

ABINIT-MP



FMOプログラムABINIT-MPの高速化と 超大規模系への対応

望月祐志^{1,2} (課題責任者)

中野達也³、坂倉耕太⁴、渡邊啓正⁵、秋澤和輝¹

片桐孝洋⁶、大島聡史⁶、山梨祥平⁶、森下誠⁶

1:立教大、2:東大生研、3:国立衛研、4:FOCUS

5:HPCシステムズ、6:名大

謝辞:SS研「A64FXシステムアプリ性能検討WG」の活動とも連携しています


フラグメント分子軌道 (FMO) 法

◇巨大分子系

生体高分子や凝集系では一般的

⇒ タンパク質、DNA (水和状態)

数千～数万原子、数千～数十万軌道



【HIVプロテアーゼとロピナビル】

◇分割&統合系のアプローチの一つ

北浦らが20年前に2体展開で提案

⇒ フラグメントとその対で系のエネルギーを評価 (FMO2)

⇒ **環境静電ポテンシャル (ESP)**、直接結合切断 (BDA)


⇒ 階層的な並列処理 (フラグメントリスト&内部処理)

⇒ 電子相関の導入、分子構造の最適化も可能


フラグメント間の相互作用エネルギー (**IFIE**)

⇒ **計算対象の解析ツール**

⇒ 創薬設計には好適



モノマー (アミノ酸単位など)



ダイマー

FMO計算のためのプログラム

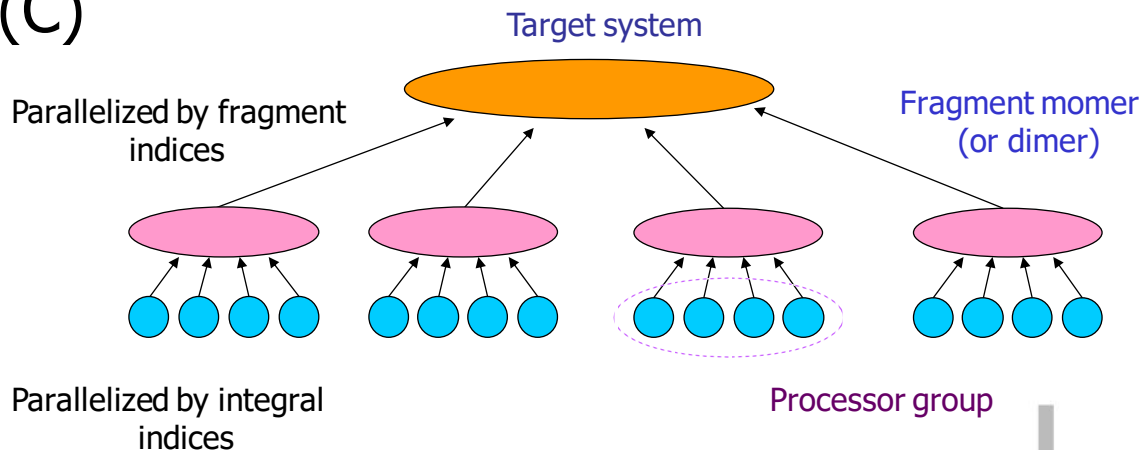
◇GAMESS-US [米国Gordonグループ]; Fedorov、北浦、中田ら
GAUSSIANに抗し得る有力なフリーソフト、世界規模 (Fortran)
⇒ 様々な計算機能をFMO化、GDDI並列

◇ABINIT-MP; 望月、中野ら
実用機能は十分、東大系PJ・CREST-PJなどで開発 (Fortran)
⇒ IOレス、MPI/OpenMP並列、4体展開FMO、専用GUI

