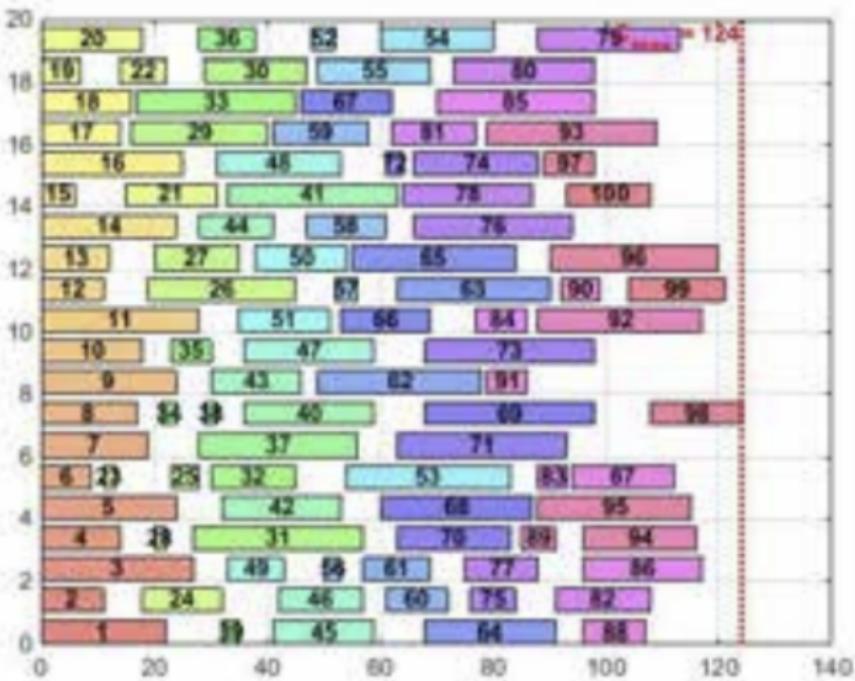


Covariance matrix adaptation evolution strategy (CMA-ES)

