(ll,mm)=min(max(wmp0-sv,1.0d0),wnvyp2)
    mm2(ll,mm)=min(max(wmp0-sv-sv,1.0d0),wnvyp2)
  end do
end do
```

max, min を整数から
倍精度実数演算に変更

CX400とFX1: 型変換の演算が増えたため、
実効効率が1%低下

FX10と京: 実効効率が**3%向上!!** (~18%)

“特殊系”チューニング(整数関数が遅すぎる...)

「一般ユーザ」として 京を使ってみて...

- 待ち時間が長い...
 - 他のシステムだと、全リソースの10分の1以下なら1日待ちぐらいで走る
- 大量ファイル操作のストレス
6万個のデータファイルと2万個のリスタート用ファイル
フロントエンドがIsで固まる...
- 市販の(非並列)ソフトウェアを用いると、図を描くだけでかなり時間がかかる
(ある物理量 + 磁力線の図で3時間)

今後：6次元計算

- $40^3 \times 40^3 \sim 160\text{GB}$
- $30^3 \times 30^3 \sim 40\text{GB}$
- $20^3 \times 40^3 \sim 20\text{GB}$ -32GBで動くサイズ

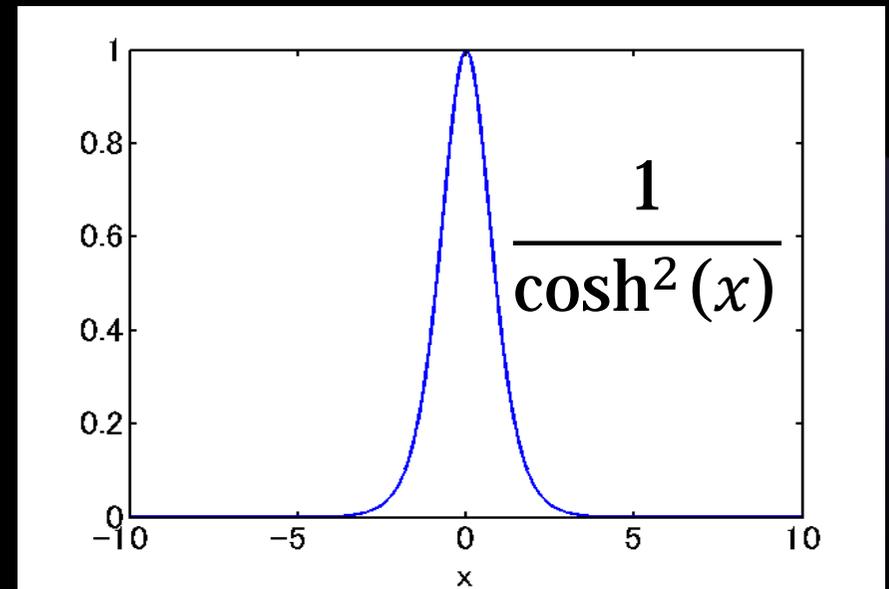
このサイズをどうノード内並列するか??

- **既存の**ノード内スレッド並列(ループ1次元のみをOpenMP/自動並列)では、メニーコア環境(>32スレッド??)に対応できない
ノード内スレッド+ノード間MPIのハイブリッド並列は不可

大規模計算ならではの 「これは困った」

- 引数が大きくなって関数がオーバーフローする
- (コンパイラ)オーバーフローの回避
 - 既にオプション有あり?

- x 大
- $\cosh^2(x)$ NaN (1.0E+300)
- $1/\cosh^2(x)$ もNaN
- インテルCPUだと、 $\cosh^2(x)$ Inf
(富士通コンパイラでも) $1/\text{Inf}$ 0.0



6次元計算に向けて

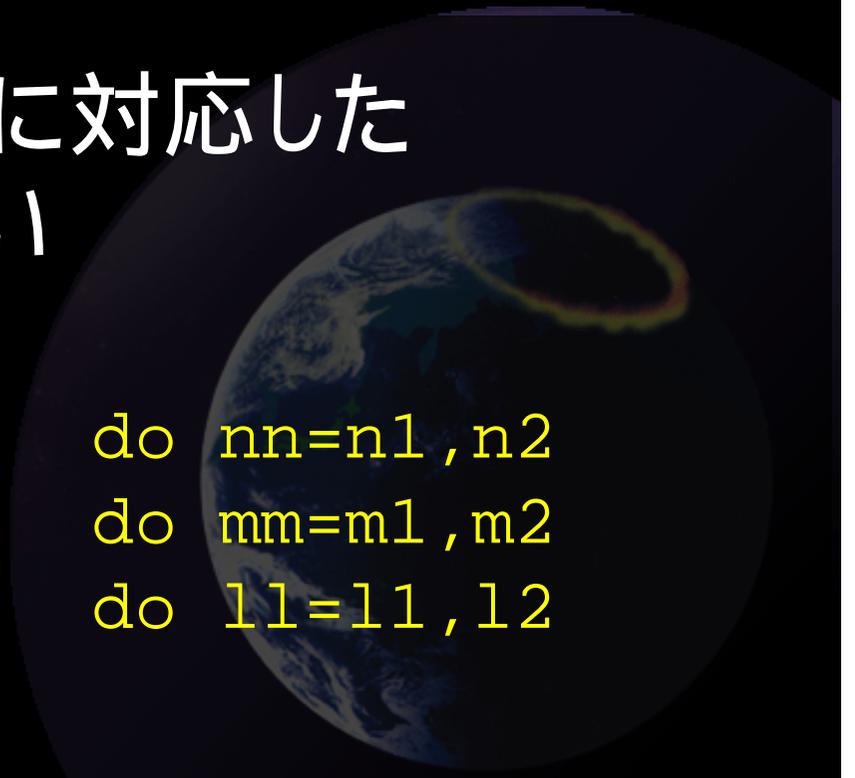
- (ハード) ノード内共有メモリはある程度欲しい
 - プロセス数(ノード間通信量)を減らす
 - ループ長を伸ばす
 - データファイル数を減らす
- (コンパイラ) 多次元ループに対応したスレッド並列化機能が欲しい

```
do nn=1, 30  
do mm=1, 30  
do ll=1, 30
```



```
do nn=n1, n2  
do mm=1, 30  
do ll=1, 30
```

```
do nn=n1, n2  
do mm=m1, m2  
do ll=l1, l2
```



6次元計算に向けて

- 1変数あたり数千ファイルのデータ解析処理が思った以上に大変...
 - 市販の解析ソフト(非並列)で、1つの図を描くの
に数時間...
プロセス数をできるだけ減らしたい
- (フリーな)分散データ解析環境？

Data01~Data64

Data129~Data192



Data65~Data128

Data193~Data256

Group1

Group2

Group3

Group4

まとめ

- 20～30年後の地球磁気圏の第一原理6次元シミュレーションに向けて、「京」を用いた5次元シミュレーションを実行中
- 既存のハード・コンパイラ・データ解析環境の延長では、エクサでさえ厳しい...
 - － ノード内メモリの増加
 - － 多次元ループのスレッド化
 - － 大量ファイルのデータ解析処理
プロセス数はできるだけ減らしたい