◇PAICS; 石川
FMO-MP2(RI)に特化 (C)
⇒ MPI並列

◇OpenFMO; 稲富ら
FMO-HFのみ (C)
⇒ 超並列指向

2階層の並列処理で計算資源を有効利用



ABINIT-MPの主な機能（オープンシリーズとして整備中）

<http://www.cenav.org/abinitmpopen1/>

保護されていない通信 | cenav.org/abinit-mp-open_ver-1-rev-22/

計算工学ナビ

ものづくりにHPCを活用するためのツールとケーススタディー

ログイン 検索

レポート ニュース 解析事例データベース ライブラリ Q&A コミュニティ

ABINIT-MP Openシリーズ (Ver.1 Rev.22)

※2019年3月版(Ver.1 Rev.15)に関するページはこちらです

はじめに

ABINIT-MPは、フラグメント分子軌道（FMO）計算を高速に行えるソフトウェアです[1]。専用GUIのBioStation Viewerとの連携により、入力データの作成～計算結果の解析が容易に行えます。4体フラグメント展開（FMO4）による2次摂動計算も可能です。また、部分構造最適化や分子動力学の機能もあります。FMOエネルギー計算では、小規模のサーバから超並列スパコンまで対応しています（Flat MPIとOpenMP/MPI混成）。

[1]"Electron-correlated fragment-molecular-orbital calculations for biomolecular and nano systems", S. Tanaka, Y. Mochizuki, Y. Komeiji, Y. Okiyama, K. Fukuzawa, Phys. Chem. Chem. Phys. 16 (2014) 10310-10344.

Open Ver. 1（ポスト「京」のPJで整備）

- ・Rev. 5 (2016年12月)
- ・Rev. 10 (2018年2月)
- ・Rev. 15 (2019年3月)
- ・Rev. 22 (2020年6月); 当面は併存

Open Ver. 2（「富岳」の時代に移行）

- ・Rev. 5 (2021年7月予定)

・エネルギー

- FMO4: HF, MP2
- FMO2: HF~CCSD(T), LRD
- FMO2: CIS/CIS(D)

・エネルギー微分

- FMO4: HF, MP2
- FMO2: MP2構造最適化, MD

・その他機能

- SCIFIE, PB, sp2-BDA, $\alpha(\omega)$
- 電子密度生成, CAFI, FILM

・並列化環境(PC~スパコン)

- MPI, OpenMP/MPI混成
- 最深部はBLAS処理

基本のHF計算

$$\mathbf{F}^x \mathbf{C}^x = \mathbf{S}^x \mathbf{C}^x \boldsymbol{\varepsilon}^x \quad \mathbf{F}^x = \mathbf{H}^x + \mathbf{G}^x \quad \Leftrightarrow \text{HFの一般化固有値問題 (要反復計算)}$$

$$H_{\mu\nu}^x = H_{\mu\nu}^{\text{core } x} + V_{\mu\nu}^x + \sum_k B_k \langle \mu | \theta_k \rangle \langle \theta_k | \nu \rangle \quad V_{\mu\nu}^x = \sum_{K \neq x} (u_{\mu\nu}^K + v_{\mu\nu}^K) \quad \Leftrightarrow \text{1電子部分の修飾}$$

$$u_{\mu\nu}^K = \sum_{A \in K} \langle \mu | (-Z_A / |\mathbf{r} - \mathbf{A}|) | \nu \rangle \quad v_{\mu\nu}^K = \sum_{\lambda\sigma \in K} P_{\lambda\sigma}^K (\mu\nu | \lambda\sigma) \quad \Leftrightarrow \text{環境静電ポテンシャル (ESP)}$$

$$P_{\mu\nu} = 2 \sum_{i=1}^{\text{occ}} C_{\mu i}^* C_{\nu i} \quad G_{\mu\nu}^x = \sum_{\lambda\sigma \in x} P_{\lambda\sigma}^x \left[(\mu\nu | \lambda\sigma) - \frac{1}{2} (\mu\sigma | \lambda\nu) \right] \quad \Leftrightarrow \text{2電子部分 (N}^4\text{) (並列処理)}$$