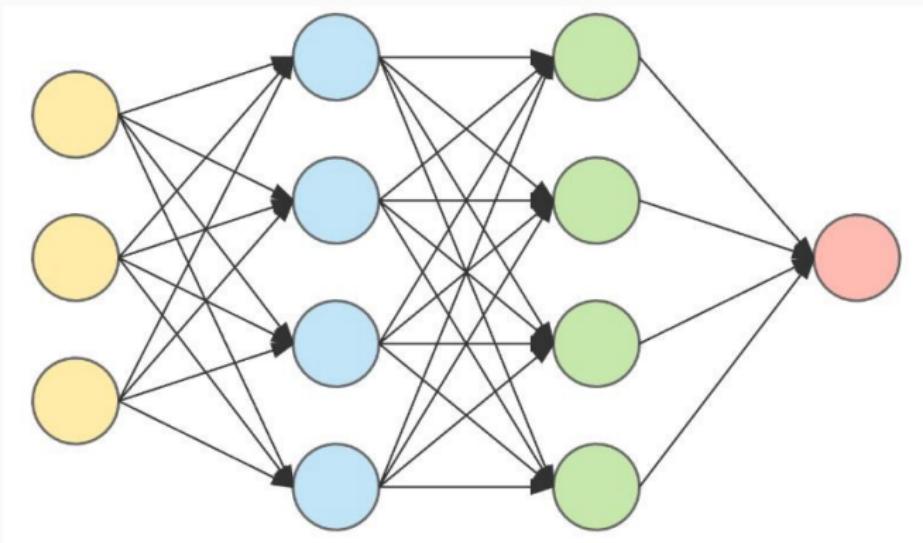
Mikołaj Słupiński

Zastosowania



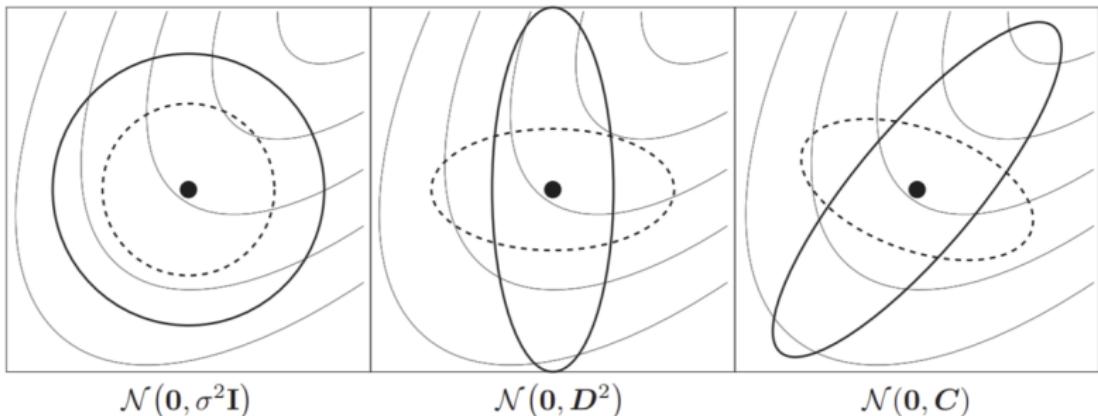
Task Scheduling Algorithm Using Covariance Matrix Adaptation Evolution Strategy (CMA-ES) in Cloud Computing Ghazaal Emadi et al.

Zastosowania



CMA-ES for Hyperparameter Optimization of Deep Neural Networks Ilya
Loshchilov et al.

Rozkład normalny



Rozkład normalny

$$C = BD^2B^\top$$

Rozkład normalny

$$\begin{aligned} C^{-1} &= \left(B D^2 B^\top \right)^{-1} \\ &= B^{\top -1} D^{-2} B^{-1} \\ &= B D^{-2} B^\top \\ &= B \operatorname{diag} \left(\frac{1}{d_1^2}, \dots, \frac{1}{d_n^2} \right) B^\top. \end{aligned}$$

Rozkład normalny

$$\begin{aligned} C^{-\frac{1}{2}} &= BD^{-1}B^\top \\ &= B \operatorname{diag} \left(\frac{1}{d_1}, \dots, \frac{1}{d_n} \right) B^\top \end{aligned}$$

Rozkład normalny

$$\begin{aligned}\mathcal{N}(m, C) &\sim m + \mathcal{N}(\mathbf{0}, C) \\ &\sim m + C^{\frac{1}{2}} \mathcal{N}(\mathbf{0}, \mathbf{I}) \\ &\sim m + \underbrace{B D B^\top}_{\sim \mathcal{N}(\mathbf{0}, \mathbf{I})} \mathcal{N}(\mathbf{0}, \mathbf{I}) \\ &\sim m + \underbrace{B D \mathcal{N}(\mathbf{0}, \mathbf{I})}_{\sim \mathcal{N}(\mathbf{0}, D^2)},\end{aligned}$$

Schemat algorytmu

```
initialization  $m, \sigma, C = I, p_\sigma = 0, p_c = 0$ ;  
while not terminate do  
    for  $i \in \{1 \dots \lambda\}$  do  
         $x_i = sample(m, \sigma^2 C)$ ;  
         $f_i = fitness(x_i)$   
    end  
     $X_{1\dots\lambda} \leftarrow X_{s(1)\dots s(\lambda)}$ ;  
     $m' = m$ ;  
     $m \leftarrow update\_m(x_1, \dots, x_\lambda)$ ;  
     $p_\sigma \leftarrow update\_ps(p_\sigma, \sigma^{-1} C^{-1/2} (m - m'))$ ;  
     $p_c \leftarrow update\_pc(p_c, \sigma^{-1} (m - m'), \|p_\sigma\|)$ ;  
     $C \leftarrow update\_c(C, p_c, (x_1 - m') / \sigma, \dots, (x_\lambda - m') / \sigma)$ ;  
     $\sigma \leftarrow update\_sigma(\sigma, \|p_\sigma\|)$ ;  
end  
return  $x_1$ 
```

$$x_k^{(g+1)} \sim m^{(g)} + \sigma^{(g)} \mathcal{N}(0, C^{(g)}) \quad \text{for } k = 1, \dots, \lambda$$

Skąd wziąć $m^{(g)}$, $C^{(g)}$, $\sigma^{(g+1)}$?

