

# Kvantumadatkompresszió és kvantuminformáció klasszikus szuperszámítógépeken

Legeza Örs

Erősen korrelált rendszerek "Lendület" kutatócsoport


Wigner Fizikai Kutatóközpont, Budapest

Big Data Day, 2013.09.12, Budapest


# Érintett témák, hogyan jelenik meg a BigData koncepció

1. Mi a cél? Mi a kihívás?
2. Kölcsönható klasszikus és kvantum rendszer
3. Kvantuminformáció szerepe:  
Algoritmusok polynomiális skálázódási tulajdonságokkal
  - Density matrix renormalization group (DMRG) [White,1992](#)
  - Matrix Product State (MPS) [Ostlund,1995; Verstraete,2004](#)
  - Tree Tensor Network States (TTNS) [Murg,2010; Chan,2013](#)
4. Szimulációk szuperszámítógépeken: A K-Computer

# Objektum állapotai (bázis)



áll




ül



guggol


- ▶ Lokális tér dimenziója  $d = 3$

# Konfigurációs tér




- ▶ Konfigurációs tér dimenziója:  $3^N$ , ahol  $N$  az emberek száma
- ▶ Ez egy példa rendezetlen eloszlásra: véletlenszerűen vannak az egyének az egyes lokális állapotaikban
- ▶ Konfigurációs tér exponenciálisan skálázódik

## Rendeződés kölcsönhatások/külső behatás révén




- ▶ Ez egy példa rendezett eloszlásra: egyének egyes lokális állapotai egyfajta rendet mutatnak
- ▶ Rendezettség mérhető korrelációkkal, rendparaméterekkel, stb
- ▶ A kölcsönhatásokat leíró operátort Hamilton-operátornak hívjuk

## Táncterem: diszkó




- ▶ Például diszkóban a táncosok szinte egymástól függetlenül táncolnak

## Táncterem: társastánc




- ▶ Kötött párok alakulhatnak ki, egészen más tulajdonságokkal rendelkeznek
- ▶ Erős korreláció két egyén között
- ▶ Többi párral is lehetnek erős korrelációban: egyszerre lép minden páros: kollektív módusok

## Táncterem: "Bomba nő" megjelenése



- ▶ Vonzó kölcsönhatás és perturbáció
- ▶ Párok felszakadhatnak
- ▶ Gerjesztett állapotok, amíg a rendszer nem relaxálódik


## Táncterem: "Bomba nő" megjelenése



- ▶ Felszakadt párok
- ▶ "Bomba nő" körülötte az őt ostromló férfiakkal: mint egy megnövekedett tömegű részecske
- ▶ Például jóval lassabban tud haladni

## Klasszikus eset

- ▶ Például lokális tér d=2 dimenziós (két állapot van csak)
- ▶ Két egyén (A és B helyen)
- ▶ Négyféle konfiguráció lehet
- ▶ A helyen egyén vagy áll, vagy guggol
- ▶ B helyen egyén vagy áll, vagy guggol



## Kvantumfizikában minden:

- ▶ Például lokális tér d=2 dimenziós (két állapot van csak)
- ▶ Két helyen (A és B helyen)
- ▶ Négyféle konfiguráció lehet
- ▶ A helyen egyén 50%-os valószínűsséggel vagy áll, vagy guggol
- ▶ B helyen egyén 50%-os valószínűsséggel vagy áll, vagy guggol
- ▶ Összefonódott állapot → kvantuminformáció (q-dits)

$$\frac{1}{\sqrt{2}} \left( \begin{array}{c} \text{stick figure} \\ \text{giggle} \end{array} \otimes \begin{array}{c} \text{stick figure} \\ \text{giggle} \end{array} + \begin{array}{c} \text{giggle} \\ \text{stick figure} \end{array} \otimes \begin{array}{c} \text{stick figure} \\ \text{giggle} \end{array} \right)$$
$$\frac{1}{\sqrt{2}} \left( \begin{array}{c} \uparrow \\ \downarrow \end{array} \otimes \begin{array}{c} \downarrow \\ \uparrow \end{array} + \begin{array}{c} \downarrow \\ \uparrow \end{array} \otimes \begin{array}{c} \uparrow \\ \downarrow \end{array} \right)$$

