



Wintersemester 2006/07

Fundamente der Computational Intelligence
(Vorlesung)

Prof. Dr. Günter Rudolph

Fachbereich Informatik

Lehrstuhl für Algorithm Engineering



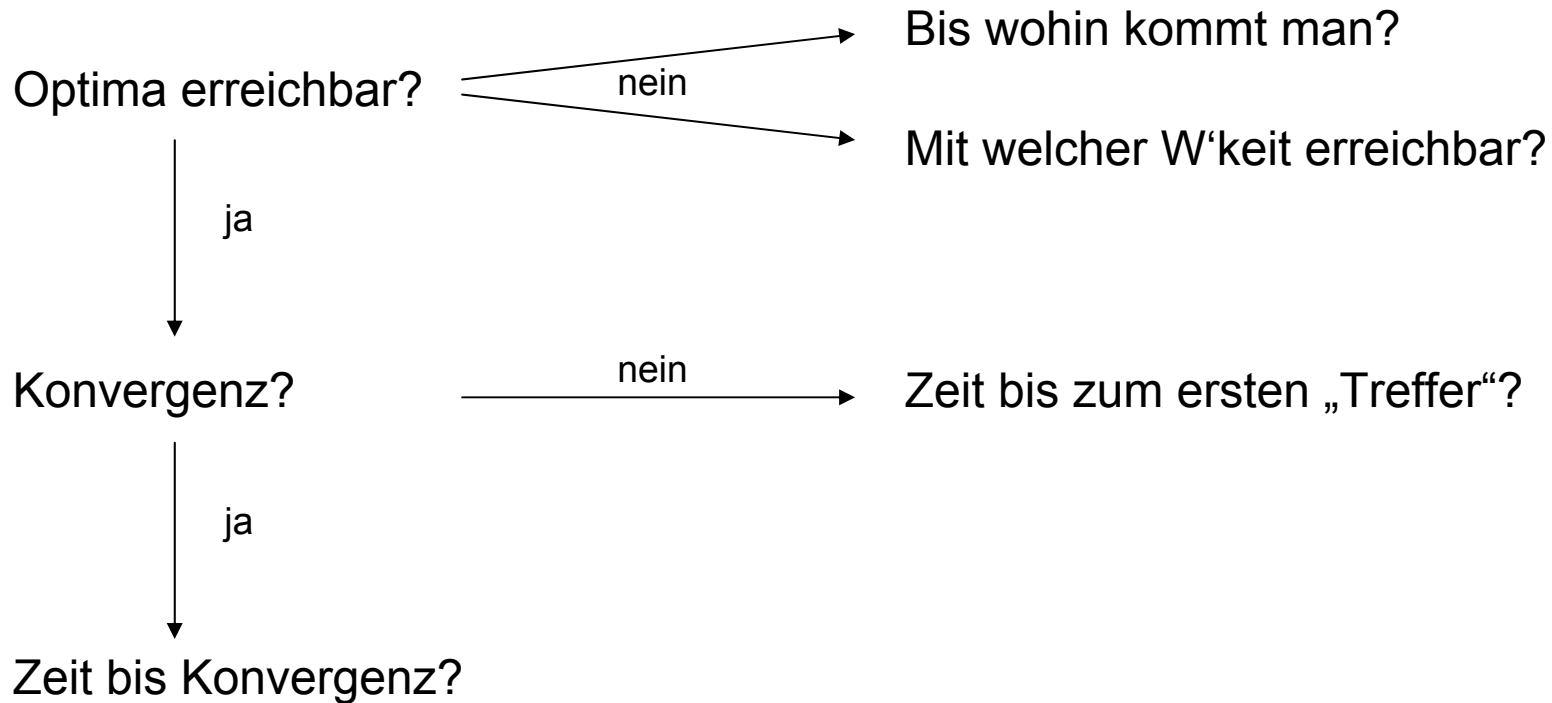


Inhalt

- Konvergenz
- EA im \mathbb{R}^n



Typische theoretische Fragestellungen:





Zum Begriff „Konvergenz“

$D_k = |f(X_k) - f^*| \geq 0$ ist eine Zufallsvariable

wir betrachten die stochastische Folge D_0, D_1, D_2, \dots

Konvergiert die stochastische Folge $(D_k)_{k \geq 0}$ gegen 0?

