


Inria

JCAD 2021

Passage à l'échelle d'un algorithme de
Randomized SVD pour la caractérisation
du vivant par méthode de positionnement
multidimensionnel

E. Agullo, O. Coulaud, M. Faverge, A. Franc, J.M. Frigerio, [F. Pruvost](#)



- Généralement : $\approx 10\ 000$ individus
- Challenge : 1 000 000 individus \Rightarrow **calcul parallèle distribué**
- Données : Inrae, diatomées (algues) du lac Léman

Matrice de distance D

$$\begin{pmatrix} d_{1,1} & d_{1,2} & \cdots & d_{1,n} \\ d_{2,1} & d_{2,2} & \cdots & d_{2,n} \\ \vdots & \vdots & \vdots & \vdots \\ d_{n,1} & d_{n,2} & \cdots & d_{n,n} \end{pmatrix}$$

Projection sur un
espace Euclidien

$$r \ll n$$




Conservation des
distances

Nuage de points X

$$\begin{pmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,r} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,r} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n,1} & x_{n,2} & \cdots & x_{n,r} \end{pmatrix}$$

X représenté sur un plan

Voting patterns



Visualisation de X en 2 ou 3 dimensions

$$\begin{pmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,r} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,r} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n,1} & x_{n,2} & \cdots & x_{n,r} \end{pmatrix}$$

Matrice de distance D

$$\begin{pmatrix} d_{1,1} & d_{1,2} & \cdots & d_{1,n} \\ d_{2,1} & d_{2,2} & \cdots & d_{2,n} \\ \vdots & \vdots & \vdots & \vdots \\ d_{n,1} & d_{n,2} & \cdots & d_{n,n} \end{pmatrix}$$

Projection sur un espace Euclidien

$$r \ll n$$



Conservation des distances

Nuage de points X


$$\begin{pmatrix} X_{1,1} & X_{1,2} & \cdots & X_{1,r} \\ X_{2,1} & X_{2,2} & \cdots & X_{2,r} \\ \vdots & \vdots & \vdots & \vdots \\ X_{n,1} & X_{n,2} & \cdots & X_{n,r} \end{pmatrix}$$

Coordonnées parallèles

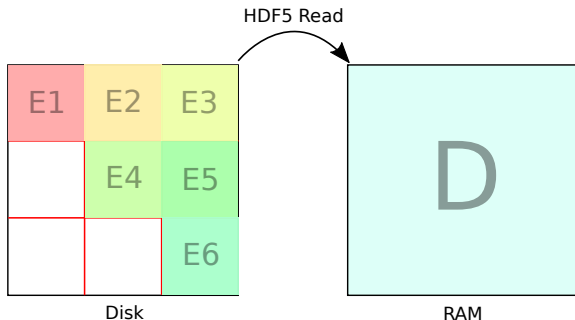
$$\begin{pmatrix} X_{1,1} & X_{1,2} & \cdots & X_{1,r} \\ X_{2,1} & X_{2,2} & \cdots & X_{2,r} \\ \vdots & \vdots & \vdots & \vdots \\ X_{n,1} & X_{n,2} & \cdots & X_{n,r} \end{pmatrix}$$

1 courbe = 1 individu

Parallel coordinate plot, Fisher's Iris data




1) Lecture matrice de distance D



Plusieurs échantillons, fichiers HDF5


2) Matrice de Gram (double recentrage) $D \rightarrow G$




$$d_{i.}^2 = \frac{1}{n} \sum_j d_{ij}^2$$

$$d_{..}^2 = \frac{1}{n^2} \sum_{i,j} d_{ij}^2$$


$$G_{i,j} = -\frac{1}{2}(d_{ij}^2 - d_{i.}^2 - d_{.j}^2 + d_{..}^2)$$

3) Singular Value Decomposition (SVD) $G = U\Sigma V^T$ 

4) Nuage de point $X = U\Sigma^{1/2}$




5) Ecriture HDF5 matrice X , Σ , metadata ...




