

# Theorie des maschinellen Lernens

Hans U. Simon

13. Juni 2017

## 9 Lineare Voraussagefunktionen

Lineare Voraussagefunktionen sind wichtig, und zwar aus folgenden Gründen:

- Sie werden in Anwendungen oft benutzt.
- Sie führen zu effizient lösbaren Lernproblemen (mit gewissen Einschränkungen im agnostischen Fall).
- Sie sind der Intuition zugänglich und einfach zu interpretieren.
- Wenn sie geeignet eingesetzt werden, beschreiben sie oftmals die in Anwendungen vorliegenden Daten auf eine befriedigende Weise.

Im Folgenden fassen wir Vektoren  $w \in \mathbb{R}^d$  grundsätzlich als Spaltenvektoren auf. Der betreffende Zeilenvektor wird als  $w^\top$  notiert. Das Skalarprodukt von  $w, x \in \mathbb{R}^d$  schreiben wir entweder in der Form  $w^\top x$  oder (als inneres Produkt) in der Form  $\langle w, x \rangle$ . Weiterhin sei

$$\text{LIN}_d := \{x \mapsto h_{w,b}(x) : w \in \mathbb{R}^d, b \in \mathbb{R}\} \quad (1)$$

mit

$$h_{w,b} : \mathbb{R}^d \rightarrow \mathbb{R}, \quad h_{w,b}(x) = \langle w, x \rangle + b = \sum_{i=1}^d w_i x_i + b.$$

die Klasse der *affinen Funktionen*. Wir bezeichnen  $w$  als den *Gewichtsvektor* und  $b$  als das *Bias* der Abbildung  $h_{w,b}$ . Eine *lineare Voraussagefunktion* mit Werten in  $\mathcal{Y}$  ergibt sich aus der Komposition einer Funktion  $\phi : \mathbb{R} \rightarrow \mathcal{Y}$  mit einer affinen Funktion aus  $\text{LIN}_d$ :

$$\phi \circ h_{w,b} : \mathbb{R}^d \rightarrow \mathcal{Y}, \quad \phi(h_{w,b}(x)) = \phi(\langle w, x \rangle + b).$$

Mögliche Wahlen von  $\phi$ :

1.  $\phi = \text{sign} : \mathbb{R} \rightarrow \{-1, 1\}$  mit

$$\text{sign}(a) = \begin{cases} +1 & \text{if } a \geq 0 \\ -1 & \text{if } a < 0 \end{cases}$$

für alle  $a \in \mathbb{R}$ . Diese Wahl erfolgt im Zusammenhang mit binären Klassifikationsproblemen.

2.  $\phi = \text{id} : \mathbb{R} \rightarrow \mathbb{R}$  mit  $\text{id}(a) = a$  für alle  $a \in \mathbb{R}$ . Diese Wahl erfolgt im Zusammenhang mit Regressionsproblemen.

Wir vereinbaren, dass die Anwendung der Funktion  $\text{sign}$  auf einen Vektor komponentenweise durchzuführen ist.

Es bezeichne  $\text{LIN}_d^0 = \{h_{w,0} : w \in \mathbb{R}^d\}$  die Klasse der *linearen Funktionen* (affine Funktionen mit Bias 0). Es gilt einerseits  $\text{LIN}_d^0 \subset \text{LIN}_d$ ; andererseits können wir eine Funktion  $h_{w,b} \in \text{LIN}_d$  auch als Funktion in  $\text{LIN}_{d+1}^0$  auffassen, indem wir folgende Einbettungen von  $x, w \in \mathbb{R}^d$  in den  $(d+1)$ -dimensionalen Euklidischen Raum vornehmen:

$$x' = (1, x) = (1, x_1, \dots, x_d) \neq \vec{0} \quad \text{und} \quad w' = (b, w) = (b, w_1, \dots, w_d) . \quad (2)$$

Offensichtlich gilt dann:

$$h_{w,b}(x) = \langle w, x \rangle + b = \langle w', x' \rangle = h_{w',0}(x') .$$

Wann immer wir das bequem finden, werden wir daher lineare Funktionen (angewendet auf vom Nullvektor verschiedene Vektoren) anstelle von affinen Funktionen betrachten, d.h., wir werden mitunter oBdA  $b = 0$  setzen und  $x \neq \vec{0}$  voraussetzen. Man spricht dann auch vom “homogenen Fall” (im Unterschied zum sogenannten “inhomogenen Fall” bei Betrachtung von allgemeinen affinen Funktionen).

