

Wahrscheinlichkeitstheorie und Statistik

Anwendungsbeispiele und Prüfungsvorbereitung

Aufgabe 13-1 (Batching) Betrachten Sie den Machine-Learning Algorithmus zum Erkennen handgeschriebener Ziffern in [1] und beantworten Sie folgende Fragen:

- (a) Wie lautet die Verlustfunktion?
- (b) Welcher Optimierer wird zum Minimieren der Verlustfunktion eingesetzt?
- (c) Welche Gradienten verwendet das Optimierungsverfahren und sind diese zufällig oder deterministisch?

MC 13-2 (Universalität) Sei F eine universelle Menge von neuronalen Netzen $f : \mathbb{R}^d \rightarrow \mathbb{R}$ und $g : \mathbb{R}^d \rightarrow \mathbb{R}$ eine stetige Funktion. Welche Aussagen gelten für alle $\epsilon > 0$? (Mehrere richtige Antworten sind möglich.)

- (a) $\forall n \in \mathbb{N}, \forall x_1, \dots, x_n \in \mathbb{R}^d, \exists f \in F, \forall i \in \{1, \dots, n\} : |f(x_i) - g(x_i)| < \epsilon.$
- (b) $\exists f \in F, \forall n \in \mathbb{N}, \forall x_1, \dots, x_n \in \mathbb{R}^d, \forall i \in \{1, \dots, n\} : |f(x_i) - g(x_i)| < \epsilon.$
- (c) $\forall n \in \mathbb{N}, \exists f \in F, \forall x \in [-n, n]^d : |f(x) - g(x)| < \epsilon.$
- (d) $\exists f \in F, \forall n \in \mathbb{N}, \forall x \in [-n, n]^d : |f(x) - g(x)| < \epsilon.$

MC 13-3 (Approximationsfehler). Sei F eine universelle Menge von neuronalen Netzen $f : \mathbb{R}^d \rightarrow \mathbb{R}$. Welche Aussagen gelten für den empirischen Verlust

$$L(f) = \sum_{i=1}^n (f(X_i(\omega)) - Y_i(\omega))^2$$

bezüglich eines Datensatzes von unabhängigen, identisch verteilten Beobachtungen (X_i, Y_i) , $i \in \{1, \dots, n\}$? (Mehrere richtige Antworten sind möglich.)

- (a) $\inf_{f \in F} L(f) = \inf_{f \in C(\mathbb{R}^d, \mathbb{R})} L(f)$
- (b) $\arg \min_{f \in F} L(f) \subseteq \arg \min_{f \in C(\mathbb{R}^d, \mathbb{R})} L(f)$
- (c) $\inf_{f \in F} L(f) = \inf_{f \in F} \mathbb{E}(f(X_1) - Y_1)^2$

MC 13-4 (Machine Learning als inverses Problem). Wir betrachten den empirischen Verlust eines ReLU Netzes auf einem Datensatz von Paaren reeller Zahlen (x_i, y_i) :

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n (f_\theta(x_i) - y_i)^2, \quad \theta = (w, a, b) \in \mathbb{R}^m \times \mathbb{R}^m \times \mathbb{R}^m, \quad f_\theta(x) = \sum_{i=1}^m w_i \max\{0, a_i x + b_i\}.$$

Welche Aussagen sind für hinreichend grosses m korrekt? (Mehrere richtige Antworten sind möglich.)

- (a) Es gibt genau ein $\theta^* \in \arg \min_\theta L(\theta)$.
- (b) Es gibt genau ein $\theta^* \in \arg \min_\theta L(\theta)$ und θ^* hängt stetig von den Daten (x_i, y_i) ab.

- (c) $\inf_{\theta} L(\theta)$ hängt stetig von den Daten (x_i, y_i) ab.
- (d) $\inf_{\theta} L(\theta) = 0$.

MC 13-5 (Lösungsbegriff Bayesianische Optimierung). Auf einem Wahrscheinlichkeitsraum $(\Theta, \mathcal{A}, \pi_0)$ betrachten wir eine messbare Funktion $L : \Theta \rightarrow \mathbb{R}$ mit Minimierer $\theta^* \in \arg \min_{\theta} L(\theta)$ und Minimum $m = L(\theta^*)$. Welche der folgenden Aussagen treffen auf π_n -verteilte Zufallsvariablen θ_n zu, wobei

$$\pi_n(d\theta) \propto \exp(-nL(\theta))\pi_0(d\theta), \quad n \in \mathbb{N}.$$

(Mehrere richtige Antworten sind möglich.)

- (a) $L(\theta_n) \rightarrow m$ in Wahrscheinlichkeit.
- (b) $L(\theta_n) \rightarrow 0$ in Wahrscheinlichkeit.
- (c) $\theta_n \rightarrow \theta^*$ in Wahrscheinlichkeit.
- (d) $\theta_n \rightarrow \theta^*$ in Wahrscheinlichkeit, falls L stetig ist.