1. Lecture HDF5, assembler D
 2. Transformation de Gram, $D \rightarrow G$
 3. SVD sur G , $G = U\Sigma V^T$
 4. Nuage de points, $X = U\Sigma^{1/2}$
 5. Ecriture HDF5 de X
- Faisable en Python, $n < 10000$
 - Capable de traiter des problèmes de taille $n = 1$ million ?
 - > Non, la SVD est trop coûteuse, $O(n^3)$!
 - En pratique G de rang faible, $r \ll n$ ($r = 10^3, n = 10^6$)
 - > Approcher la SVD de G par Randomized SVD, $O(n^2 \times r)$


Lorsque rang de G est $r \ll n$, la SVD peut être tronquée



1. Génération d'une matrice aléatoire Gaussienne : Ω
2. Produit de matrices : $Y = G \Omega$
3. Décomposition QR : $Y = Q_Y R_Y$



4. Produit de matrices : $C = G^T Q_Y = G Q_Y$, G symétrique
5. Décomposition QR : $C = Q_C R_C$



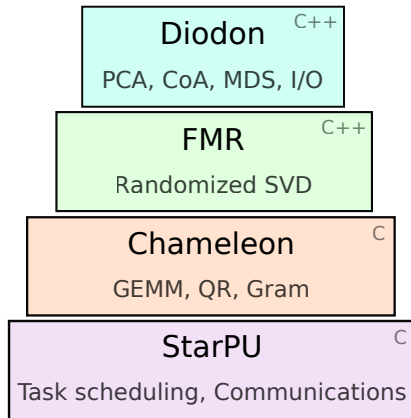
6. Décomposition SVD : $R_C = U_C \Sigma_C V_C^T$, $\Sigma = \Sigma_C$

7. Produit de matrices : $U = Q_Y V_C$, $V^T = U_C^T Q_C^T$

$$r \begin{array}{|c|} \hline \hline R_C \\ \hline \hline \end{array} = \begin{array}{|c|} \hline U_C \\ \hline \end{array} \begin{array}{|c|} \hline \hline \Sigma_C \\ \hline \hline \end{array} \begin{array}{|c|} \hline V_C^T \\ \hline \end{array}$$


$$r \begin{array}{|c|} \hline \hline \Sigma \\ \hline \hline \end{array} = \begin{array}{|c|} \hline \hline \Sigma_C \\ \hline \hline \end{array} \quad n \begin{array}{|c|} \hline U \\ \hline \end{array} = \begin{array}{|c|} \hline Q_Y \\ \hline \end{array} \begin{array}{|c|} \hline V_C \\ \hline \end{array}$$

1. GEMM : $Y = G \Omega$, $O(n^2 \times r)$
 2. QR : $Y = Q_Y R_Y$, $O(n \times r^2)$
 3. GEMM $C = G Q$, $O(n^2 \times r)$
 4. QR : $C = Q_C R_C$, $O(n \times r^2)$
 5. SVD : $R_C = U_C \Sigma_C V_C^T$, $O(r^3)$
 6. GEMM : $U = Q_Y V_C$, $O(n \times r^2)$
- Complexité dominée par les produits de matrices $O(n^2 \times r)$
 - GEMM : très parallélisables !
 - QR : raisonnablement parallélisables
 - SVD : petit système, calculable sur un noeud



Le moteur d'exécution **StarPU**

- Soumission d'un graphe de tâches (DAG)
- Gestion des dépendances et des transferts de données (MPI/CUDA)
- Différentes stratégies d'ordonnancement
- Portabilité des performances





Solveur d'algèbre linéaire dense **Chameleon**

- format en tuiles → noyaux (CPU, GPU)
- graphe de tâches → moteur d'exécution


```

for (j = 0; j < N; j++) {
    POTRF (RW,A[j][j]);
    for (i = j+1; i < N; i++)
        TRSM (RW,A[i][j], R,A[j][j]);
    for (i = j+1; i < N; i++) {
        SYRK (RW,A[i][i], R,A[i][j]);
        for (k = j+1; k < i; k++)
            GEMM (RW,A[i][k],
                 R,A[i][j], R,A[k][j]);
    }
}
__wait__();
    
```




Résultats

Temps CPU de la MDS, $r = 10^4$, cas complexe à résoudre
 La RSVD passe bien à l'échelle !



