

# Wahrscheinlichkeitstheorie und Statistik

## Serie 11 - Lösungen

**Aufgabe 11-1 (Lösungsbegriff der Bayesianische Optimierung).** Für eine nicht-negative Zufallsvariable  $L$  auf einem Wahrscheinlichkeitsraum  $(\Theta, \mathcal{A}, \pi_0)$  definieren wir rekursiv die Folge von Wahrscheinlichkeitsmassen

$$\pi_n(d\theta) = \frac{\exp(-L(\theta))\pi_{n-1}(d\theta)}{\int_{\Theta} \exp(-L(\theta))\pi_{n-1}(d\theta)}, \quad n = 1, 2, \dots$$

Zeigen Sie, dass  $\lim_{n \rightarrow \infty} \pi_n(A) = 0$  für jedes Ereignis  $A \in \mathcal{A}$ , sodass

$$\exists \delta > 0 : \quad \text{ess inf}_{\theta \in A} L(\theta) \geq \delta + \text{ess inf}_{\theta \in \Theta} L(\theta).$$

Die Interpretation dieser Aussage ist, dass sich  $\pi_n$  für grosses  $n$  an Minima von  $L$  konzentriert.

**Lösung:** Wir greifen auf die in der Vorlesung bewiesenen Aussage zurück, dass

$$m := \text{ess-inf}_{\theta \in \Theta} L(\theta) = - \lim_{n \rightarrow \infty} \frac{1}{n} \log \left( \int_{\Theta} \exp(-nL(\theta))\pi_0(d\theta) \right).$$

Dann gilt auf  $A$  fast sicher, dass  $L \geq \delta + m$  und daher:

$$\begin{aligned} -\frac{1}{n} \log \pi_n(A) &= -\frac{1}{n} \log \frac{\int_A \exp(-nL(\theta))\pi_0(d\theta)}{\int_{\Theta} \exp(-nL(\theta))\pi_0(d\theta)} \\ &\geq \delta + m + \frac{1}{n} \log \int_{\Theta} \exp(-nL(\theta))\pi_0(d\theta) \rightarrow \delta. \end{aligned}$$

**Aufgabe 11-2 (Bayesianische Optimierung mit quadratischer Verlustfunktion).** Berechnen Sie  $\pi_n$  in folgendem Spezialfall von Aufgabe 4:

$$\pi_0 \sim \mathcal{N}(\mu_0, \sigma_0^2), \quad L(\theta) = \frac{(\theta - \mu_1)^2}{2\sigma_1^2}.$$

Bonusfrage: Konvergiert  $\pi_n$  in einem geeigneten Sinn gegen das globale Minimum  $\mu_1$ ?

**Lösung:** Wir berechnen

$$\pi_n(d\theta) \propto \exp\left(-\frac{(\theta - \mu_1)^2}{2\sigma_1^2/n}\right) \exp\left(-\frac{(\theta - \mu_0)^2}{2\sigma_0^2}\right) d\theta \propto \exp\left(-\frac{(\theta - \hat{\mu}_n)^2}{2\hat{\sigma}_n^2/n}\right) d\theta,$$

wobei man  $\hat{\mu}_n$  und  $\hat{\sigma}_n$  durch Koeffizientenvergleich ermittelt:

$$\hat{\mu}_n = \frac{\tau_0\mu_0 + n\tau_1\mu_1}{\tau_0 + n\tau_1}, \quad \hat{\sigma}_n^2 = 1/(\tau_0 + n\tau_1), \quad \tau_0 = 1/\sigma_0^2, \quad \tau_1 = 1/\sigma_1^2.$$

Daher gilt  $\pi_n \sim \mathcal{N}(\hat{\mu}_n, \hat{\sigma}_n^2)$ . Die Wahrscheinlichkeitsmasse  $\pi_n$  konvergieren in Verteilung gegen  $\delta_{\mu_1}$ ,

denn  $\pi_n$ -verteilte Zufallsvariablen  $\theta_n$  konvergieren in  $L^2$  gegen  $\mu_1$ :

$$\begin{aligned}\mathbb{E}((\theta_n - \mu_1)^2) &= \mathbb{E}((\theta_n - \hat{\mu}_n + \hat{\mu}_n - \mu_1)^2) \\ &= \underbrace{\mathbb{E}((\theta_n - \hat{\mu}_n)^2)}_{=\sigma_n^2 \rightarrow 0} + 2 \underbrace{\mathbb{E}(\theta_n - \hat{\mu}_n)}_{=0} (\hat{\mu}_n - \mu_1) + \underbrace{(\hat{\mu}_n - \mu_1)^2}_{\rightarrow 0}.\end{aligned}$$

**MC 11-3 (Bayesianische Optimierung für Maximum-Likelihood Schätzung).** Wenden Sie den Algorithmus für Bayesianische Optimierung aus Aufgabe 1 auf das Problem der Maximum-Likelihood Schätzung an. Welche Aussagen sind korrekt? (Mehrere richtige Antworten sind möglich.)