高速化のための幾つかの工夫


$$V_{\mu\nu}^L \cong \sum_{\lambda \in L} (\mathbf{P}^L \mathbf{S}^L)_{\lambda\lambda} (\mu\nu | \lambda\lambda) \quad \text{for } R_{\min}(X, L) \geq L_{\text{aoc}} \quad \Leftrightarrow \text{ESP-AOC近似 (実用精度高し)}$$

$$V_{\mu\nu}^L \cong \sum_{A \in L} \langle \mu | (Q_A / |\mathbf{r} - \mathbf{A}|) | \nu \rangle \quad \text{for } R_{\min}(X, L) \geq L_{\text{ptc}} \quad Q_A = \sum_{\lambda \in A} (\mathbf{P}^L \mathbf{S}^L)_{\lambda\lambda} \quad \Leftrightarrow \text{ESP-PTC近似 (速い)}$$

$$E'_{IJ} \cong E'_I + E'_J + \text{Tr}(\mathbf{P}^I \mathbf{u}^J) + \text{Tr}(\mathbf{P}^J \mathbf{u}^I) + \sum_{\mu\nu \in I} \sum_{\lambda\sigma \in J} \mathbf{P}_{\mu\nu}^I \mathbf{P}_{\lambda\sigma}^J (\mu\nu | \lambda\sigma) \quad \Leftrightarrow \text{Dimer-ES近似 (HF計算無)}$$

種々の工夫により、FMO2の計算コストのシステムサイズ依存性は2乗より低い

MP2エネルギー計算 (ABINIT-MPの実装)



$$E^{MP2} = \sum_{ijab} \frac{(ia | jb)(2(ia | jb) - (ib | ja))}{\varepsilon_i + \varepsilon_j - \varepsilon_a - \varepsilon_b}$$

$$(ia | jb) = \sum_{\mu\nu\lambda\sigma} C_{\mu i} C_{\nu a} C_{\lambda j} C_{\sigma b} (\mu\nu | \lambda\sigma)$$

(基底関数の添字から変換)

Loop over *ij*-batch ! size depending on available memory

Loop over σ ! to be parallelized

Loop over λ

Preparing $(\mu\nu | \lambda\sigma)$! for canonical $\mu\nu$ -pair

Forming $(i\nu | \lambda\sigma)$! **DGEMM**, fixed $\lambda\sigma$, running over μ

Forming $(ia | \lambda\sigma)$! **DGEMM**, fixed $\lambda\sigma$, running over ν

Forming $(ia | j\sigma)$! **DGEMM**, fixed σ , direct-product for fixed λ

End of loop over λ

Forming $(ia | jb)$! **DGEMM**, direct-product for fixed σ

End of loop over σ ! all-reduce operation as barrier

Calculate partial MP2 energy with respect to *ij*-batch

End of loop over *ij*-batch

$$(i\nu | \lambda\sigma) = \sum_{\mu} C_{\mu i} (\mu\nu | \lambda\sigma)$$

$$(ia | \lambda\sigma) = \sum_{\nu} C_{\nu a} (i\nu | \lambda\sigma)$$

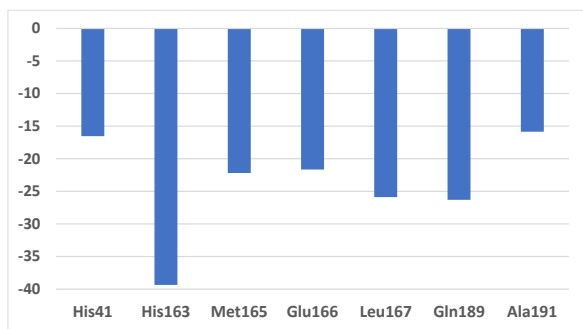


$$(ia | j\sigma) = \sum_{\lambda} C_{\lambda j} (ia | \lambda\sigma)$$

$$(ia | jb) = \sum_{\sigma} C_{\sigma b} (ia | j\sigma)$$

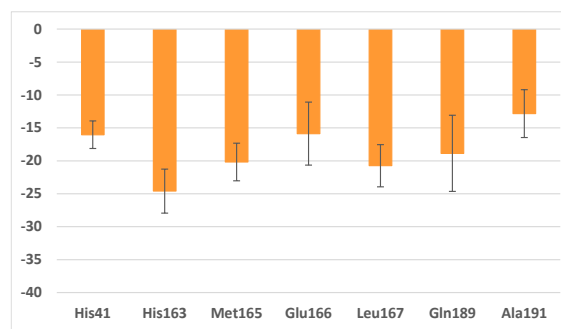

(DGEMMは行列積ルーチン)