Selekcja i rekombinacja

$$\begin{aligned} \mathbf{m}^{(g+1)} &= \sum_{i=1}^{\mu} w_i \mathbf{x}_{i:\lambda}^{(g+1)} \\ \sum_{i=1}^{\mu} w_i &= 1, \quad w_1 \geq w_2 \geq \dots \geq w_{\mu} > 0 \end{aligned}$$

$\mathbf{x}_{i:\lambda}$ oznacza x_k o i -tej najmniejszej wartości funkcji celu

$$\mu_{\text{eff}} = \left(\frac{\|\mathbf{w}\|_1}{\|\mathbf{w}\|_2} \right)^2 = \frac{\|\mathbf{w}\|_1^2}{\|\mathbf{w}\|_2^2} = \frac{\left(\sum_{i=1}^{\mu} |w_i| \right)^2}{\sum_{i=1}^{\mu} w_i^2} = \frac{1}{\sum_{i=1}^{\mu} w_i^2}$$

Dobre założenia:

$$1 \leq \mu_{\text{eff}} \leq \mu$$

$$\mu_{\text{eff}} \approx \lambda/4$$

$$w_i \propto \mu - i + 1$$

Aktualizacja średniej

$$\mathbf{m}^{(g+1)} = \mathbf{m}^{(g)} + c_m \sum_{i=1}^{\mu} w_i \left(\mathbf{x}_{i:\lambda}^{(g+1)} - \mathbf{m}^{(g)} \right)$$

Estymacja macierzy kowariancji

$$\mathbf{C}_{\text{emp}}^{(g+1)} = \frac{1}{\lambda - 1} \sum_{i=1}^{\lambda} \left(\mathbf{x}_i^{(g+1)} - \frac{1}{\lambda} \sum_{j=1}^{\lambda} \mathbf{x}_j^{(g+1)} \right) \left(\mathbf{x}_i^{(g+1)} - \frac{1}{\lambda} \sum_{j=1}^{\lambda} \mathbf{x}_j^{(g+1)} \right)^{\top}$$

$$\mathbf{C}_{\lambda}^{(g+1)} = \frac{1}{\lambda} \sum_{i=1}^{\lambda} \left(\mathbf{x}_i^{(g+1)} - \mathbf{m}^{(g)} \right) \left(\mathbf{x}_i^{(g+1)} - \mathbf{m}^{(g)} \right)^{\top}$$

Estymacja macierzy kowariancji

$$\mathbf{C}_\mu^{(g+1)} = \sum_{i=1}^{\mu} w_i \left(\mathbf{x}_{i:\lambda}^{(g+1)} - \mathbf{m}^{(g)} \right) \left(\mathbf{x}_{i:\lambda}^{(g+1)} - \mathbf{m}^{(g)} \right)^\top$$

Estymacja macierzy kowariancji

Aby $C_\mu^{(g+1)}$ było wiarygodnym estymatorem, wartość μ_{eff} musi być dostatecznie duża: otrzymanie wskaźnika uwarunkowania niższego niż dziesięć dla $C_\mu^{(g)}$ dla $f_{\text{sphere}}(\mathbf{x}) = \sum_{i=1}^n x_i^2$, wymaga $\mu_{\text{eff}} \approx 10n$.

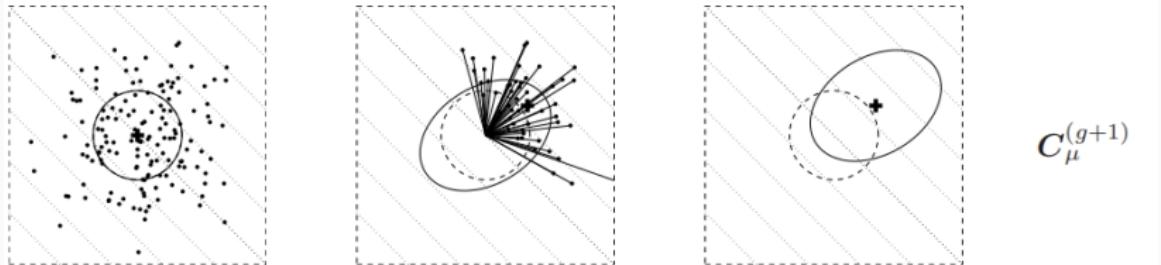
Zauważmy, że żeby przeszukiwanie było szybkie, to λ musi być małe. Powiedzieliśmy wcześniej, że zazwyczaj $\mu_{\text{eff}} \approx \lambda/4$, a zatem również μ_{eff} musi być małe.