Wenn ja, dann offensichtlich „Konvergenz zum Optimum“!

Es existieren viele Arten von **stochastischer Konvergenz!**

→ deshalb hier nur die gebräuchlichsten ...

Notation: $\mathcal{P}^{(t)}$ = Population zum Zeitpunkt $t \geq 0$, $f_b(\mathcal{P}(t)) = \min\{f(x) : x \in \mathcal{P}(t)\}$



Definition

Sei $D_t = |f_b(\mathcal{P}(t)) - f^*| \geq 0$. Wir sagen: Der EA

(a) **konvergiert vollständig** zum Optimum, wenn $\forall \varepsilon > 0$

$$\lim_{t \rightarrow \infty} \sum_{k=1}^t P\{D_k > \varepsilon\} < \infty ;$$

(b) **konvergiert fast sicher** oder **mit W'keit 1** zum Optimum, wenn

$$P\{\lim_{t \rightarrow \infty} D_k = 0\} = 1 ;$$

(c) **konvergiert in Wahrscheinlichkeit** zum Optimum, wenn $\forall \varepsilon > 0$

$$\lim_{t \rightarrow \infty} P\{D_t > \varepsilon\} = 0 ;$$

(a) **konvergiert im Mittel** zum Optimum, wenn $\forall \varepsilon > 0$

$$\lim_{t \rightarrow \infty} E\{D_t\} = 0 .$$





Lemma

- $(a) \Rightarrow (b) \Rightarrow (c)$.
- $(d) \Rightarrow (c)$.
- Falls $\exists K < \infty : \forall t \geq 0 : D_t \leq K$, dann $(d) \Leftrightarrow (c)$.
- Falls $(D_t)_{t \geq 0}$ stochastisch unabhängige Folge, dann $(a) \Leftrightarrow (b)$. ■

Typische Vorgehensweise:

1. Zeige Konvergenz in W'keit (c). Meistens einfach!
2. Zeige, dass Konvergenz schnell genug (a). Dann folgt auch (b).
3. Folge nach oben beschränkt? Dann folgt (d).



Beispiele: Sei $(X_k)_{k \geq 1}$ Folge unabhängiger Zufallsvariablen.

Verteilung:
$$P\{X_k = 0\} = 1 - \frac{1}{k} \quad P\{X_k = 1\} = \frac{1}{k}$$

1.
$$P\{X_k > \varepsilon\} = P\{X_k = 1\} = \frac{1}{k} \rightarrow 0 \text{ für } t \rightarrow \infty$$

\Rightarrow Konvergenz in W'keit (c)

2.
$$\sum_{k=1}^{\infty} P\{X_k > \varepsilon\} = \sum_{k=1}^{\infty} P\{X_k = 1\} = \sum_{k=1}^{\infty} \frac{1}{k} = \infty$$

\Rightarrow Konvergenz nicht schnell genug! Also keine vollständige Konvergenz!

3. Es gilt: $\forall k \geq 0 : 0 \leq X_k \leq 1$. Also: Folge beschränkt mit $K=1$.

Wg. Konvergenz in W'keit (c) und Beschränktheit \Rightarrow Konvergenz im Mittel (d)



Beispiele: Sei $(X_k)_{k \geq 1}$ Folge unabhängiger Zufallsvariablen.

Verteilung:		(a)	(c)	(d)
$P\{X_k = 0\} = 1 - \frac{1}{k}$	$P\{X_k = 1\} = \frac{1}{k}$	(-)	(+)	(+)
$P\{X_k = 0\} = 1 - \frac{1}{k^2}$	$P\{X_k = 1\} = \frac{1}{k^2}$	(+)	(+)	(+)
$P\{X_k = 0\} = 1 - \frac{1}{k}$	$P\{X_k = k\} = \frac{1}{k}$	(-)	(+)	(-)
$P\{X_k = 0\} = 1 - \frac{1}{k^2}$	$P\{X_k = k\} = \frac{1}{k^2}$	(+)	(+)	(+)
$P\{X_k = 0\} = 1 - \frac{1}{k}$	$P\{X_k = k^2\} = \frac{1}{k}$	(-)	(+)	(-)
$P\{X_k = 0\} = 1 - \frac{1}{k^2}$	$P\{X_k = k^2\} = \frac{1}{k^2}$	(+)	(+)	(-)



Satz:

Sei $D_k = |f(x_k) - f^*|$ für $k \geq 0$ durch einen (1+1)-EA generiert,
 $S^* = \{x^* \in S : f(x^*) = f^*\}$ die Menge der optimalen Lösungen und
 $P_m(x, S^*)$ die W'keit, von $x \in S$ durch eine Mutation nach S^* zu gelangen.