- (a) Man muss eine a-priori Verteilung  $\pi_0$  wählen.
- (b) Die Verlustfunktion ist die log-Likelihood  $L(\theta) = \log f(x|\theta)$ .
- (c) Man erhält als  $\pi_1$  die a-posteriori Verteilung für eine Beobachtung  $x$ .
- (d) Man erhält als  $\pi_2$  die a-posteriori Verteilung, indem man eine neue Beobachtung  $x$  unter dem vorherigen Prior  $\pi_1$  berücksichtigt.

**Lösung:** Nur (c) ist falsch.

- (a) Richtig. Bayesianische Optimierung verlangt die Wahl eines Wahrscheinlichkeitsmasses  $\pi_0$  und dieses kann als a-priori Verteilung interpretiert werden.
- (b) Falsch. Korrekt wäre die negative log-Likelihood  $L(\theta) = -\log f(x|\theta)$ .
- (c) Richtig. Bayesianische Optimierung liefert die a-posteriori Verteilung

$$\pi_1(d\theta) = \exp(-L(\theta))\pi_0(d\theta) = f(x|\theta)\pi_0(d\theta).$$

- (d) Richtig. Das Wahrscheinlichkeitsmass  $\pi_2$  ist

$$\pi_2(d\theta) = \exp(-2L(\theta))\pi_0(d\theta) = f(x|\theta)^2\pi_0(d\theta).$$

Dies entspricht einer zweimaligen unabhängigen Beobachtung derselben Daten  $x$ .

**MC 11-4 (Gradientenfluss).** Der Gradientenfluss  $\text{Fl}_t(x_0)$  einer Funktion  $f$  mit Anfangswert  $x_0$  ist definiert als die Lösung der Differentialgleichung

$$\frac{d}{dt} \text{Fl}_t(x_0) = -\nabla f(\text{Fl}_t(x_0)), \quad x(0) = x_0.$$

Welche Aussagen gelten im Limes  $t \rightarrow \infty$ ?

- (a) Für  $f(x) = \exp(-x)$  konvergiert  $\text{Fl}_t(0)$  gegen einen Minimierer von  $f$ .
- (b) Für  $f(x) = \exp(-x)$  konvergiert  $f(\text{Fl}_t(0))$  gegen das Infimum von  $f$ .
- (c) Für  $f(x) = x^2/2$  konvergiert  $\text{Fl}_t(1)$  gegen einen Minimierer von  $f$ .
- (d) Für  $f(x) = x^2/2$  konvergiert  $f(\text{Fl}_t(1))$  gegen das Infimum von  $f$ .

**Lösung:**

- (a) Falsch. Der Gradientenfluss  $\text{Fl}_t(0) = \log(1+t)$  divergiert gegen  $\infty$  und  $f$  hat keinen Minimierer.
- (b) Richtig. Die Verlustfunktion  $f(\text{Fl}_t(0)) = 1/(1+t)$  konvergiert entlang des Gradientenflusses gegen das Infimum 0 von  $f$ .
- (c) Richtig. Der Gradientenfluss  $\text{Fl}_t(1) = e^{-t}$  konvergiert gegen das Minimum 0 von  $f$ .
- (d) Richtig. Die Verlustfunktion  $f(\text{Fl}_t(1)) = e^{-2t}/2$  konvergiert gegen das Infimum 0 von  $f$ .

**Aufgabe 11-5 (Langevin Dynamik).** Implementieren Sie die diskrete Langevin-Dynamik

$$\theta_{n+1} = \theta_n - \eta \nabla L(\theta_n) + \sqrt{\eta} \sigma \epsilon_n, \quad \epsilon_n \sim \mathcal{N}\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}\right),$$

mit unabhängigen Störungen  $(\epsilon_n)$ , um folgende Verlustfunktion Bayesianisch zu minimieren:

$$L: \mathbb{R}^2 \rightarrow \mathbb{R}, \quad L(x, y) = (x^2 - 1)^2 + y^2.$$

Simulieren Sie mehrere Lösungen  $\theta_{500}$  mit Anfangswert  $\theta_0 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ , Schrittweite  $\eta = 0.1$  und Standardabweichung  $\sigma = 0.1$ . Plotten Sie die Lösungen gemeinsam mit den Kontouren der Verlustfunktion.

```
import numpy as np
import matplotlib.pyplot as plt

def loss(x, y):
    return (x**2 - 1)**2 + y**2

def grad_loss(x, y):
    dL_dx = 4 * x * (x**2 - 1)
    dL_dy = 2 * y
    return np.array([dL_dx, dL_dy])

def langevin_dynamics(x0, eta=0.1, sigma=0.1, steps=500):
    x = np.array(x0, dtype=float)
    for _ in range(steps):
        grad = grad_loss(x[0], x[1])
        noise = np.random.normal(0, 1, size=2)
        x -= eta * grad + np.sqrt(eta) * sigma * noise
    return x

particles = [langevin_dynamics([0, 0]) for _ in range(50)]

plt.figure(figsize=(10, 8))
X, Y = np.meshgrid(np.linspace(-2, 2, 400), np.linspace(-2, 2, 400))
Z = loss(X, Y)
contours = plt.contour(X, Y, Z, levels=50, cmap='viridis')
plt.colorbar(contours)
```

```
for particle in particles:  
    plt.scatter(particle[0], particle[1], color='red', s=10)  
plt.show()
```