Jak zatem z tego wybrnąć?

Rank- μ -Update

$$C^{(g+1)} = \frac{1}{g+1} \sum_{i=0}^g \frac{1}{\sigma^{(i)^2}} C_\mu^{(i+1)}$$

Rank- μ -Update



The CMA Evolution Strategy: A Tutorial N.Hansen

Rank- μ -Update

$$\begin{aligned} C^{(g+1)} &= (1 - c_\mu) C^{(g)} + c_\mu \frac{1}{\sigma^{(g)} 2} C_\mu^{(g+1)} \\ &= (1 - c_\mu) C^{(g)} + c_\mu \sum_{i=1}^{\mu} w_i y_{i:\lambda}^{(g+1)} {y_{i:\lambda}^{(g+1)}}^\top \end{aligned}$$

$$y_{i:\lambda}^{(g+1)} = \left(x_{i:\lambda}^{(g+1)} - m^{(g)} \right) / \sigma^{(g)}$$

Rank- μ -Update

$$\begin{aligned}\mathcal{C}^{(g+1)} &= \left(1 - c_\mu \sum w_i\right) \mathcal{C}^{(g)} + c_\mu \sum_{i=1}^{\lambda} w_i \mathbf{y}_{i:\lambda}^{(g+1)} \mathbf{y}_{i:\lambda}^{(g+1)\top} \\ &= \mathcal{C}^{(g)^{1/2}} \left(\mathbf{I} + c_\mu \sum_{i=1}^{\lambda} w_i \left(\mathbf{z}_{i:\lambda}^{(g+1)} \mathbf{z}_{i:\lambda}^{(g+1)\top} - \mathbf{I} \right) \right) \mathcal{C}^{(g)^{1/2}} \\ c_\mu &\approx \mu_{\text{eff}} / n^2 \\ \mathbf{z}_{i:\lambda}^{(g+1)} &= \mathcal{C}^{(g)^{-1/2}} \mathbf{y}_{i:\lambda}^{(g+1)}\end{aligned}$$

Rank-One-Update

$$\mathcal{N}(0, 1)\mathbf{y}_1 + \cdots + \mathcal{N}(0, 1)\mathbf{y}_{g_0} \sim \mathcal{N}\left(\mathbf{0}, \sum_{i=1}^{g_0} \mathbf{y}_i \mathbf{y}_i^\top\right)$$

$$\mathcal{C}^{(g+1)} = (1 - c_1) \mathcal{C}^{(g)} + c_1 \mathbf{y}_{g+1} \mathbf{y}_{g+1}^\top$$

Ścieżka ewolucji

$$\frac{m^{(g+1)} - m^{(g)}}{\sigma^{(g)}} + \frac{m^{(g)} - m^{(g-1)}}{\sigma^{(g-1)}} + \frac{m^{(g-1)} - m^{(g-2)}}{\sigma^{(g-2)}}$$
$$p_c^{(g+1)} = (1 - c_c) p_c^{(g)} + \sqrt{c_c (2 - c_c) \mu_{\text{eff}}} \frac{m^{(g+1)} - m^{(g)}}{\sigma^{(g)}}$$
$$p_c^{(g+1)} \sim \mathcal{N}(0, C)$$
$$C^{(g+1)} = (1 - c_1) C^{(g)} + c_1 p_c^{(g+1)} p_c^{(g+1)\top}$$