Wenn für jedes $x \in S \setminus S^*$ gilt $P_m(x, S^*) \geq \delta > 0$, dann $D_k \rightarrow 0$ vollständig.

Beweis:

Für den (1+1)-EA gilt: $P(x, S^*) = 1$ für $x \in S^*$ wg. Selektion des Besseren.

Es reicht also zu zeigen, dass der EA durch Mutation S^* sicher erreicht:

Erfolg in 1. Iteration: $P_m(x, S^*) \geq \delta$.

Kein Erfolg in 1. Iteration $\leq 1 - \delta$.

Kein Erfolg in k. Iteration $\leq (1 - \delta)^k$.

\Rightarrow Erfolg in k. Iteration $\geq 1 - (1 - \delta)^k \rightarrow 1$ für $k \rightarrow \infty$.

Wg. $P\{D_k > \varepsilon\} \leq (1 - \delta)^k \rightarrow 0$ folgt Konvergenz in W'keit und da $\sum_{k=0}^{\infty} (1 - \delta)^k < \infty$
folgt sogar vollständige Konvergenz.

Außerdem: $\forall k \geq 0: 0 \leq D_k \leq D_0 < \infty$, also auch Konvergenz im Mittel. ■



Die Bedingung: $\forall x \in S \setminus S^*$ gilt $P_m(x, S^*) \geq \delta > 0$

- ist hinreichend, aber nicht notwendig und
- etwa für die globale Mutation mit Mutationsw'keit $p \in (0,1)$ erfüllt, da

$$P_m(x, y) = p^{H(x,y)} (1-p)^{n-H(x,y)} > 0 \text{ für alle } x, y \text{ in } S,$$

wobei n = Dimension und $H(x,y)$ der Hamming-Abstand zwischen x und y .

Achtung:

Die gleiche Konvergenzaussage erhält man für reine Zufallssuche:

```
Wähle  $X_0 \in S$ , setze  $k = 0$ .
repeat
  Wähle  $Y_k$  zufällig gleichverteilt aus  $S$ .
  Falls  $f(Y_k) < f(X_k)$  dann  $X_{k+1} = Y_k$ 
                        sonst  $X_{k+1} = X_k$ 
until Terminierung
```



Folgerung:

Solche Aussagen sind von geringer Bedeutung, weil δ astronomisch klein!

Beispiel:

alle Bits müssen invertiert werden $\Rightarrow p^n = n^{-n} = \delta$

Übergang zum Optimum erfolgt mit W'keit δ (geometrische Verteilung)

\Rightarrow mittlere Zeit bis zum Eintreffen des Ereignisses $1/\delta = n^n$

Sei $n = 20$ und wir haben einen Tera-Hertz-Rechner (10^{12} Iterationen/Sekunde).

Dann warten wir im Mittel $20^{20} / 10^{12}$ Sekunden = $2^{20} \times 10^8$ Sekunden auf Lösung,

also über 3,325 Millionen Jahre!

\Rightarrow Das ist mathematisch gesehen zwar endlich, praktisch jedoch **unendlich!**



Also:

Stochastische Konvergenzaussagen (auch für Simulated Annealing etc.) sind mit Vorsicht zu genießen!

Aber:

Negative Aussage (keine Konvergenz bzw. kein sicheres Besuchen des Optimums) ist schon von Bedeutung!

Beispiel:

Sicheres Auffinden des Optimums in Zeit t mit W'keit $\gamma > 0$.

⇒ Multistart! W'keit des Mißerfolgs sinkt exponentiell schnell!