# Efficient simulation of quantum systems on classical computers?

- ▶ R. Feynman (1985): simulating quantum systems on classical computers takes an amount of time that scales exponentially with size of system, while quantum simulations can scale in polynomial time with system size.
- ▶ Tensor network states as low-rank approximations of high-dimensional tensor spaces → efficient simulations on classical computers **with polynomial costs**
- ▶ Major aim: no need to build expensive laboratories and experimental environments to design new materials and system just simulate them on computers
- ▶ In certain cases we can already reproduce and simulate experimental results


Major aim:

For example using a spin-orbit basis ( $d=4$ ):

$$|\alpha_i\rangle \equiv |0\rangle, |\downarrow\rangle, |\uparrow\rangle, |\downarrow\uparrow\rangle$$

Wavefunction in full tensor form:



$$|\Psi\rangle = \sum_{\alpha_1, \dots, \alpha_N} U_{\alpha_1, \dots, \alpha_N} |\alpha_1, \dots, \alpha_N\rangle$$



## Tensor product approximations:

- Matrix Product State (MPS) representation:

$$|\Psi\rangle = \sum_{\alpha_1, \alpha_2, \dots, \alpha_N}^d \text{Tr} (A_{\alpha_1}^1 A_{\alpha_2}^2 \cdots A_{\alpha_N}^N) |\alpha_1\rangle |\alpha_2\rangle \cdots |\alpha_N\rangle$$



$$A_i[m, m]_{d_i}$$

- We can call this as a network.
- The Density Matrix Renormalization Group (DMRG) is a special algorithm that provides the optimized set of  $A_i$  matrices.

# Tensor product approximation

Approximation of a single tensor, or even an ensemble of tensors  $\mathbf{u}_y$ ,  $y = 1, \dots, m$ , in tensor product spaces,

$$|\mathbf{u}_y\rangle = \sum_{x_1=1}^{n_1} \cdots \sum_{x_d=1}^{n_d} U(x_1, \dots, x_d, y) |x_1\rangle \otimes \cdots \otimes |x_d\rangle \in \bigotimes_{i=1}^d V_i := \bigotimes_{i=1}^d \mathbb{C}^{n_i}$$

where  $\text{span}\{|x_i\rangle : x_i = 1, \dots, n - i\} = V_i = \mathbb{C}^{n_i}$ . If there is no ambiguity with respect to the basis vectors  $|x_i\rangle$ ,  $x_i = 1, \dots, n_i$ , we can identify  $(|\mathbf{u}_y\rangle)_{y=1}^m$ , with the discrete function

$$\left( (x_1, \dots, x_d) \mapsto U(x_1, \dots, x_d, y) \right)$$

i.e.  $x_i = 1, \dots, n_i$ ,  $y = 1, \dots, m$ .

## DMRG, MPS, TT

A special representation of  $U$  if we introduce the matrices  
 $\mathbf{U}_p(x_p) \in \mathbb{C}^{r_{p-1} \times r_p}$  by

$$(\mathbf{U}_p(x_p))_{k_{p-1}, k_p} = U_p(k_{p-1}, x_p, k_p) , \quad 1 < p < d .$$

Then we can represent the tensor by matrix products

$$U(x_1, \dots, x_d) = \mathbf{U}_1(x_1) \cdots \mathbf{U}_p(x_p) \cdots \mathbf{U}_d(x_d) .$$

Density matrix renormalization group (DMRG) method ([White, 1992](#))


Matrix product state (MPS) ([Östlund and Rommer, 1996](#); [F. Verstraete and Cirac, 2004](#))

Tensor Train (TT) ([Oseledets 2009](#); [Hackbusch 2009](#))

# Sajátállapot megtalálásának komplexitása

- contains ground states of short-ranged Hamiltonians
- merit of TNS:  
parametrize  
this set efficiently!

ground states are here!



