

Nichtparametrische Regression via Neuronaler Netzwerke mithilfe der ReLU-Funktion

Seminar: Mathematische Grundlagen von Statistischem Lernen

Dozentin: Prof. Dr. Rohde

Doktorand: Dario Kieffer

23.06.2020, Lukas Königs

Gliederung

- Nichtparametrische Regression
- Motivation
- Neuronale Netzwerke, Netzwerk-Klasse und Schätzer
- Parallelen und Unterschiede zum Klassifikationsproblem
- Funktionenklasse
- Regressionfunktion
- Theorem 2 mit Beweis
- Theorem 1 mit Beweis-Idee
- Ausblick

nichtparametrische Regression

Regressionsmodell

- n iid Vektoren $X_i \in [0,1]^d$
- n abhängige Variablen $Y_i \in \mathbb{R}$

Definiere für ein $f_0 : [0,1]^d \rightarrow \mathbb{R}$

$\forall i \in \mathbb{N} : Y_i = f_0(X_i) + \epsilon_i$ mit ϵ_i standardnormalverteilt und unabhängig von $(X_i)_i$

Regressionsproblem:

Finde in Abhängigkeit von den Daten $((X_1, Y_1), \dots, (X_n, Y_n))$ einen möglichst guten Schätzer \hat{f}_n für f_0 .

lineare Einfachregression

$f_0(x)$ ist eine Gerade: $f_0(x) = \beta_0 + \beta_1 X$

-> Struktur ist bis auf zwei unbekannte Parameter festgelegt

-> Schätzung der Regressionsfunktion wird auf die Schätzung der unbekannt Parameter zurückgeführt

Problem: Es wird ein linearer Zusammenhang angenommen, ist das korrekt?

nichtparametrische Regression

Es wird keine spezielle funktionale Form der Regressionsfunktion angenommen.

Qualitative Modellannahme: f_0 hinreichend glatt

-> funktionale Form der Regressionsfunktion wird aus den Daten bestimmt

(vgl. Fahrmeir L., Kneib T)

Motivation

Deep Learning: visuelle Bilderkennung, Spracherkennung,...

Wesentlich: Lernen mit Daten, einfaches Retraining und hohe Flexibilität

siehe Vorlesung Deep Learning (Prof. Dr. Harms)

Motivation

Approximationstheorie

Neuronale Netzwerke zur Approximierung von Funktionen

-> Dichtheit neuronaler Netzwerkfunktionen in vielen Funktionenräumen

[Cybenko 1989]

-> Multilayer Feedforward Networks are Universal Approximators

[Hornik, K]

Generalisierungsfähigkeit

Achtung!! „Unreasonable Effectiveness of Deep Learning in artificial intelligence“-

Sejnowski, T.

Neuronale Netzwerke

Neuronale Netzwerk-Architektur (L,p)

$L \in \mathbb{Z}_+$ für die Zahl der Hidden Layers

beziehungsweise für die Tiefe

$p = (p_0, \dots, p_{L+1}) \in \mathbb{N}^{L+2}$ für die Weite

Neuronales Netzwerk (Netzwerkfunktion)

$$f: \mathbb{R}^{p_0} \rightarrow \mathbb{R}^{p_{L+1}} \quad x \mapsto f(x) = W_L \circ \sigma_{V_L} \circ W_{L-1} \circ \sigma_{V_{L-1}} \circ \dots \circ W_1 \circ \sigma_{V_1} \circ W_0 x$$

Netzwerk-Parameter: W_i eine $p_i \times p_{i+1}$ Gewicht-Matrix

$v_i \in \mathbb{R}^{p_i}$ Verschiebungsvektor.

Aktivierungsfunktion

$$\sigma: \mathbb{R} \rightarrow \mathbb{R}$$

$$\sigma(x) = \max(x, 0)$$

Neuronale Netzwerke

shifted Aktivierungsfunktion


$\sigma_V : \mathbb{R}^r \rightarrow \mathbb{R}^r$ für $v = (v_1, \dots, v_r) \in \mathbb{R}^r$

$$\sigma_V \begin{pmatrix} y_1 \\ \vdots \\ y_r \end{pmatrix} = \begin{pmatrix} \sigma(y_1 - v_1) \\ \vdots \\ \sigma(y_r - v_r) \end{pmatrix}$$

