

# Local Performance of the $(\mu/\mu_I, \lambda)$ -*ES* in a noisy Environment

von Dirk V. Arnold und Hans-Georg Beyer

vorgetragen von  
Lin Himmelmann im April 2003

# 1. $(\mu/\mu_I, \lambda)$ -ES Notation

ES entwickelt sich im Zeitverlauf und durchläuft verschiedene Generationen. Generation besteht aus Eltern und Kindern. Die besten Kinder überleben und bilden Eltern der nächsten Generation.

Population  $\simeq$  Punkte im  $\mathbb{R}^N$   
 $\simeq$  Parametrisierte Lösungskandidaten.


$\lambda$  := Anzahl der Lösungskandidaten, die pro Zeiteinheit neu entstehen. Diese müssen jeweils neu ausgewertet werden.

$\mu$  := Anzahl der ausgewählten besten Lösungskandidaten. Diese bilden in der nächsten Zeiteinheit die Eltern-Generation.


, := Auswahl der Lösungskandidaten erfolgt nur aus den Nachkommen.

$I$  := Variation der neuen Generation erfolgt durch Rekombination (“global Intermediate“) und Mutation.


## 2. $(\mu/\mu_I, \lambda)$ -ES Beispiel




$\lambda$  Initial



$\mu$  auswählen  
 $\langle x \rangle$  berechnen  
 messe  $\langle x \rangle - \hat{x}$



$\lambda$  Neue



mit Rauschen

### 3. Variation:

Gegeben:  $x^i \in \mathbb{R}^N, i = 1, \dots, \mu \cong$  Generation der Eltern.

Wie wird hieraus der Nachwuchs:  $y^j \in \mathbb{R}^N, j = 1, \dots, \lambda$  gebildet?

1. Rekombination:

$$\langle x \rangle := \frac{1}{\mu} \sum_{i=1}^{\mu} x^i$$

2. Mutation:

Seien  $z^j, j = 1, \dots, \lambda$  Vektoren aus  $N$  unabhängigen  $\mathcal{N}(0, \sigma^2)$ -verteilten Zufallsvariablen. Die neue Generation wird gebildet durch:  
 $y^j = \langle x \rangle + z^j, j = 1, \dots, \lambda.$

Hierbei bezeichne  $\sigma$  die Mutationsstärke.

## 4. Selektion

Gegeben:  $y^j \in \mathbb{R}^N, i = 1, \dots, \lambda \cong$  Nachwuchs.

Welche bleiben erhalten? D.h. welche werden die Eltern  $x^i \in \mathbb{R}^N, i = 1, \dots, \mu$  der folgenden Generation?

Die besten  $\mu$ -Lösungskandidaten des Nachwuchses bleiben erhalten.

Definiere hierzu die Fitness-Funktion:

$f : \mathbb{R}^N \rightarrow \mathbb{R}$  durch  $f(x) = \sum_{i=1}^N (\hat{x}_i - x_i)^2$ , für  $x = (x_1, \dots, x_N)$ , mit  $\hat{x} = (\hat{x}_1, \dots, \hat{x}_N) \in \mathbb{R}^N$ .  $\hat{x}$  ist das Optimum in der Fitness-Funktion, d.h. die Werte werden minimiert.

Der Fitness-Vorteil einer Mutation  $z$  zu einem Lösungskandidaten  $x$  wird definiert durch:

$$q_x(z) = f(x) - f(x + z).$$

Für festes  $x$ , ist  $q_x$  eine reellwertige Zufallsvariable, deren Verteilung von der Fitness-Funktion  $f$  und von der Mutationsstärke  $\sigma$  abhängt.

## 5. Maß für die Performance

Es gibt zwei Konzepte um die Performance des  $(\mu/\mu_I, \lambda)$ -ES zu messen. Lokale Performance bedeutet hier von Schritt zu Schritt.