MC 13-6 (Invarianz unter der Langevin-Dynamik). Sei θ_0 eine \mathbb{R}^d -wertige Zufallsvariable mit Dichtefunktion proportional zu $\exp(-L(\theta)/\epsilon)$, für eine messbare Funktion $L : \mathbb{R}^d \rightarrow \mathbb{R}$ und $\epsilon > 0$. Ferner sei W unabhängig von θ_0 und standardnormalverteilt. Unter welcher Dynamik ist π infinitesimal invariant im Sinn von

$$\left. \frac{d}{dt} \right|_{t=0} \mathbb{E}(f(\theta(t))) = 0, \quad \text{für alle Testfunktionen } f.$$

(Mehrere richtige Antworten sind möglich.)

- (a) $\dot{\theta}(t) = -\nabla L(\theta(t)), \theta(0) = \theta_0$
- (b) $\dot{\theta}(t) = -\nabla L(\theta(t)) + \sqrt{2t/\epsilon}W, \theta(0) = \theta_0$
- (c) $\theta(t) = \theta_0 - t\nabla L(\theta_0)$
- (d) $\theta(t) = \theta_0 - t\nabla L(\theta_0) + \sqrt{2t/\epsilon}W$

MC 13-7 (Gradientenfluss). Sei $L : \mathbb{R}^d \rightarrow \mathbb{R}$ eine glatte Funktion mit einem eindeutigen globalen Minimum θ^* und sei $\theta_0 \in \mathbb{R}^d$. Welche Aussagen sind im Allgemeinen korrekt? (Mehrere richtige Antworten sind möglich.)

- (a) Wenn L ein quadratisches Polynom ist, konvergiert der Gradientenfluss gegen θ^* .
- (b) Wenn L kein quadratisches Polynom ist, kann der Gradientenfluss divergieren.
- (c) Wenn L kein quadratisches Polynom ist, kann der Gradientenfluss gegen $\theta \neq \theta^*$ konvergieren.
- (d) Der empirische Verlust eines neuronalen Netzes ist im Allgemeinen kein quadratisches Polynom.

MC 13-8 (Aktivierungsfunktion). Welche der folgenden Funktionen Aktivierungsfunktionen liefern universale neuronale Netze? (Mehrere richtige Antworten sind möglich.)

- (a) $f(x) = \max(0, x)$

- (b) $f(x) = -\max(0, x)$
- (c) $f(x) = \max(0, x^2)$
- (d) $f(x) = \max(x/100, x)$
- (e) $f(x) = x$
- (f) $f(x) = x^2$

Aufgabe 13-9 (Tests für Mittelwert und Standardabweichung). Zwei verschiedene Methoden wurden verwendet, um die Schmelzenthalpie von Wasser zu messen. Methode A lieferte bei 10 Messungen eine durchschnittliche Schmelzenthalpie von 6.0 kJ/mol bei einer Standardabweichung von 0.2 kJ/mol. Methode B lieferte bei 5 Messungen eine durchschnittliche Schmelzenthalpie von 5.6 kJ/mol bei einer Standardabweichung von 0.1 kJ/mol. Die Standardabweichungen wurden ohne Besselkorrektur berechnet.

- (a) Testen Sie auf einem Signifikanzniveau von 5 %, ob die beiden Methoden dieselbe Standardabweichung haben.
Hinweis: Der Quotient von zwei unabhängigen χ^2 -verteilten Zufallsvariablen ist F -verteilt, und die Quantile der F -Verteilung sind in Tabellen oder Statistik-Software verfügbar.
- (b) Testen Sie auf demselben Signifikanzniveau, ob sich die Mittelwerte der beiden Methoden signifikant unterscheiden.
Hinweis: Verwenden Sie den t-Test von Welch [2].

Aufgabe 13-10 (Parameterschätzung für Exponentialverteilung). Die Lebensdauer T (in Stunden) einer Glühbirne unter extremen Bedingungen wird als exponentialverteilt mit unbekanntem Parameter $\lambda > 0$ angenommen. Eine Stichprobe von 5 Glühbirnen wurde bis zum Ausfall beobachtet. Die gemessenen Lebensdauern lauten $T_1 = 4$, $T_2 = 4$, $T_3 = 5$, $T_4 = 3$. Beantworten Sie die folgenden Fragen:

- (a) Schätzen Sie den Parameter λ und die mittlere Lebensdauer.
- (b) Schätzen Sie die Überlebenswahrscheinlichkeit $S(3) = \mathbb{P}(T > 3)$.
- (c) Wenn eine Glühbirne bereits 2 Stunden funktioniert hat, wie viele Stunden wird sie voraussichtlich noch halten?
- (d) Wenn zwei Glühbirnen unabhängig voneinander betrieben werden, wie groß ist die Wahrscheinlichkeit, dass beide länger als 3 Stunden halten?

References

- [1] Josef Teichmann. *Introduction to Mathematics of New Technologies in Banking and Finance*. Verfügbar unter: <https://gist.github.com/jteichma/ea9452fc6cc307afcc9309741aeeed9b7>. Mai 2025.
- [2] Wikipedia. *Welch's t-Test*. Verfügbar unter: https://en.wikipedia.org/wiki/Welch's_t-test. Mai 2025.