Finalne równanie macierzy kowariancji

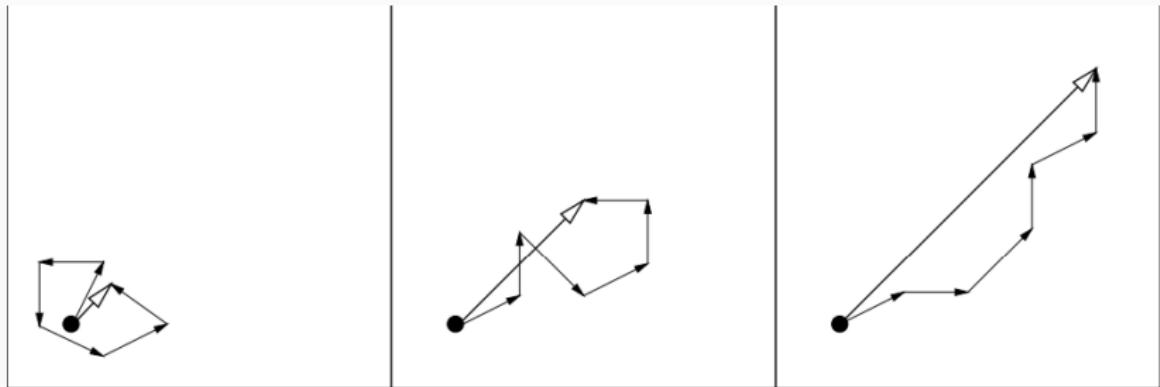
$$\begin{aligned} \mathbf{C}^{(g+1)} &= \underbrace{\left(1 - c_1 - c_\mu \sum w_j\right)}_{\text{can be close or equal to 0}} \mathbf{C}^{(g)} \\ &\quad + c_1 \underbrace{\mathbf{p}_c^{(g+1)} \mathbf{p}_c^{(g+1)\top}}_{\text{rank-one update}} + c_\mu \underbrace{\sum_{i=1}^{\lambda} w_i \mathbf{y}_{i:\lambda}^{(g+1)} \left(\mathbf{y}_{i:\lambda}^{(g+1)}\right)^\top}_{\text{rank-}\mu\text{ update}} \end{aligned} \quad (30)$$

$$c_1 \approx 2/n^2$$

$$c_\mu \approx \min\left(\mu_{\text{eff}}/n^2, 1 - c_1\right)$$

$$\mathbf{y}_{i:\lambda}^{(g+1)} = \left(\mathbf{x}_{i:\lambda}^{(g+1)} - \mathbf{m}^{(g)}\right) / \sigma^{(g)}$$

Kontrola rozmiaru kroku



The CMA Evolution Strategy: A Tutorial N.Hansen

Cumulative step length adaptation (CSA)

$$p_{\sigma}^{(g+1)} = (1 - c_{\sigma}) p_{\sigma}^{(g)} + \sqrt{c_{\sigma} (2 - c_{\sigma}) \mu_{\text{eff}}} C^{(g)^{-\frac{1}{2}}} \frac{m^{(g+1)} - m^{(g)}}{\sigma^{(g)}}$$

Aktualizacja σ

$$\ln \sigma^{(g+1)} = \ln \sigma^{(g)} + \frac{c_\sigma}{d_\sigma} \left(\frac{\|p_\sigma^{(g+1)}\|}{E\|\mathcal{N}(0, I)\|} - 1 \right)$$

$$d_\sigma \approx 1$$

$$E\|\mathcal{N}(0, I)\| = \sqrt{2}\Gamma\left(\frac{n+1}{2}\right) / \Gamma\left(\frac{n}{2}\right)$$

Uzasadnienie doboru parametrów można znaleźć w *Verallgemeinerte individuelle Schrittweitenregelung in der Evolutionsstrategie* Hansen N.

Aktualizacja σ

$$\sigma^{(g+1)} = \sigma^{(g)} \exp \left(\frac{c_\sigma}{d_\sigma} \left(\frac{\|p_\sigma^{(g+1)}\|}{E\|\mathcal{N}(0, I)\|} - 1 \right) \right)$$

Finalny algorytm

```
initialization  $m, \sigma, C = I, p_\sigma = 0, p_c = 0$ ;  
while not terminate do  
    for  $i \in \{1 \dots \lambda\}$  do  
         $x_i = sample(m, \sigma^2 C)$ ;  
         $f_i = fitness(x_i)$   
    end  
     $X_{1\dots\lambda} \leftarrow X_{s(1)\dots s(\lambda)}$ ;  
     $m' = m$ ;  
     $m \leftarrow update\_m(x_1, \dots, x_\lambda)$ ;  
     $p_\sigma \leftarrow update\_ps(p_\sigma, \sigma^{-1} C^{-1/2} (m - m'))$ ;  
     $p_c \leftarrow update\_pc(p_c, \sigma^{-1} (m - m'), \|p_\sigma\|)$ ;  
     $C \leftarrow update\_c(C, p_c, (x_1 - m') / \sigma, \dots, (x_\lambda - m') / \sigma)$ ;  
     $\sigma \leftarrow update\_sigma(\sigma, \|p_\sigma\|)$ ;  
end  
return  $x_1$ 
```

Przebieg algorytmu