Allerdings spielt Größe von γ eine Rolle!


$$P \{ \text{mindestens 1 Erfolg bis zum } k\text{-ten Versuch} \} = 1 - (1 - \gamma)^k$$




“Functions of Unication“ (Goldberg/Deb 1993):

Es existiert $g: \{0, 1, \dots, n\} \rightarrow \mathbb{R}$ mit $f(x) = g(\|x\|)$, wobei $\|\cdot\|$ Hamming-Norm.


Beispiel: Counting Ones $f(x) = \|x\|$



$\gamma = 1$



$\gamma = 0.5$



γ klein

NIAH
(needle-in-a-haystick)



Schematischer Ablauf eines Evolutionären Algorithmus

```
Initialisierung der Population
repeat
  Reproduktionsselektion
  Rekombination
  Mutation
  Überlebensselektion
until Abbruch
```

	<u>GA</u>	<u>ES</u>	<u>EP</u>
Initialisierung der Population	x	x	x
Reproduktionsselektion	x	-	-
Rekombination	x	x	-
Mutation	x	x	x
Überlebensselektion	-	x	x

Heute: Keine Unterscheidung zwischen GA / ES / EP, da Übergänge fließend



EA im \mathbb{R}^n

Selektion: unabhängig von Representation

Rekombination: k-Punkt-Crossover, Uniform Crossover
funktioniert auf allen Produkträumen!

zusätzlich:

Intermediäre Rekombination $z_i = \alpha_i x_i + (1-\alpha_i) y_i$, $\alpha_i \in (0,1)$

$\alpha_i \equiv \alpha$: auf Verbindungslinie zwischen x und y
sonst innerhalb des durch x und y definierten Hyperrechtecks

auch: Varianten mit > 2 Eltern

Mutation: additiv via Normalverteilung $N(0, C)$, C Kovarianzmatrix
häufig: $C = \sigma^2 \cdot I_n$ oder individuelle σ_i


auch: Cauchyverteilung („Levy flights“) oder Mixturen

notwendig: Anpassung von C bzw. σ_i während Suche!




Forderungen an Such- / Mutationsverteilung von m_k

1. Keine Richtung ohne Grund bevorzugen → Symmetrie um 0
2. Kleine Änderungen wahrscheinlicher als große → Unimodal mit Modus 0
3. Steuerbar: Größe der Umgebung, Streuung → Parametrisierbar
4. Leicht erzeugbar
5. ...




symmetrisch, multimodal



symmetrisch, unimodal



Gleichverteilung $f_m(x) = \frac{1}{2r} \cdot \mathbf{1}_{(-r,r)}(x)$




- symmetrisch
- unimodal
- steuerbar $\rightarrow r$
- leicht erzeugbar:

$$m = r(2u - 1)$$

wobei $u \in [0, 1)$
gleichverteilt
(aus Bibliothek)




Betaverteilung $f_m(x) = \frac{r^{1-2p}}{\sqrt{\pi}} \cdot \frac{\Gamma(p + \frac{1}{2})}{\Gamma(p)} (1 - x^2)^{p-1} \cdot 1_{(-r,r)}(x)$



- symmetrisch
- unimodal
- steuerbar $\rightarrow r, p$
- leicht erzeugbar (Bibliothek)




Normalverteilung $f_m(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{x^2}{2\sigma^2}\right)$



- symmetrisch
- unimodal
- steuerbar $\rightarrow \sigma$
- nicht ganz so leicht erzeugbar (Bibliothek)



Cauchyverteilung $f_m(x) = \frac{1}{c\pi} \cdot \frac{1}{1 + \left(1 + \frac{x}{c}\right)^2}$




- symmetrisch
- unimodal
- steuerbar $\rightarrow c$
- leicht erzeugbar (Bibliothek)

Besonderheit:
unendliche Varianz



Höherdimensionale Suchräume: Symmetrie? Unimodalität? Steuerbarkeit?