# Kvantumos adattömörítés

1.  $\rho^{(N)} = \rho \otimes \rho \otimes \dots \otimes \rho$ , ahol  $\rho = \sum_{\alpha} p_{\alpha} |\phi_{\alpha}\rangle\langle\phi_{\alpha}|$ , és a szöveg Neumann-entrópiája:  $s(\rho^{(N)}) = Ns(\rho)$ .
2.  $\Lambda^{(N)}$  felbontható egy ún. **tipikus** ( $\Lambda_{\text{typ}}^{(N)}$ ) és **atipikus** ( $\Lambda_{\text{atyp}}^{(N)}$ ) altérre  $\Pi_{\text{typ}}$  és  $\Pi_{\text{atyp}}$  projektorok alkalmazásával.
3. Amennyiben bármely  $\epsilon > 0$ -ra, a sokaságnak szinte a teljes súlya benne van  $\Lambda_{\text{typ}}^{(N)}$ -ben, azaz  $\text{Tr} \Pi_{\text{typ}} \rho^{(N)} \Pi_{\text{typ}} > 1 - \epsilon$ , ugyanakkor az atipikus altérre  $\text{Tr} \Pi_{\text{atyp}} \rho^{(N)} \Pi_{\text{atyp}} < \epsilon$ , akkor bármilyen  $\delta > 0$ -ra és elég nagy  $N$ -re  $\rho^{(N)}$ -nek az  $\omega_{\text{typ}}$  tipikus sajátértékhalmazához tartozó sajátértéke egy kicsiny tartományba esik:

$$e^{-N[s(\rho)+\delta]} < \omega_n < e^{-N[s(\rho)-\delta]}.$$

4. Ennek megfelelően a **tipikus altér dimenziójára** fennáll, hogy

$$(1 - \epsilon) e^{N[s(\rho)-\delta]} \leq \dim \Lambda_{\text{typ}}^{(N)} \leq e^{N[s(\rho)+\delta]}.$$

# Data sparse representation of the wavefunction

Example from 2002: DBSS approach applied on  $F_2$  (d2h) (18/18)


$$\Lambda_{\text{FCI}} = (2N)! / [(2N - N_e)! N_e!] = 9075135300$$

$$\Lambda_{\text{DMRG}} = M_l \times 4 \times 4 \times M_r = 28800000 (M_l = 1200, Mr = 1500)$$


sparsity  $\simeq 315$

$$\Lambda_{\text{DMRG}} = M_l \times 4 \times 4 \times M_r = 7680 (M_l = 120, Mr = 4)$$


sparsity  $\simeq 1181658$  Legeza, Roder, Hess, Phys Rev B (2002)



# Entanglement → Multiply connected networks



LiF at  $r=3.05$



LiF at  $r=13.7$

Rissler, White, Noack, ECP (2006)

Murg, Verstraete, Schneider, Nagy, Legeza (2013)

- ▶ DMRG → Matrix product states, i.e. optimization along one-spatial dimension
- ▶ Need for an algorithm that reflects the entanglement topology of the problem → Tensor Network State (TNS) methods
- ▶ Use tensors  $[A_i]_{\alpha_1 \dots \alpha_z}^k$  where  $z$  is the coordination number

# Fujitsu: K computer 10.51 petaflops




- ▶ DDMRG simulations: ACM Gordon Bell Prize in 2012
- ▶ Number of processors: 88,128
- ▶ Total Memory capacity: More than 1 petabyte

# Fujitsu: K computer 10.51 petaflops

- ▶ The 6-dimensional mesh/torus topology in the K computer provides many communication routes between neighboring CPUs.
- ▶ Execution of data communications between CPUs via the shortest route and over the shortest period of time
- ▶ CPU: Fujitsu SPARC64 VIIIfx processors:  
**2.2 gigaflops per watt**
- ▶ Water cooling system for its major components



"6-dimensional mesh/torus" topology  
(model)



SPARC64™ VIIIfx

- ▶ A VKSZ12 BigData projekt – ha nem is ilyen volumenű fejlesztést céloz meg – mindenképpen egyedülálló lehetőséget biztosít, hogy a világban nagy intenzitással folyó kutatói és fejlesztői munkában a Magyarországról származó innovációs és szellemi tőke is érvényre juthasson.
- ▶ Mindez hosszabb távon hozzájárulna az utánpótlás neveléséhez, a kutatás és az ipar szorosabb összekapcsolódásához, illetve nemzetközi kutatási programok révén az ország európai integrációját is elősegítené.

Köszönöm megtisztelő figyelmüket!