(i) Erwarteter Fitness Gewinn:

Sei  $\langle x \rangle^g$  die Rekombination zum Zeitpunkt bzw. der Generation  $g$ . Der erwartete Fitness Gewinn zum Zeitpunkt  $g$  ist definiert als der Wert  $f(\langle x \rangle^g) - f(\langle x \rangle^{g-1})$ .

(ii) Fortschritt-Rate  $\phi$ :

Sei  $R^g := \|\langle x \rangle^g - \hat{x}\|_2$  der erwartete euklidische Abstand zwischen der Rekombination und dem Optimum der Fitness-Funktion. Die Fortschritts-Rate zum Zeitpunkt  $g$  ist definiert als der erwartete Wert  $R^g - R^{g-1}$ .

(iii) Gibt es ein Konzept, welches ohne  $\hat{x}$  auskommt? Z.B. mit Norm im  $\mathbb{R}^N$ .

Konzept (i) und (ii) stimmen für  $N \rightarrow \infty$  überein.

## 6. Rauschen

In der realen Welt gibt es häufig Störungen, Messfehler etc. Diese werden als Rauschen bezeichnet und wie folgt involviert:


Einem Lösungskandidat  $x$  ordnet man den idealen Fitness-Wert der Größe  $f(x)$  zu.

Der durch Messfehler verfälschte Fitness-Wert wird mit  $f(x) + \sigma_\epsilon \delta$  simuliert.

Hierbei ist  $\delta$  eine  $\mathcal{N}(0, 1)$ -verteilte Zufallsvariable, und  $\sigma_\epsilon \in \mathbb{R}$  steht für die Stärke des Rauschen.

# 7. Performance Berechnung I

Zunächst ein Trick:



Sei  $z = (z_1, \dots, z_N) \in \mathcal{N}(0, \sigma^2) \times \dots \times \mathcal{N}(0, \sigma^2)$  der Mutationsvektor. Nach Zerlegung von  $z$  wie oben in  $z = z_A + z_B = \sigma(z_1, 0, \dots, 0)^T + \sigma(0, z_2, \dots, z_N)^T$ , mit der Mutationsstärke  $\sigma$  und  $z_i \in \mathcal{N}(0, 1)$  gilt:

$$r^2 = (R - \sigma z_1)^2 + \|z_B\|_2^2.$$

Normierungen:

$$\sigma^* = \sigma \frac{N}{R}, \quad \sigma_\epsilon^* = \sigma \epsilon \frac{N}{2R^2}, \quad q_x^*(z) = q_x(z) \frac{N}{2R^2}.$$

$$q_x^*(z) = \frac{N}{2R^2}(R^2 - r^2) \quad \Leftrightarrow$$

$$q_x^*(z) = \sigma^* z_1 - \frac{\sigma^{*2}}{2N} - \frac{\sigma^{*2}}{2N} \sum_{i=2}^N z_i^2 \quad \stackrel{R?}{\Leftrightarrow}$$

$$q^*(z) = \sigma^* z_1 - \frac{\sigma^{*2}}{2N} - \frac{\sigma^{*2}}{2N} \sum_{i=2}^N z_i^2 \quad \stackrel{N \rightarrow \infty}{\Leftrightarrow}$$

$$q^*(z) = \sigma^* z_1 - \frac{\sigma^{*2}}{2}$$

## 8. Performance Berechnung II

Der idealisierte Fitness Vorteil ist:

$$q^*(z) = \sigma^* z_1 - \frac{\sigma^{*2}}{2}.$$

Selektion findet auf Basis des wahrgenommenen Fitness Vorteil statt ( $\tau := \sigma_\epsilon^*/\sigma^*$ ):

$$q^*(z) + \sigma_\epsilon^* \delta = \sigma^*(z_1 + \tau \delta) - \frac{\sigma^{*2}}{2}.$$

Die  $\mu$  Kandidaten aus dem Nachwuchs mit der höchsten gemessenen Fitness werden ausgewählt. Der Fortschrittsvektor ( $\langle x \rangle^{g-1} \rightarrow \langle x \rangle^g$ ) ist dann:  $\langle z \rangle = \frac{1}{\mu} \sum_{k=1}^{\mu} z^{(k,\lambda)}$ .