Parameterwahl

$$p_0 = d \text{ und } p_{L+1} = 1$$

Mathematische Definition ist äquivalent zur grafischen Repräsentation



Notation

- $\mathbf{x} = (x_1, \dots, x_d)^\top$ Vektor
- $\|\mathbf{x}\|_p := \left(\sum_{i=1}^d |x_i|^p \right)^{1/p}$ mit $\|\mathbf{x}\|_\infty := \max_i |x_i|$ und $\|\mathbf{x}\|_0 := \sum_i 1_{(x_i \neq 0)}$
- $\|f\|_p := \|f\|_{L^p(D)}$ sei die L^p -Norm auf D wann immer keine Zweideutigkeit auf dem Definitionsbereich D besteht
- Für zwei Folgen $(a_n)_n$ und $(b_n)_n$:
 - $a_n \lesssim b_n$ falls eine Konstante C existiert, sodass: $a_n \leq C b_n$ für alle n
 - $a_n \asymp b_n$ falls $a_n \lesssim b_n$ und $b_n \lesssim a_n$
- \log_2 für den Logarithmus zur Basis 2
- $\lceil x \rceil$ für die kleinste ganze Zahl größer gleich x

Parameter


- Parameter-Trick:

Indikatorfunktion leicht durch ReLU-Funktion abschätzbar:

$$x \mapsto \sigma(ax) - \sigma(ax - 1)$$

- in der Praxis: kleine Parameter

- beschränken die Parameter im Absolutwert durch 1
- große Tiefe L und große Zahl von potenziellen Netzwerk-
Parametern



Netzwerk-Klasse und Schätzer

Netzwerk-Klasse $\mathcal{F}(L, \mathbf{p}) := \{f \text{ Netzwerkfunktion} : \max_{j=0, \dots, L} \|W_j\|_\infty \vee |v_j|_\infty \leq 1\}$

s-besetzte Netzwerk-Klasse $\mathcal{F}(L, \mathbf{p}, s) := \mathcal{F}(L, \mathbf{p}, s, F) := \left\{ f \in \mathcal{F}(L, \mathbf{p}) : \sum_{j=0}^L \|W_j\|_0 + |v_j|_0 \leq s, \left\| |f|_\infty \right\|_\infty \leq F \right\}$

Empirische Risikominimierung: $\hat{f}_n \in \arg \min_{f \in \mathcal{F}(L, \mathbf{p}, s)} \frac{1}{n} \sum_{i=1}^n (Y_i - f(\mathbf{X}_i))^2$

Parallelen und Unterschiede zum Klassifikationsproblem

Erinnerung Klassifikationsproblem:

Seien $(X_1, Y_1), (X_2, Y_2), \dots \sim P$. Finde in Abhängigkeit von Daten $((X_1, Y_1), \dots, (X_n, Y_n))$ einen möglichst guten Schätzer von $f_0 := \arg \max_{y \in \mathcal{Y}} P(Y = y | X = \cdot)$.

- Klassifikation: endlich viele Werte; Regression: Y kann unendlich viele Werte annehmen (in \mathbb{R})
- Die Varianz $V[X_i, Y_i]$ (Ungenauigkeit) kann von dem Wert X_i abhängen. Im Regressionsmodell ist $V[Y_i | X_i] = V[\epsilon_i] = 1$ unabhängig von der Position X_i .

Aber Begriffe lassen sich ähnlich verwenden:

- 'estimation error':
$$\Delta_n(\hat{f}_n, f_0) = \Delta_n(\hat{f}_n, f_0, \mathcal{F}(L, p, s, F)) := E_{f_0} \left[\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{f}_n(\mathbf{X}_i))^2 - \inf_{f \in \mathcal{F}(L, p, s, F)} \frac{1}{n} \sum_{i=1}^n (Y_i - f(\mathbf{X}_i))^2 \right]$$

(vergleiche 3. Vortrag: 'Algorithmus-Risiko')

- Klassifikationsproblem: Minimiere Risiko bezüglich des Bayes-Klassifizierers. Hier: Minimiere Risiko bezüglich f_0 , also

$$R(\hat{f}_n, f_0) := E_{f_0}[(\hat{f}(\mathbf{X}) - f_0(\mathbf{X}))^2]$$

Funktionenklasse



Regressionsfunktion Hölder-stetig mit Konstante β

MiniMax-Rate $n^{-2\beta/(2\beta+d)}$ für den Vorhersage-Fehler:

$$\inf_{\hat{f}_n} \sup_{f_0 \in \mathcal{G}(q,d,t,\beta,K)} R(\hat{f}_n, f_0)$$

curse of dimensionality

Hierarchische Struktur



Regressionfunktion

Regressionsfunktion $f_0 = g_q \circ g_{q-1} \circ \dots \circ g_1 \circ g_0$

- mit $g_i : [a_i, b_i]^{d_i} \rightarrow [a_{i+1}, b_{i+1}]^{d_{i+1}}$
- g_{ij} β_i -Hölder-Stetig &
- g_{ij} t_i -variat

