

### III. 10 Optimierungsprobleme

Im Zusammenhang mit den Problemen in der Quantenmechanik stellen sich oft Optimierungsprobleme z.B.

#### (i) Strukturoptimierung (Born-Oppenheimer Näherung)

Für den Hamiltonoperator des Moleküls

$$H_e = \sum_i \frac{p_i^2}{2m_e} - \sum_a \sum_{i=1}^{N_e} \frac{1}{4\pi\epsilon_0} \frac{Z_a e^2}{|r_i - R_a|} + \sum_{i < j} \frac{1}{8\pi\epsilon_0} \frac{e^2}{|r_i - r_j|} + \sum_{a < b} \frac{1}{8\pi\epsilon_0} \frac{Z_a Z_b}{|R_a - R_b|}$$

Wird die Kernposition fixiert

$R_a$ ! Born-Oppenheimer: Die Masse der Kerne ist sehr viel größer als die der Elektronen  $\Rightarrow$  langsame Bewegung

- \* Daher wird die Kernposition  $R_a$  fixiert, an dem Punkt in dem die minimale Gesamtenergie verliert.  
(Adiabatische Behandlung, Elektron folgen den Kernen schnell)
- \* Bestimmung der Kernposition  $\Rightarrow$  Optimierungsproblem bzgl. der Kernposition  $\Rightarrow$  Benötigt wird  $E(R_a)$  und Algorithmen
- \* Taylorentwicklung um Gleichgewichtsposition  $R_a^0$

$$E(\{R_a^0 + \Delta R_a\}) = \sum_{i,j} M_{ij} (\Delta R_a^0)_i (\Delta R_a^0)_j$$

existiert in quadratisches Potential  $\Rightarrow$  harmonische Oszillatoren  
 $\Rightarrow$  Phononen.  $M$  wird über die Hesse-Matrix bestimmt

(kann durch finite Differenz an E(L) brechen werden)

(ii) Basisatz optimierung

Zur Ermittlung STO oder STO enthaltene Parameter:

STO:

$$\chi_{r, h_1, l, m}(r, \theta, \varphi) = N Y_{lm}(\theta, \varphi) r^{n-1} e^{-\frac{r}{\lambda}}$$


Dieses Zeta  $\chi$  wurde für den Ansatz der Wellenfunktion optimiert und zwar

$$\langle E(r_1, \dots, r_n) \rangle$$

Funktion der entsprechenden Basisatzparameter!

Diese Funktion wurde numerisch brechen und dann optimiert.

(iii) Beispiel aus der modernen Physik (Exp. Physik, Imaging, Astrophysik)



$$B(x, y) = \int dx' \int dy' \text{PSF}(x-x', y-y') O(x', y')$$

Point Spread Funktion  
beschreibt wie ein Punkt des Objekts  
in Bild abgebildet wird.



Punkt A wird verstreut! PSF macht Bildverschmierung  
Fassen wir  $O(x', y')$  als Verteilung auf, so kann z.B.

$$E(\theta) = \left\| \int dx' \int ds' \text{PSF}(x-x', s-s') O(x', s) - B_{\text{exp}}(x, s) \right\|_2$$

$\Rightarrow$  wird  $O(x, s)$  variiert und dabei  $E(\theta)$  minimiert.

Kann man in gewissern Sinne Unsicherheit reduzieren

(Eine von vielen Möglichkeiten der Deconvolutionalgorithmen)

$\Rightarrow$  Eine Übersicht über Optimierungsalgorithmen wäre schön!

### Algorithmen für Optimierungsprobleme

Bevor es los geht, eine Banche:

Quadratische Optimierungsprobleme

z.B. 
$$\text{Err}(\underline{a}) = \sum_j \left( y_j - \sum_i^N a_i x_{ij} \right)^2$$

$\uparrow$  wird gesucht

keinen über lineares Gleichungssystem gelöst werden:

Dann

$$\frac{\partial \text{Err}(\underline{a})}{\partial a_i} = -2 \sum_j x_{ij} \left( y_j - \sum_{i'} a_{i'} x_{i'j} \right) \stackrel{!}{=} 0$$