Es folgt der erwartete Fitness-Gewinn:

$$\begin{aligned} q^*(\langle z \rangle) &\stackrel{\forall x}{=} \frac{N}{2R^2} (f(x) - f(x + \langle z \rangle)) \\ &= \sigma^* \langle z_1 \rangle - \frac{\sigma^{*2}}{2N} \langle z_1 \rangle - \frac{\sigma^{*2}}{2N} \sum_{i=2}^N \langle z_i \rangle^2 \\ &= \frac{\sigma^* c_{\mu/\mu_I, \lambda}}{\sqrt{1+\tau^2}} - \frac{\sigma^{*2}}{2\mu}, \end{aligned}$$

mit dem Fortschrittskoeffizienten:

$$c_{\mu/\mu_I, \lambda} := \frac{\lambda - \mu}{2\pi} \int_{-\infty}^{\infty} e^{-x^2} (\Phi(x))^{\lambda - \mu - 1} (1 - \Phi(x))^{\mu - 1} dx.$$

Und daraus die normalisierte Fortschritts-Rate:


$$\phi^* = \frac{\sigma^* c_{\mu/\mu_I, \lambda}}{\sqrt{1+\tau^2}} - \frac{\sigma^{*2}}{2\mu}.$$

## 9. Ergebnis Mutationsstärke

Numerisches lösen von  $\phi^* = \frac{\sigma^* c_{\mu/\mu_I, \lambda}}{\sqrt{1+\tau^2}} - \frac{\sigma^{*2}}{2\mu}$ .

Je nach Stärke des Rauschens wird die normierte Mutationsstärke optimiert, so dass die Fortschrittsrate maximal ist.

opt. Mutationsstärke  $\hat{\sigma}^*/(\hat{\sigma}^*|_{\sigma_\epsilon^*=0})$



Stärke des Rauschens  $\sigma_\epsilon^*/(\hat{\sigma}^*|_{\sigma_\epsilon^*=0})$

Aus dieser und der nächsten Abbildung folgt, dass stets positive Fortschrittsraten erreichbar sind (bei optimierter Mutationsstärke), wenn die Stärke des Rauschens unter  $2\mu c_{\mu/\mu_I, \lambda}$  bleibt. ( $\hat{\sigma}^*|_{\sigma_\epsilon^*=0} = \mu c_{\mu/\mu_I, \lambda}$ ).


# 10. Ergebnis Fortschrittsrate

Durch eine Populationserhöhung ist immer eine positive Fortschritts Rate erreichbar! Die Stärke des Rauschens muss nur unter  $2\mu c_{\mu/\mu_I,\lambda}$  liegen.

Achsenkalierung:

$$\hat{\sigma}^*|_{\sigma_\epsilon^*=0} = \mu c_{\mu/\mu_I,\lambda}, \quad \hat{\phi}^*|_{\sigma_\epsilon^*=0} = \mu c_{\mu/\mu_I,\lambda}^2 / 2.$$

max. Fortschritts-Rate  $\hat{\phi}^* / (\hat{\phi}^*|_{\sigma_\epsilon^*=0})$



Stärke des Rauschens  $\sigma_\epsilon^* / (\hat{\sigma}^*|_{\sigma_\epsilon^*=0})$

Grund ist genetic repair:  $\phi^* = \frac{\sigma^* c_{\mu/\mu_I,\lambda}}{\sqrt{1+\tau^2}} - \frac{\sigma^{*2}}{2\mu}$ .