DEGMMを使わず、閾値判定でDAXPYを使うことも可能(1段目、3段目)

20年度の「富岳」利用のCOVID-19特別PJでの成果例



揺らぎ無しIFIE (結晶構造)



揺らぎありIFIE (生体環境)

「富岳」の威力：0.6時間/1構造、100並列で1000構造が総計5時間

21年度のjh210036-NAHでの実施内容と現状(6月)

■ ABINIT-MP関係(「不老」Type Iサブシステム)

- ・ 超大規模系対応: 1万超フラグメントのMP2ジョブの実現
 - 「不要な配列」の削除 (BioStation Viewerとの互換性は保留)
 - 「不要なプリント」の抑制
 - ⇒ 1.1万フラグメントのMP2/cc-pVDZ計算を達成 (1ラック)
 - ⇒ MP2は全段DGEMM処理がベター (10%程度速い)
- ・ 高速化: 2電子積分生成が全体の1/2のコスト、HF処理が1/4
 - 積分ルーチンのSIMD化 (小原式アルゴリズムでタイプが多数)
 - Fock行列の加算処理の改良
 - ⇒ 高速化は積分生成で17%、Fock行列構築で30%の速度向上

■ 機械学習関係(「不老」Type IIサブシステム)

- ・ 画像処理データの準備
 - 可視化IFIEデータの深層学習
 - タンパク質の基本構造の判定 (α ヘリックス、 β シートの存在)
 - ⇒ TensorFlowを使った先行事例の「再訪」に向けて準備中

超大規模系への対応 (Ver.2 Rev.2:暫定版)

- ・「不老」の1ラック、1プロセス/1ノードで実行
- ・インフルHA+Fab抗体 × 2 (PDB id: 1KEN) の水和モデル
- ・Dimer-ESの遠領域 (Ldimer>5) は多重極展開で近似
- ・フラグメント総数は11307、MP2/cc-pVDZジョブ、9.2時間
- ・基本スケーリングは良好、多ラック使用で加速の見込み

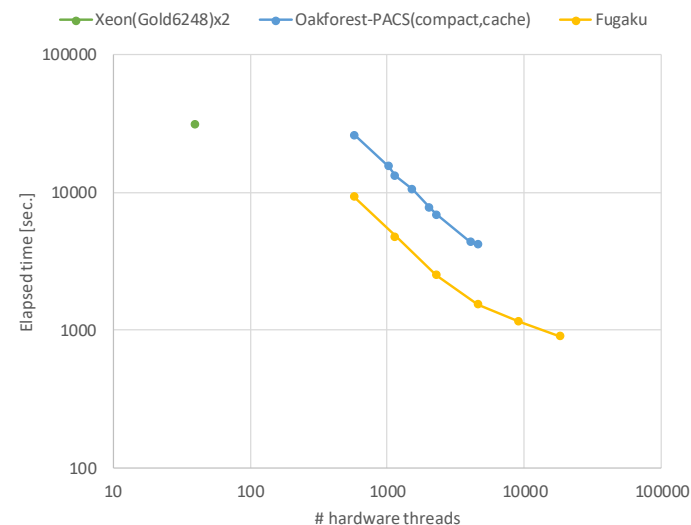
== ## TIME PROFILE ==

Elapsed time: Monomer SCF	=	14546.6 seconds
Elapsed time: Monomer MP2	=	32.5 seconds
Elapsed time: Monomer (Total)	=	14741.5 seconds
Elapsed time: Dimer ES	=	4021.8 seconds
Elapsed time: Dimer SCF	=	7215.9 seconds
Elapsed time: Dimer MP2	=	2492.4 seconds
Elapsed time: Dimer (Total)	=	18240.6 seconds
Elapsed time: FMO (Total)	=	32982.1 seconds