$$\text{Hölder-Ball } \mathcal{C}(D, K) = \left\{ f : D \subset \mathbb{R}^r \rightarrow \mathbb{R} : \sum_{\alpha: |\alpha| < \beta} \|\partial^\alpha f\|_\infty + \sum_{\alpha: |\alpha| = \lfloor \beta \rfloor} \sup_{x, y \in D; x \neq y} \frac{|\partial^\alpha f(x) - \partial^\alpha f(y)|}{|x - y|^{\beta - \lfloor \beta \rfloor}} \leq K \right\}$$

$$\Rightarrow g_{ij} \in \mathcal{C}_{t_i}^{\beta_i}([a_i, b_i]^{t_i}, K_i)$$

also zugrundeliegender **Funktionsraum**

$$\mathcal{G}(q, \mathbf{d}, \mathbf{t}, \beta, K) := \left\{ f = g_q \circ \dots \circ g_0 : g_i = (g_{ij})_j : [a_i, b_i]^{d_i} \rightarrow [a_{i+1}, b_{i+1}]^{d_{i+1}}, g_{ij} \in \mathcal{C}_{t_i}^{\beta_i}([a_i, b_i]^{t_i}, K), \text{ für ein } |a_i|, |b_i| \leq K \right\}$$

effektive Stetigkeit-Indizes

$$\beta_i^* := \beta_i \prod_{l=i+1}^q (\beta_l \wedge 1)$$

Rate

$$\phi_n := \max_{i=0, \dots, q} n^{-\frac{2\beta_i^*}{2\beta_i^* + t_i}}$$

Theorem 2

Theorem 5

Betrachte eine beliebige Funktion $f \in C_r^\beta([0,1]^r, K)$, ganze Zahlen $m \geq 1$ und $N \geq (\beta + 1)^r \vee (K + 1)e^r$.

Dann existiert ein Netzwerk $\tilde{f} \in \mathcal{F}(L, (r, 6(r + \lceil \beta \rceil)N), \dots, 6(r + \lceil \beta \rceil)N, s, \infty)$ mit der Tiefe

$L = 8 + (m + 5)(1 + \lceil \log_2(r \vee \beta) \rceil)$ und Parameterzahl $s \leq 141(r + \beta + 1)^{(3+r)}N(m + 6)$, sodass

$$\|\tilde{f} - f\|_{L^\infty([0,1]^r)} \leq (2K + 1)(1 + r^2 + \beta^2)6^r N 2^{-m} + K 3^\beta N^{-\frac{\beta}{r}}.$$

Beweis-Idee

siehe Vorlesung Deep Learning von Dr. Harms

Lemma 3

Für die Funktion $f = g_q \circ \dots \circ g_0 = h_q \circ \dots \circ h_0$ und die Funktion \tilde{h}_i gibt Lemma 3 folgende Abschätzung:

$$\|h_q \circ \dots \circ h_0 - \tilde{h}_q \circ \dots \circ \tilde{h}_0\|_{L^\infty([0,1]^d)} \leq K_q \prod_{l=0}^{q-1} (2K_l)^{\beta_{l+1}} \sum_{i=0}^q \| \|h_i - \tilde{h}_i\|_\infty \|_{L^\infty([0,1]^{d_i})}^{\prod_{l=i+1}^q \beta_l \wedge 1}.$$

Theorem 1

Betrachtet wird das d -variate nichtparametrische Regressionsmodell für eine zusammengesetzte Regressionsfunktion in der Klasse $\mathcal{G}(q, \mathbf{d}, \mathbf{t}, \beta, K)$. Sei \hat{f}_n ein Schätzer mit Werten aus der Netzwerkklassse $\mathcal{F}(L, (p_i)_{i=0, \dots, L+1}, s, F)$, welcher den Voraussetzungen

$$(i) F \geq \max(K, 1),$$

$$(ii) \sum_{i=0}^q \log_2(4t_i \vee 4\beta_i) \log_2 n \leq L \lesssim n\phi_n,$$

$$(iii) n\phi_n \lesssim \min_{i=1, \dots, L} p_i$$

$$(iv) s \asymp n\phi_n \log n.$$

Es existieren Konstanten C, C' , welche nur von $q, \mathbf{d}, \mathbf{t}, \beta, F$ abhängen, sodass falls

$$\Delta_n(\hat{f}_n, f_0) \leq C\phi_n L \log^2 n, \text{ dann}$$

$$(1) R(\hat{f}_n, f_0) \leq C'\phi_n L \log^2 n,$$

Und falls

$$\Delta_n(\hat{f}_n, f_0) \geq C\phi_n L \log^2 n, \text{ dann}$$

$$(2) \frac{1}{C'} \Delta_n(\hat{f}_n, f_0) \leq R(\hat{f}_n, f_0) \leq C' \Delta_n(\hat{f}_n, f_0).$$