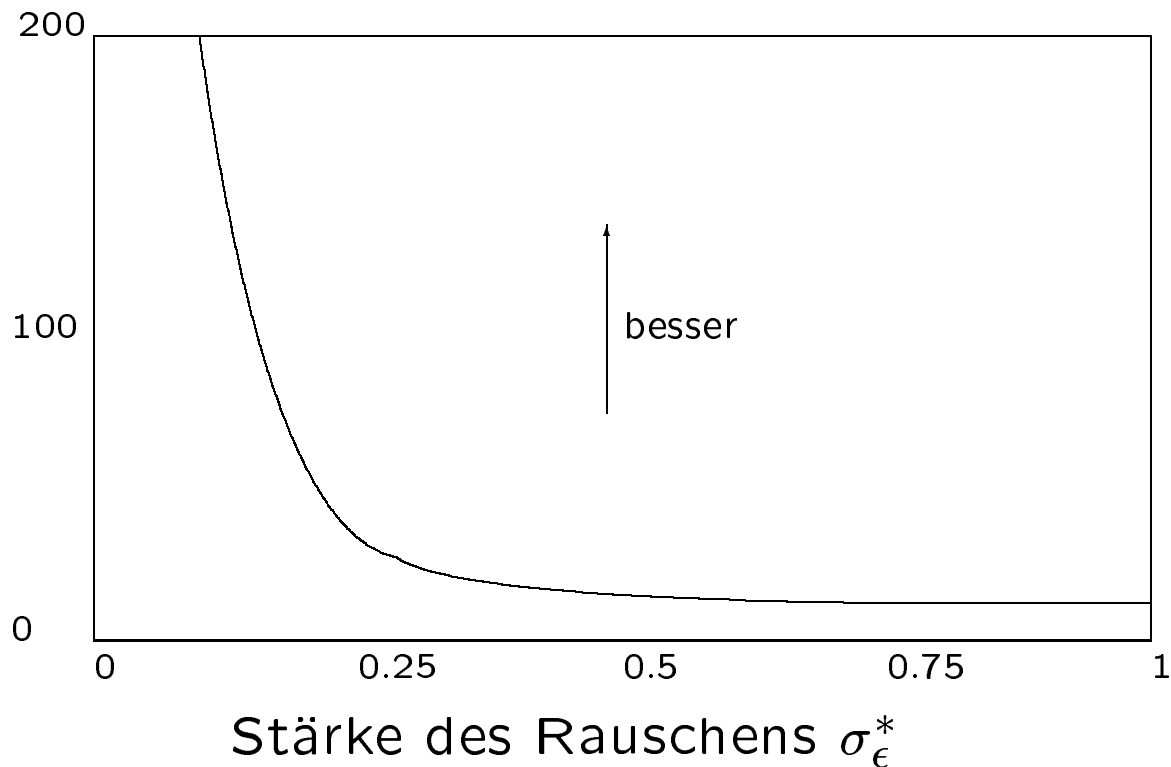
Beim  $(1, \lambda)$ -ES nicht möglich (nur bis  $2c_{1,\lambda}$ ).

# 11. Ergebnis Nachkommen

Die Effizienz  $\eta$  eines  $ES$  ist die normalisierte Fortschrittsrate pro Auswertung der Fitness-Funktion, bei optimaler Mutations-Rate.

Die Abbildung zeigt die Anzahl der Nachkommen, bei denen ein optimaler  $(\mu/\mu_I, \lambda) - ES$  den optimalen  $(1 + 1) - ES$  übertrifft. Dies geschieht schon bei geringer Anzahl  $\lambda$ .