## 9.1 Halbräume

Es bezeichne

$$H_{w,b} = \{x \in \mathbb{R}^d : h_{w,b}(x) = 0\} = \{x \in \mathbb{R}^d : \langle w, x \rangle + b = 0\}$$

die durch  $w, b$  gegebene affine Hyperebene im  $\mathbb{R}^d$ . Diese zerteilt den  $\mathbb{R}^d$  in zwei Halbräume:

$$H_{w,b}^+ = \{x \in \mathbb{R}^d : \langle w, x \rangle + b \geq 0\} \quad (\text{positiver Halbraum}) .$$

$$H_{w,b}^- = \{x \in \mathbb{R}^d : \langle w, x \rangle + b < 0\} \quad (\text{negativer Halbraum}) .$$

Wir bezeichnen dann

$$\text{HS}_d = \{H_{w,b}^+ : w \in \mathbb{R}^d, b \in \mathbb{R}\}$$

als die Klasse der (*affinen*) *Halbräume*. Alternativ können wir einen positiven Halbraum  $H_{w,b}^+$  auch identifizieren mit der Abbildung  $x \mapsto \text{sign}(h_{w,b}(x))$ , welche die Punkte im positiven Halbraum mit 1 und die im negativen Halbraum mit  $-1$  markiert. Die Klasse der affinen Halbräume, aufgefasst als Klasse von  $\pm 1$ -wertigen Funktionen, wäre dann gegeben durch

$$\text{HS}_d = \text{sign} \circ \text{LIN}_d = \{x \mapsto \text{sign}(\langle w, x \rangle + b) : w \in \mathbb{R}^d, b \in \mathbb{R}\} .$$

Wir werden Halbräume meist mit  $H_{w,b}^+$  identifizieren (gelegentlich vielleicht aber auch mit  $x \mapsto \text{sign}(h_{w,b}(x))$ ).

Eine affine Hyperebene  $H_{w,b}$  heißt *homogen*, falls  $b = 0$  und *inhomogen* falls  $b \neq 0$ . Der Gewichtsvektor  $w \in \mathbb{R}^d$  wird auch als der *Normalenvektor* von  $H_{w,b}$  bezeichnet. Aus der linearen Algebra ist bekannt, dass folgendes gilt:

**Homogener Fall:**  $x \in H_{w,0}$  (bzw.  $x \in H_{w,0}^+ \setminus H_{w,0}$  oder  $x \in H_{w,0}^-$ ) genau dann, wenn  $x$  und  $w$  einen rechten Winkel (bzw. einen spitzen oder einen stumpfen) Winkel miteinander bilden.

**Inhomogener Fall:** Es sei  $a \in H_{w,b}$  ein beliebiger Punkt auf der affinen Hyperebene  $H_{w,b}$ . Dann gilt

$$H_{w,b} = a + H_{w,0}, \quad H_{w,b}^+ = a + H_{w,0}^+ \quad \text{und} \quad H_{w,b}^- = a + H_{w,0}^- .$$

Somit gilt  $a + x \in H_{w,b}$  (bzw.  $a + x \in H_{w,b}^+ \setminus H_{w,b}$  oder  $a + x \in H_{w,b}^-$ ) genau dann, wenn  $x$  und  $w$  einen rechten Winkel (bzw. einen spitzen oder einen stumpfen) Winkel miteinander bilden.

### 9.1.1 Informationskomplexität der Klasse der Halbräume

Wir wissen, dass die Anzahl der zum PAC-Lernen einer Hypothesenklasse  $\mathcal{H}$  benötigten Trainingsbeispiele proportional zur VC-Dimension von  $\mathcal{H}$  ist. In diesem Abschnitt werden wir zeigen, dass die VC-Dimension von  $\text{HS}_d$  exakt  $d + 1$  beträgt und somit eine lediglich lineare Abhängigkeit in dem „Komplexitätsparameter“  $d$  aufweist.