Beweis-Idee

$$(1 - \epsilon)^2 \Delta_n(\hat{f}_n, f_0) - \tau_{\epsilon, n} \leq R(\hat{f}_n, f_0) \leq (1 + \epsilon)^2 \left(\inf_{f \in \mathcal{F}(L, \mathbf{p}, s, F)} \|f - f_0\|_\infty^2 + \Delta_n(\hat{f}_n, f_0) \right) + \tau_{\epsilon, n}$$

-> Zeige $\tau_{\epsilon, n} \leq C' \phi_n L \log 2n$

$$\text{Dann: } (1 - \epsilon)^2 \Delta_n(\hat{f}_n, f_0) - C' \phi_n L \log 2n \leq R(\hat{f}_n, f_0) \leq (1 + \epsilon)^2 \left(\inf_{f \in \mathcal{F}(L, \mathbf{p}, s, F)} \|f - f_0\|_\infty^2 + \Delta_n(\hat{f}_n, f_0) \right) + C' \phi_n L \log 2n$$

-> Wähle $C = 8C'$, $\epsilon = 1/2$ für die untere Schranke, $\epsilon = 1$ für die obere Schranke

Damit ist die untere Schranke in (2) bewiesen.

Für die oberen Schranken:

-> forme Regressionsfunktion um

-> konstruiere und erweitere die Netzwerk-Klasse mittels Vergrößerung, Komposition von Netzwerken, Hinzufügen von Layern in den Netzwerken, Parallelisieren von Netzwerken

-> bis hin zu der Netzwerk-Klasse $\mathcal{F}(L, p, s)$

$$\text{-> } \inf_{f^* \in \mathcal{F}(L, p, s)} \|f^* - f_0\|_\infty^2 \leq C' \max_{i=0, \dots, q} N^{-\frac{2\beta_i^*}{t_i}} \leq C' \max_{i=0, \dots, q} c^{-\frac{2\beta_i^*}{t_i}} n^{-\frac{2\beta_i^*}{2\beta_i^* + t_i}}$$

$$\text{-> } \inf_{f^* \in \mathcal{F}(L, p, s)} \|f^* - f_0\|_\infty^2 \leq C \phi_n$$

Ausblick

Folgerung 1

Sei $\tilde{f}_n \in \arg \min_{f \in \mathcal{F}(L, \mathbf{p}, s, F)} \sum_{i=1}^n (Y_i - f(\mathbf{X}_i))^2$ ein empirischer Risiko-Minimierer. Es gelten dieselben Voraussetzungen wie in

Theorem 1. Dann existiert eine Konstante C' , welche lediglich von $q, \mathbf{d}, \mathbf{t}, \beta, F$ abhängt, sodass

$$R(\tilde{f}_n, f_0) \leq C' \phi_n L \log^2 n.$$

Theorem 3

Minimax Schätzrate für den Vorhersagefehler

Vielen Dank für Ihre Aufmerksamkeit!

Quellen

- Cybenko, G. (1989) Approximation by superpositions of sigmoidal function. In: Mathematics of Control, Signals and Systems 2, 4; 303–314.
- Fahrmeir L., Kneib T., Lang S. (2009) Nichtparametrische Regression. In: Regression. Statistik und ihre Anwendungen. Springer, Berlin, Heidelberg. 40-41
- Hornik, K., Stinchcombe, M., and White, H. (1989) Multilayer feedforward networks are universal approximators. In: Neural Networks 2, 5; 359 – 366.
- Hornik, K., Stinchcombe, M., and White, H. (1990) Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. In: Neural Networks 3, 5; 551 – 560
- Schmidt-Hieber, J. (2020) Nonparametric Regression using Deep Neural Networks with ReLU Activation function.
- Sejnowski, T. (2020) The unreasonable effectiveness of deep learning in artificial intelligence.
- Zeiler, M., Fergus, R. (2013) Visualizing and Understanding Convolutional Networks.