Anzahl der Nachkommen  $\lambda$



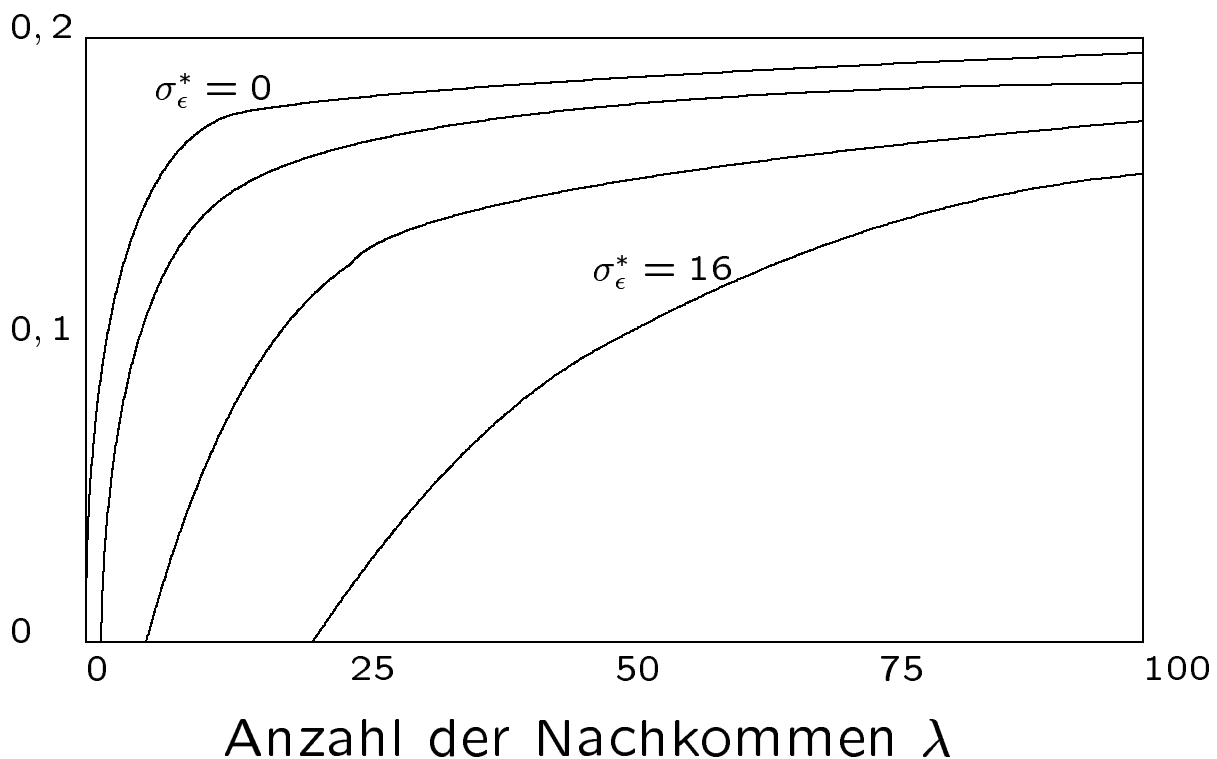
Ohne Rauschen kann der  $(1 + 1) - ES$  durch einen  $(\mu/\mu_I, \lambda) - ES$  nicht übertroffen werden.

## 12. Ergebnis Effizienz

Diese Abbildung zeigt die maximale Effizienz des  $(\mu/\mu_I, \lambda) - ES$  mit optimaler Anzahl an Nachkommen  $\mu$  als Funktion von  $\lambda$ .

Die unterschiedlichen Kurven spiegeln unterschiedliche Rausch-Pegel dar. Das Rauschen nimmt von oben nach unten zu.

max. Effizienz



Falls die Population genügend groß ist, wird die maximale Effizienz in rauschfreier Umgebung asymptotisch bei 0,202 angenähert.

## 13. Bewertung der Ergebnisse

Aufgrund der Unendlichkeitsbetrachtungen sind die Ergebnisse für endlich dimensionale  $N$  eher begrenzt.

Für sehr große  $N$  macht man Fehler, wenn man  $\sigma^*$  ( $= \sigma \frac{N}{R}$ ) klein wählt. Betrachtung der Fehlerfortpflanzung!

Dennoch gute Verallgemeinerung:

(i) Für  $\sigma_\epsilon^* = 0$  bekommt man das gleiche Ergebnis, wie bei der Analyse in einer Umgebung ohne Rauschen.

(ii) Der Fall für  $\mu = 1$  mit Rauschen, ist ebenfalls als Spezialfall enthalten.

(iii) Empirische Untersuchungen der Performance von Herdy bestätigen die Resultate.