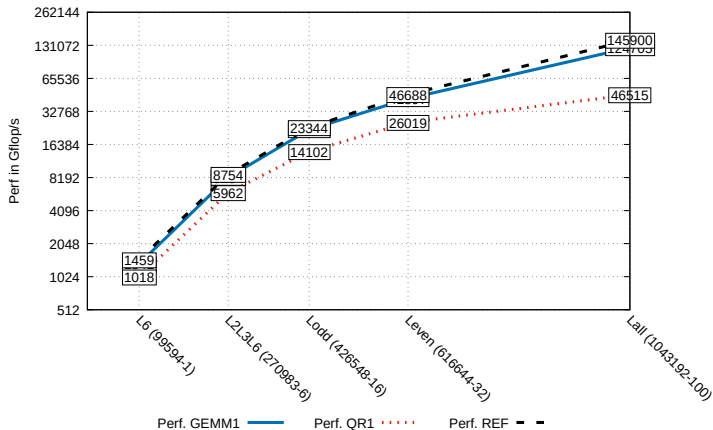
CINES Occigen, $n \in [10^5, 10^6]$, #Nodes $\in [1, 100]$, #CPUs $\in [24, 2400]$

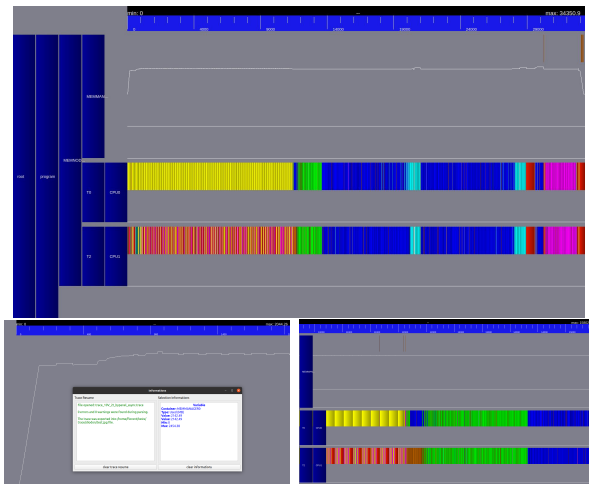
Temps CPU de la MDS, $r = 10^3$, rang plus réaliste en pratique
 La MDS du problème 1 million se résout en moins de 15 min !




CINES Occigen, $n \in [10^5, 10^6]$, #Nodes $\in [1, 100]$, #CPUs $\in [24, 2400]$

Efficacité du GEMM sur 100 noeuds = 85% !







Représentation de la MDS sur 2 axes, $n = 10^6$

- Grâce à une pile logicielle d'algèbre linéaire mature nous avons pu résoudre le challenge de SVD (approchée) $n = 10^6$
- La MDS peut fournir des solutions de références à comparer avec des méthodes de "clustering" avec heuristiques moins coûteuses mais moins robustes (Swarm)
- Les temps de calculs deviennent moindres devant les I/O si la matrice est de rang très faible
- Principales difficultés :
 - > I/O, conversion formats HDF5 → tuiles Chameleon,
 - > contrôle de la consommation mémoire avec StarPU

- Mettre à disposition **Diodon** (MDS, PCA, ...) en licence libre
- Faciliter l'utilisation du logiciel sur supercalculateurs
 - > serveur Galaxy, Jupyter notebook, packaging GNU Guix
- Trouver de nouvelles applications SVD sur grandes données
 - > compression, problèmes inverses, POD, ...
- Réaliser des tests avec des GPUs
 - > expérimentations en cours sur IDRIS Jean Zay
- Réaliser un portage sur un système "big data"
 - > écosystèmes yarn/hdfs
 - > se comparer à Hadoop MapReduce et Spark
- Travailler sur une SVD exacte passant à l'échelle
 - > si r devient grand, l'étape de SVD sur R_C devient bloquante

Merci pour votre attention !