Time profile

Number of cores (total)	=	384
Number of cores (fragment)	=	1
THREADS (FRAGMENT)	=	48
Total time =		33120.9 seconds

6LU7 - FMO2-MP2/6-31G* - Elapsed time



スケーリング性能の例




1KEN水和モデル

FMO-MP2計算のコスト分析(Ver.1 Rev.22)

・Ala₉GlyのFMO-MP2/6-31G*のテストジョブ
・12スレッド8プロセス(2ノード実行:FX1000)

■ プログラム全体のコスト分布

- 基本プロファイラによるプロセス0番、スレッド0番のコスト分布
- 2電子積分処理が全体の約半分を占める
ただし、81種の処理の総和であるため、
1種あたりのコストは1%前後と非常に小さい
- 通信に関連したコストは8%程度と小さい
- 性能改善に向けたソース分析は以下を対象とする
 - 2電子積分
 - Direct SCF
 - リスト作成



2電子積分 : 81種のサブルーチン(sub_*)のコスト総和
Direct SCF : サブルーチンdirect_scf_gmatのコスト
リスト作成 : 3種のサブルーチン(get_tei_rs_fix, get_tei_pq_fix, get_ixijcs_to_proc_pqfix)のコスト総和
通信関連 : 通信に関連した処理(putofu_*, opal_*, mca_*)のコスト総和
システム関連 : ライブラリやOSなどに関連した処理のコスト総和
その他 : 上記以外の処理の総和

改善の方向性(積分の生成)

- 改良指針(井上G@富士通の助言)
 - OCL指示詞の導入によるSIMD化の促進、一部スカラ変数化も必要
 - コンパイラオプションの変更
- リファレンス
 - オリジナルコード、Ala₉GlyのMP2ジョブ
 - コンパイラオプション: -O3 -Knosimd -Koptmsg=2 -V
 - 6-31G*//cc-pVZ: 153.0s/134.5s//337.4s/306.1s (MP2;AXPY/GEMM)
- 手動での最適化と結果
 - オリジナルコード + ssss, psss, spss, ssps, sssp, ppss, psp, pssp, spp, spsp, sspp, dsss, sdss, ssds, sssd (スカラ変数化)
 - OCL指示詞の追加
 - コンパイラオプション: -O3 -Knosimd -Kocl
 - 6-31G*//cc-pVZ: 142.5s/124.5s(7.4%)//294.4s/254.0s(17.0%)
(cc-pVDZの場合、オリジナルコードと比較して全体で**17.0%**の高速化)
(kfastオプションの指定によってさらに高速化される可能性あり)



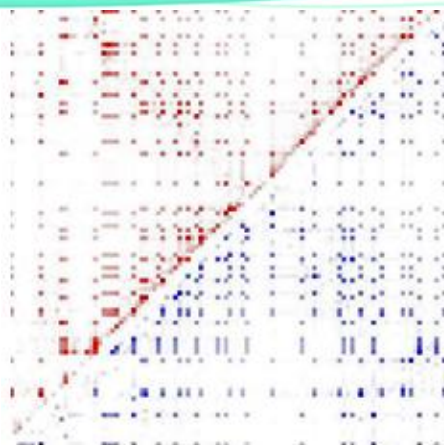
改善の方向性(Fock行列の構築)