Rotationssymmetrie

Definition:

Sei T eine $(n \times n)$ -Matrix mit $T^T T = I_n$. (I_n : n -dim. Einheitsmatrix)

T heißt **orthogonale Matrix** oder **Rotationsmatrix**. ■

Beispiel:

$$T = \begin{pmatrix} \cos \omega & -\sin \omega \\ \sin \omega & \cos \omega \end{pmatrix}$$

$y = T^T x \Rightarrow$ Vektor x wurde um Winkel ω gedreht



Definition:

n-dimensionaler Zufallsvektor x heißt

sphärisch symmetrisch oder ***rotationssymmetrisch***


$\Leftrightarrow x \stackrel{d}{=} T'x$ für jede orthogonale Matrix T . ■

$x \stackrel{d}{=} y$ bedeutet: x hat die gleiche Verteilung wie y

Beispiel: Gleichverteilung auf Kreis (Hyperkugel der Dimension $n = 2$)

u gleichverteilt in $[0, 1]$ $\Rightarrow \omega = 2\pi u$

$$x \stackrel{d}{=} \begin{pmatrix} \cos \omega \\ \sin \omega \end{pmatrix}$$





Satz:

Zufallsvektor x rotationssymmetrisch $\Leftrightarrow x \stackrel{d}{=} r u^{(n)}$, wobei

r nichtnegative Zufallsvariable und

$u^{(n)}$ Zufallsvektor mit Gleichverteilung auf n -dim. Hyperkugelrand mit Radius 1. ■

Bemerkung:

r und $u^{(n)}$ sind stochastisch unabhängig, $u^{(n)} \stackrel{d}{=} \frac{x}{\|x\|}$

Erzeugung von rotationssymmetrischen Zufallsvektoren:

1. Wähle zufällige Richtung $u^{(n)}$
2. Wähle zufällige Schrittweite r
3. Multiplikation: $x = r u^{(n)}$



Beispiel: Multivariate Normalverteilung

Zufallsvektor m erzeugbar via

1. $m = \sigma \cdot (m_1, m_2, \dots, m_n)$,
wobei $m_i \sim N(0, 1)$ stoch. unabh., oder

2. $m = r \cdot u$, wobei $r \sim \chi_n(\sigma)$, $u \sim U(\partial S_n(1))$.

↑
 χ -Verteilung mit
n Freiheitsgraden

↑
Gleichverteilung
auf Hyperkugelrand

$$\partial S_n(r) = \{ x \in \mathbb{R}^n : \| x \| = r \} \quad \text{Hyperkugelrand}$$



Beispiel: Multivariate Cauchyverteilung

Zufallsvektor m erzeugbar via

1. $m = \sigma \cdot (m_1, m_2, \dots, m_n) / m_0$,
wobei $m_i \sim N(0, 1)$ stoch. unabh., oder

2. $m = r \cdot u$, wobei $r/n \sim F_{n,1}$, $u \sim U(\partial S_n(1))$.

F-Verteilung mit $(n, 1)$
Freiheitsgraden

↑
Gleichverteilung
auf Hyperkugelrand

Achtung:

Zufallsvektor aus n unabh. Cauchy-Zufallsvariablen nicht rotationssymmetrisch!



Optimierung ohne „Anpassen“ (reine Zufallssuche)

$$f(x) = \|x\|^2 = x'x \rightarrow \min! \text{ wobei } x \in S_n(r) = \{x \in \mathbb{R}^n : \|x\| \leq r\}$$

Z_k ist gleichverteilt in $S_n(r)$

$$X_{k+1} = Z_k \text{ falls } f(Z_k) < f(X_k), \text{ sonst } X_{k+1} = X_k$$

$$\Rightarrow V_k = \min \{ f(Z_1), f(Z_2), \dots, f(Z_k) \} \quad \text{bester ZF-Wert bis Iteration } k$$

$$P\{ \|Z\| \leq x \} = P\{ Z \in S_n(x) \} = \text{Vol}(S_n(x)) / \text{Vol}(S_n(r)) = (x/r)^n, \quad 0 \leq x \leq r$$

$$P\{ \|Z\|^2 \leq x \} = P\{ \|Z\| \leq x^{1/2} \} = x^{n/2} / r^n, \quad 0 \leq x \leq r^2$$

$$P\{ V_k \leq x \} = 1 - (1 - P\{ \|Z\|^2 \leq x \})^k = 1 - (1 - x^{n/2} / r^n)^k$$

$$E[V_k] \rightarrow r^2 \Gamma(1 + 2/n) k^{-2/n} \quad \text{für große } k$$




Optimierung ohne „Anpassen“ (lokal gleichverteilt)

$f(x) = \|x\|^2 = x'x \rightarrow \min!$ wobei $x \in S_n(r) = \{x \in \mathbb{R}^n : \|x\| \leq r\}$

Z_k ist gleichverteilt in $[-r, r]$, $n = 1$

$X_{k+1} = X_k + Z_k$ falls $f(X_k + Z_k) < f(X_k)$, sonst $X_{k+1} = X_k$



ohne Anpassung:

$$D_k \sim \mathcal{O}(k^{-2/n})$$

ab hier:
wie reine
Zufallssuche!