Es bezeichne  $\text{HS}_d^0 = \{H_{w,0}^+ : w \in \mathbb{R}^d\}$  die Klasse der homogenen Halbräume. Wir notieren mit  $\vec{e}_i$  den Vektor mit einer 1 in Position  $i$  und Nullen in allen anderen Positionen. Im Zusammenhang mit Halbräumen benutzen wir im Folgenden die Binärlabels  $-1, 1$  (anstelle der Labels  $0, 1$ ).

**Lemma 9.1** *Eine Punktmenge  $S \subseteq \mathbb{R}^d$  ist aufspaltbar durch  $\text{HS}_d^0$  genau dann, wenn  $S$  aus linear unabhängigen Vektoren besteht.*

**Beweis** Wir beginnen mit der Beweisrichtung „ $\Leftarrow$ “. Wir dürfen annehmen, dass  $S$  aus  $d$  linear unabhängigen Vektoren  $x_1, \dots, x_d \in \mathbb{R}^d$  besteht (da wir kleinere Mengen  $S$  zu einer Basis ergänzen können). Es sei  $A$  die  $(d \times d)$ -Matrix mit  $x_1^\top, \dots, x_d^\top$  als Zeilenvektoren. Beachte, dass  $Aw$  dann der Vektor mit den Komponenten  $x_i^\top w = w^\top x_i$  ist, d.h.,  $\text{sign}(Aw)$  ist das Binärmuster, dass  $w$  auf den Vektoren  $x_1, \dots, x_d$  erzeugt. Da  $A$  den Rang  $d$  hat, existiert die inverse Matrix  $A^{-1}$ . Dann ist das Gleichungssystem  $Aw = y$  für jede Wahl von  $y \in \mathbb{R}^d$  lösbar, nämlich mit  $w = A^{-1}y$ . Dies gilt insbesondere für alle  $y \in \{-1, 1\}^d$ . Daher ist  $S$  durch  $\text{HS}_d^0$  aufspaltbar.

Die Beweisrichtung „ $\Rightarrow$ “ zeigen wir indirekt. Wir nehmen an, dass  $S$  aus linear abhängigen Vektoren  $x_1, \dots, x_m$  besteht und zeigen, dass dann nicht alle Binärmuster durch  $\text{HS}_d^0$  realisierbar sind. Wegen der linearen Abhängigkeit existiert ein Vektor  $a \in \mathbb{R}^m \setminus \{\vec{0}\}$  mit  $\sum_{i=1}^m a_i x_i = 0$ . Betrachte die zwei Indexmengen  $I = \{i \in [m] : a_i > 0\}$  und  $J = \{j \in [m] : a_j < 0\}$ , von denen mindestens eine nichtleer ist.

**Fall 1:**  $J = \emptyset$ .

Dann folgt  $I \neq \emptyset$  und  $\sum_{i \in I} a_i x_i = 0$ . Nimm an, dass das Bitmuster  $y_i = -1$  für

alle  $i \in I$  realisierbar ist, sagen wir mit dem Gewichtsvektor  $w$ . Wir erhalten einen Widerspruch wie folgt:

$$0 > \sum_{i \in I} a_i \langle w, x_i \rangle = \left\langle w, \sum_{i \in I} a_i x_i \right\rangle = \langle w, \vec{0} \rangle = 0 .$$

**Fall 2:**  $J \neq \emptyset$ .

Die Gleichung  $\sum_{i=1}^m a_i x_i = 0$  lässt sich umschreiben zu  $\sum_{i \in I} a_i x_i = \sum_{j \in J} |a_j| x_j$ . Nimm an, dass das Binärmuster  $y_i = 1$  für alle  $i \in I$  und  $y_j = -1$  für alle  $j \in J$  realisierbar ist, sagen wir durch den Gewichtsvektor  $w$ . Wir erhalten einen Widerspruch wie folgt:

$$0 \leq \sum_{i \in I} a_i \langle w, x_i \rangle = \left\langle w, \sum_{i \in I} a_i x_i \right\rangle = \left\langle w, \sum_{j \in J} |a_j| x_j \right\rangle = \sum_{j \in J} |a_j| \langle w, x_j \rangle < 0 . \quad (3)$$

Damit ist der Beweis des Lemmas abgeschlossen. **qed.**

**Lemma 9.2** *Eine Punktmenge  $S \subseteq \mathbb{R}^d$  ergänzt um den Nullvektor  $\vec{0}$  ist durch  $\text{HS}_d$  aufspaltbar genau dann, wenn  $S$  aus linear unabhängigen Vektoren besteht.*