- 改良指針(井上G@富士通の助言)
 - 14個のIF分岐(添字の同値性判断)が最適化を阻害、アクセスも不連続に
- 手動での最適化と結果
 - 基底関数添字の同値性を $(1/2)^n$ ($n=1,2,3$)で繰り返し込み
 - IFは積分閾値の篩い落としのみ
 - 系にも拠るが最大で**30%**の加速

```
do p=ixi1,ixi2
  do q=ixj1,ixj2
    do r=ixk1,ixk2
      do s=ixl1,ixl2
        ix=ix+1
        val = sint(ix)
        if((abs(val) <= tv)) cycle
        fock(q,p)=fock(q,p)+dc(s,r)*val*2. d0! クーロン項
        fock(s,r)=fock(s,r)+dc(q,p)*val*2. d0
        fock(r,p)=fock(r,p)-dc(s,q)*val*0. 5d0! 交換項
        fock(s,p)=fock(s,p)-dc(r,q)*val*0. 5d0
        fock(r,q)=fock(r,q)-dc(s,p)*val*0. 5d0
        fock(s,q)=fock(s,q)-dc(r,p)*val*0. 5d0
      end do
    end do
  end do
end do
```

FMO計算結果の可視化の深層学習の先行例

・IFIEの可視化 (IFIE-map) の学習




Deep Learning




構造の特徴を
画像から判定



αヘリックス構造



βシート構造



両方の構造

可視化結果の再解析の準備

- ・既報のFMO計算結果をpython系ツールで再処理して可視化、ワークフローを確立中
- ・GPUスパコンの高速処理を前提に、画像をダウンサンプリングしないでそのまま利用

```
1 import seaborn as sns
2 import pandas as pd
3 import matplotlib.pyplot as plt
4 import os
5 import glob
6 import subprocess
7 import datetime
8
9 folder1 =input('csvにするフォルダ')
10
11 path1 = './'+folder1+'/*.out'
12 files1 = glob.glob(path1)
13
14 print(path1)
15 print(files1)
16
17
18 for i in range(len(files1)):
19     subprocess.call(["python", "/home/sugiura/abmptools/getifiepieda.py","-ff","1-50","51-100","-i",files1[i]])
```

```
22 foldername = input("フォルダ名入力")
23 path='./'+foldername+'/*-MP2total-ffmatrix.csv'
24
25 files = glob.glob(path)
26 print(files)
27 mkfoldername = folder1+'picture-'+str(datetime.datetime.now().strftime("%Y%m%d%H%M"))
28 os.makedirs(mkfoldername,exist_ok=True)
29
30 for i in range(len(files)):
31
32     df_ifie_csv = pd.read_csv(files[i], header=0, index_col=0, float_precision="high")
33
34     plt.figure()
35     sns.heatmap(df_ifie_csv,vmax=50,vmin=-50,center=0, cmap='bwr_r',cbar=False) #最大値50,最小値-50 カラーバー非表示
36     plt.axis('off')
37     plt.savefig(mkfoldername+'/seaborn_heatmap_list'+str(i)+'.png')
38     plt.close('all')
```

まとめと(21年度の)関連活動

■jh210036-NAH課題@「不老」

- ・超大規模系対応 (Type Iサブシステム)
 - ⇒ 1万フラグメントのFMO-MP2/cc-pVDZの完走は1Q期に達成
 - ⇒ 2万フラグメント到達に向けて改良を継続 (配列の追加整理が必要)
 - ⇒ ベンチマーク的な応用計算の実行
- ・高速化 (Type Iサブシステム)
 - ⇒ 高速化は積分生成で17%、Fock行列構築で30%の速度向上
 - ⇒ HFでは積分バッファリングの併用を検討 (積分計算の総数を削減)
- ・機械学習 (Type IIサブシステム)
 - ⇒ 可視化IFIEデータの深層学習の実施

■hp210026課題@「富岳」 (代表者:望月)

- ・ウイルスタンパク質の大規模FMO計算による相互作用エネルギー解析
 - ⇒ MM-MD/FMO連携による統計的&データ科学的な評価

■HPCI拠点へのABINIT-MPのライブラリ整備 (責任者:望月)

- ・A64FX系スパコンへの改良版の導入
 - ⇒ 「富岳」、「不老」、「Wisteria-o」