Analyse

(1, λ)-EA mit $f(x) = \|x\|^2$

$$\begin{aligned}\|Y_k\|^2 &= \|X_k + r_k U_k\|^2 = (X_k + r_k U_k)' (X_k + r_k U_k) \\ &= X_k' X_k + 2r_k X_k' U_k + r_k^2 U_k' U_k \\ &= \|X_k\|^2 + 2r_k \underbrace{X_k' U_k}_{= 1} + r_k^2 \|U_k\|^2 = \|X_k\|^2 + 2X_k' U_k + r_k^2\end{aligned}$$

da das zufällige Skalarprodukt $x'U$ die gleiche Verteilung hat wie $\|x\| B$, wobei Zufallsvariable B betaverteilt mit Parametern $(n-1)/2$ auf $[-1, 1]$ ist, folgt

$$\|Y_k\|^2 = \|X_k\|^2 + 2r_k \|X_k\| B + r_k^2$$

da der $(1, \lambda)$ den besten Wert aus λ Versuchen selektiert, folgt

$$\|X_{k+1}\|^2 = \|X_k\|^2 + 2r_k \|X_k\| B_{1:\lambda} + r_k^2$$



$$\| X_{k+1} \|^2 = \| X_k \|^2 + 2r_k \| X_k \| B_{1:\lambda} + r_k^2$$

↓ bedingte Erwartungswerte auf beiden Seiten

$$E\| X_{k+1} \|^2 = \| X_k \|^2 + 2r_k \| X_k \| E[B_{1:\lambda}] + r_k^2$$

↓ Ansatz: $r_k = \gamma \| X_k \|^2$

$$E\| X_{k+1} \|^2 = \| X_k \|^2 + 2\gamma \| X_k \|^3 E[B_{1:\lambda}] + \gamma^2 \| X_k \|^4$$

↓ wg. Symmetrie von B folgt $E[B_{1:\lambda}] = -E[B_{\lambda:\lambda}] < 0$

$$\begin{aligned} E\| X_{k+1} \|^2 &= \| X_k \|^2 - 2\gamma \| X_k \|^3 E[B_{\lambda:\lambda}] + \gamma^2 \| X_k \|^4 \\ &= \| X_k \|^2 (1 - 2\gamma E[B_{\lambda:\lambda}] + \gamma^2) \end{aligned}$$

mit Anpassung:

$$D_k \sim \mathcal{O}(c^k), c \in (0,1)$$

Parabelscheitel bei $\gamma^* = E[B_{\lambda:\lambda}]$, also $E\| X_{k+1} \|^2 = \| X_k \|^2 (1 - E[B_{\lambda:\lambda}]^2)$



Praktisches Problem:

Woher bekommen wir $\| X_k \|$ bei $r_k = \| X_k \| \cdot E[B_{\lambda:\lambda}]$?


Wir wissen aus Analyse: $E\| X_{k+1} \|^2 = \| X_k \|^2 (1 - E[B_{\lambda:\lambda}]^2)$

Annahme: r_k war optimal eingestellt

$$\Rightarrow r_{k+1} = \| X_{k+1} \| E[B_{\lambda:\lambda}] \approx \| X_k \| \underbrace{(1 - E[B_{\lambda:\lambda}]^2)^{1/2} E[B_{\lambda:\lambda}]}_{\text{Konstante!}}$$

\Rightarrow altes r_k mit Konstante multiplizieren: $r_{k+1} = c \cdot r_k$

aber: woher bekommen wir r_0 bzw. $\| X_0 \|$?