Gradient  
mess verschwindet

$$\sum_{i'} x_{ij} x_{i'j} a_{i'} = \sum_j x_{ij} y_j$$

$$\sum_j x_{ij} \sum_{i'} x_{i'j} a_{i'} = \sum_j x_{ij} y_j$$

(Adjektiv)  
 $x_{ij}^{-1}$



$$\Rightarrow \sum_{i'} x_{i'j} a_{i'} = y_j$$

$\Rightarrow \underline{x} - a = \underline{y}$   
 kann über  $a = \underline{x}^{-1} \cdot \underline{y}$  gelöst werden, falls  $\underline{x}$   
 invertierbar ist. Aber das muss nicht sein,  
 das wird es schwierig. Auch schwierig bei großen Matrizen.  
Methoden mit Gradienten:

Steepest descent (einfachste Methode)

Bemerkung: Wir suchen im folgenden ein Minimum einer Funktion  $f(x)$ ,  
 die folgende Methode finden in der Regel nur lokale  
 Minima! (Zusätzliche Strategien sind für  
 globale Minima notwendig!)



Idee 1D



Idee für das Vorgehen:

- 1) Starten an Punkt  $x_0$
- 2) Berechnen  $g = -\nabla f(x_0)$ , das wird unsere Suchrichtung.
- 3) Lineare such  $f(x_0 + \lambda g)$  berechnen für verschiedene  $\lambda$ , so klein wie  $f$  klein wird, steigt  $f$  so höher an.  
 Setze  $x_0^{(n)} = x_0^{(n-1)} + \lambda^{(n)} g$ , gehe wieder zu 2

Illustration falls  $\nabla f(x_0) \neq 0$ , sonst stopps



- Vorteile:
- Bei guter Linesearch wird steepst descent immer den Funktionswert reduzieren (Gradienten sind dem Minimum zu naher)
  - Sehr einfach
  - Nur ein Gradientenmess gespeichert werden.

- Nachteile:
- Zwei aufeinander folgende Linesearch stellen sich nicht aufeinander  $\Rightarrow$  teilweise wird die erreichte Optimierung in einer Dimension wieder zurück gemacht.
  - Der Algorithmus oscilliert um das minimale Wert
  - guter Linesearch teuer, oft muss sehr lange angesetzt
  - Nahe dem Minimum nimmt die Konvergenzrate ab (flach)

Hauptanwendung: Schnell nahe an das Minimum<sup>zu</sup> kommen und dann übernimmt die bessere Methode.

### Conjugate gradient Methode

Hauptproblem von steepst descent, was das teilweise rückgängig machen der Optimierung im nächsten Schritt.

Hier wird ~~jetzt~~ versucht, dass die Richtungen sich nicht abrupt ändern:

$$\underset{\substack{\uparrow \\ \text{Richtung}}}{d_i} = \underset{\substack{\uparrow \\ \text{Aktueller negativer} \\ \text{Gradient}}}{g_i} + \beta_i \underset{\substack{\uparrow \\ \text{letzte Richtung}}}{d_{i-1}}$$

Das ist so gebaut, dass für quadratische Oberflächen kein Gradientenrichtungswahl der vorherigen Richtung entsteht.

Verschiedene Möglichkeiten für  $\beta_i$ :

Fletcher-Reeves:  $\beta_i^{FR} = \frac{g_i \cdot g_i}{g_{i-1} \cdot g_{i-1}}$

Polak-Ribiere (PR):  
 $\beta_{PR} = \frac{g_i \cdot (g_i - g_{i-1})}{g_{i-1} \cdot g_{i-1}}$

Hestenes-Hinzel:

$$\beta_i^{HS} = \frac{g_i \cdot (g_i - g_{i-1})}{d_{i-1} \cdot (g_i - g_{i-1})}$$

Komplett super funktioniert CG bei nicht-quadratischen Oberflächen nicht, daher ist ein Neustart notwendig  
 2. B misst man in wie weit die aufeinanderfolgenden Gradienten nicht orthogonal sind

Werden anhand von quadratischen Funktionen entwickelt, so dass  $d_i \cdot H \cdot g_i = 0$ , aber  $d$  zu  $g$  konjugiert  
 Dort sind alle äquivalent, im allgemeinen unterschiedliche Verfahren

(PR funktioniert besser PostA)

Bemerkungen

- Sehr viel ~~das~~ bessere Konvergenz als steepest descent
- Precondition auf die Variable (Koordinatentransformall kann helfen)
- Nur zwei Verfahren müssen verglichen werden (einer mehr als Steepest Descent)
- Der Gradient muss in beide Methoden berechnet werden, nicht immer ist das analytisch oder in schneller Zeit möglich.