


# Tucker-Decomposition

Nächste Idee für hochdimensionale Schmidt:

$$T_{n_1 n_2 n_3 \dots n_k} = \sum_{k_1 \dots k_r} g_{k_1 \dots k_r} a_{k_1 n_1}^{(1)} a_{k_2 n_2}^{(2)} \dots a_{k_r n_r}^{(r)}$$



- 1.) Der wesentlichste Punkt für die Kompression ist das der Tensor  $g$  geringste Dimension hat als der ursprüngliche Tensor.
- 2.) Jeder Tensor  $k_n$  in diese Form gebracht werden, aber die Dimension  $g$  muss nicht kleiner sein.

Berechnung der Tucker-Decomposition mit HOSVD

HOSVD ( $X_{k_1 \dots k_N}$ )

for  $n = 1, \dots, N$  do

    Fasse alle Indizes  $k_i$  ( $i \neq n$ )

    zu einem Index zusammen

    und führe sie SVD durch

    (Mehre nur die wichtigsten



    Singular Werte mit)

    Speichere die linken Singulärvektoren

$U^{(n)}$

end

$$g_{k_1 \dots k_r} = \sum_{k_{n+1} \dots k_N} U_{k_{n+1} n_1}^{(1)} \dots U_{k_{n+1} n_r}^{(r)} X_{k_1 \dots k_N}$$



## Bemerkung

- Meist ist die Approximation nicht die effektivste, meist wird noch ein ALS Fitting algorithm

- Oder es wird ein iteratives Verfahren verwendet:

HOOI ( $X_{n_1 \dots n_N}$ )

    initialisiere  $U^{(n)}$  for  $n = 1, \dots, N$  mit HOSVD

repeat

    for  $n = 1, \dots, N$  do

$$\begin{matrix} \boxed{Y} \\ \text{|||||} \end{matrix} = \begin{matrix} \boxed{X} \\ \text{---} \end{matrix}$$

Führe SVD für  $Y$  als  $2n \times n$  Matrix wie bei HOSVD  
 Form  $U^T$

und  
 mit Lösung wie die Approximat nicht bestant


$$\begin{matrix} \boxed{S} \\ \text{|||||} \end{matrix} = \begin{matrix} \boxed{X} \\ \text{---} \\ \text{---} \\ \text{---} \\ \text{---} \end{matrix} \quad \text{und } \text{---}$$



Problem: - Keine Möglichkeit dem Tensor leicht zu updaten  
 immer komplette Teile notwendig (kei Dyn  $k$ ,  
 kein Fixwert)

Bemerkung: Es gibt noch weitere Variablen die Zerlegen  
Hierarchical Tucker

Die Idee hinter Hierardial Tucker, ist zuerst die  
 Deompositon an einem Tensor dreifachig sind hier wieder  
 Kränze.

Folgender Algorithmus:






Das hierarchisch Tada Fanout ist eine Art  
Binärer Tree Baum



Können wir mit dem HTada Fanout rechnen?

Ja, klar!

1.) Norm und Skalarprodukt



ist die  
Fan für  
den vollen  
Tree




2.) Addition

Sehen wir zunächst von zwei Matrizen aus in SU6

$$A = U_A S_A V_A \quad B = U_B S_B V_B \quad \text{damit}$$

$$A+B = [U_A \ U_B] \cdot \begin{pmatrix} S_A & 0 \\ 0 & S_B \end{pmatrix} \cdot [V_A \ V_B]^T$$

$\Rightarrow$  Das sollte dann wieder an SVD durchföhren zu Kompression.



### 3) Orthogonalisierung

Es gibt für jede Zerlegung Regeln wie die Tensoren orthogonalisiert werden können und hat zu Einflüssen  
 (i) transkription, (ii) Teilweise kein Name und Skalarprodukt schnell berechnet wird.


S. Bestätigung MATHICSE Technical report 4 2012  
 "htucker - a matlab toolbox for tensors in the hierarchical Tucker format".

Hier besteht das Problem die Tensoren zu manipulieren.

VIII.21

Matrix Product States und Matrix Product Operator

Quanteninformation ist ein großes Forschungsgebiet,  
 Grundbausteine sind meist Qubits (aka Zweiniveausystem)



in einem Kontext kann man dies auch Spin-Kette  
 oder Bose Hubbard model

Wenn  $n_i$  der Zustandsindex des  $i$  Qubits ist, die Gesamtwelt  
 $\mathcal{Z}_{n_1, n_2, \dots, n_N}$  ein Tensor!

Zur Simulation muss die Schrödingergleichung gelöst werden:

$$i\hbar \partial_t |\psi\rangle = H|\psi\rangle \Leftrightarrow i\hbar \partial_t \mathcal{Z}_{n_1, \dots, n_N} = \sum_{n'_1, \dots, n'_N} H_{n_1, \dots, n_N; n'_1, \dots, n'_N} \mathcal{Z}_{n'_1, \dots, n'_N}$$

mit  $|\psi\rangle = \sum_{n_1, \dots, n_N} \mathcal{Z}_{n_1, \dots, n_N} |n_1, \dots, n_N\rangle$

$\Rightarrow$  TDD Tensornetwork für  $\mathcal{Z}$  und für  $H$  findet!

$\Rightarrow$  Matrix Product States (Vidal PRL 81 (14) 147502 (2003)  
 (siehe zu verstehen bzw Schlüsselwort  
 arxiv! 1008.3477v2 (2011))