(1+1)-EA mit Schrittweitenanpassung (1/5-Erfolgsregel, Rechenberg 1973)

Idee:

- Wenn viele erfolgreiche Mutationen, dann Schrittweite zu klein.
- Wenn wenige erfolgreiche Mutationen, dann Schrittweite zu groß.

bei infinitesimal
kleinem Radius ist
Erfolgsrate = $1/2$




Ansatz:

- Protokolliere erfolgreiche Mutationen in gewissem Zeitraum
- Wenn Anteil größer als gewisse Schranke (z. B. $1/5$), dann Schrittweite erhöhen, sonst Schrittweite verringern



Konvergenzproblematik bei der Schrittweitenanpassung



Annahme: $X_0 = 0$

Frage: Wird lokales Optimum sicher verlassen (Übergang zu $[z-\delta, z+\delta]$) ?



Sei q_k Wahrscheinlichkeit, im Schritt k das lokale Optimum zu verlassen.

Kriterium für sicheres Verlassen:

$$1 - \prod_{k=1}^{\infty} (1 - q_k) = 1 \Leftrightarrow \prod_{k=1}^{\infty} (1 - q_k) = 0 \Leftrightarrow \sum_{k=1}^{\infty} \log \frac{1}{1 - q_k} = \infty$$

Kriterium für unsicheres Verlassen:

$$1 - \prod_{k=1}^{\infty} (1 - q_k) < 1 \Leftrightarrow \prod_{k=1}^{\infty} (1 - q_k) > 0 \Leftrightarrow \sum_{k=1}^{\infty} \log \frac{1}{1 - q_k} < \infty$$

Vereinfachung des log-Terms \longrightarrow



Lemma:

Sei $x \in (0,1)$. Dann gilt: $x < \log \left(\frac{1}{1-x} \right) < \frac{x}{1-x}$

Beweis:

Reihenentwicklung $\log \left(\frac{1}{1-x} \right) - \log(1-x) = \sum_{i=1}^{\infty} \frac{x^i}{i}$

$$\text{also: } 0 < x < \sum_{i=1}^{\infty} \frac{x^i}{i} < \sum_{i=1}^{\infty} x^i = \sum_{i=0}^{\infty} x^i - 1 = \frac{x}{1-x}$$

q.e.d.



Hinreichendes Kriterium für unsicheres Verlassen:

$$\sum_{k=1}^{\infty} \log \frac{1}{1 - q_k} < \sum_{k=1}^{\infty} \frac{q_k}{1 - q_k} < \frac{1}{1 - q_1} \sum_{k=1}^{\infty} q_k < \infty$$

Lemma

weil q_k monoton fallend

$$\begin{aligned} p_k &= P\{0 \rightarrow (z-\delta, z+\delta)\} = P\{z-\delta < Z < z+\delta\} = F_Z(z+\delta) - F_Z(z-\delta) = \\ &= 2 \delta f_Z(z-\delta + \theta \cdot 2 \delta) \quad \text{mit } \theta \in (0,1) \end{aligned}$$

Mittelwertsatz der
Differentialrechnung!

Annahme: Dichte $f_Z(\cdot)$ von Z ist unimodal

dann: $2 \delta f_Z(z+\delta) < p_k < 2 \delta f_Z(z-\delta)$ und deshalb: $q_k = 2 \delta f_Z(z-\delta)$



Z sei normalverteilt

$$f_Z(x) = \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{x^2}{2\sigma^2}\right)$$

$$\begin{aligned} p_k \leq q_k &= \delta \sqrt{\frac{2}{\pi}} \frac{1}{\sigma_k} \exp\left(-\frac{(z - \delta)^2}{2\sigma_k^2}\right) \\ &= A \eta_k \exp(-B \eta_k^2) \end{aligned}$$

wobei

$$A = \delta (2/\pi)^{1/2}, \quad B = (z - \delta)^2/2, \quad \eta_k = 1/\sigma_k.$$

Sei $\eta_k = \eta_0 \beta^k$ mit $\beta = 1/\gamma > 1$

$$\sum_{k=1}^{\infty} \frac{\beta^k}{\exp(B \eta_0^2 \beta^{2k})}$$

konvergiert nach Wurzelkriterium!

⇒ kein sicheres Entkommen von lokalen Optima!

$$\begin{aligned} \sum_{k=0}^{\infty} |a_k| < \infty &\text{ falls} \\ \lim_{k \rightarrow \infty} |a_k|^{1/k} = \alpha < \infty \end{aligned}$$