**Beweis** Aus der in (2) beschriebenen Darstellung affiner Funktionen aus  $LIN_d$  als lineare Funktionen aus  $LIN_{d+1}^0$  folgt leicht:  $S \cup \{\vec{0}\}$  ist aufspaltbar durch  $\text{HS}_d$  genau dann, wenn  $S' := \{(1, x) : x \in S\} \cup \{(1, \vec{0})\}$  aufspaltbar durch  $\text{HS}_{d+1}^0$  ist. Gemäß Lemma 9.1 ist dies der Fall genau dann, wenn  $S'$  aus linear unabhängigen Vektoren besteht. Dies wiederum gilt genau dann (wie man sich leicht überlegt), wenn die ursprüngliche Menge  $S$  aus linear unabhängigen Vektoren besteht. **qed.**

**Theorem 9.3**  $\text{VCdim}(\text{HS}_d^0) = d$  und  $\text{VCdim}(\text{HS}_d) = d + 1$ .

**Beweis**  $\text{VCdim}(\text{HS}_d^0) = d$  ergibt sich unmittelbar aus Lemma 9.1. Wir wissen bereits, dass  $\text{HS}_d$  sich als eine Unterklasse von  $\text{HS}_{d+1}^0$  auffassen lässt. Daraus folgt  $\text{VCdim}(\text{HS}_d) \leq \text{VCdim}(\text{HS}_{d+1}^0) = d + 1$ . Aus Lemma 9.2 folgt, dass  $\text{VCdim}(\text{HS}_d) \geq d + 1$ , da jede Basis von  $\mathbb{R}^d$  ergänzt um den Nullvektor durch  $\text{HS}_d$  aufspaltbar ist. **qed.**

Punkte  $x$  mit  $\langle w, x \rangle + b = 0$  erhalten vom Halbraum  $H_{w,b}$  das Label 1, da  $\text{sign}(0) = 1$ . Es wäre befriedigender, wenn wir garantieren könnten, dass positive Labels nur aus positiven Werten von  $\langle w, x \rangle + b$  resultieren. Dies kann man in der Tat auf endlichen Punkt Mengen immer erreichen, wie die folgenden Ausführungen zeigen werden.

**Definition 9.4** *Es seien  $w, x \in \mathbb{R}^d$  und  $b \in \mathbb{R}$ . Die Größe  $|\langle w, x \rangle + b|$  heißt der (vorzeichenlose) funktionale Randabstand der affinen Hyperebene  $H_{w,b}$  vom Punkt  $x$ .*

Beachte, dass jeder von Null verschiedene funktionale Randabstand beliebig vergrößert werden kann, indem  $w$  und  $b$  um den gleichen positiven Faktor  $\lambda > 0$  hochskaliert werden. Dabei bleibt das Vorzeichen unverändert:  $\text{sign}(\langle w, x \rangle + b) = \text{sign}(\langle \lambda w, x \rangle + \lambda b)$ .

**Lemma 9.5** *Für eine endliche Punktmenge  $S$  in  $\mathbb{R}^d$  gilt folgendes. Wenn ein Binärmuster auf den Punkten aus  $S$  mit einem affinen Halbraum realisierbar ist, dann ist dies bei geeigneter Wahl von  $(w, b)$  auch so möglich, dass  $H_{w,b}$  einen funktionalen Randabstand von mindestens 1 zu jedem der Punkte aus  $S$  aufweist.*

**Beweis** Betrachte eine affine Hyperebene  $H$ , die ein vorgegebenes Binärmuster realisiert. Sie hat zu allen nicht auf ihr liegenden Punkten aus  $S$  einen echt positiven Randabstand. Durch hinreichend kleine Parallelverschiebung können wir erreichen, dass einerseits zu allen Punkten aus  $S$  ein positiver funktionaler Randabstand entsteht, aber andererseits das realisierte Binärmuster nicht verändert wird. Sind alle funktionalen Randabstände verschieden von 0, dann können wir sie durch Skalierung beliebig vergrößern. **qed.**

### 9.1.2 Die Berechnungskomplexität der Klasse der Halbräume

Beim *uniformen Kostenmaß* wird eine Zahl als eine Einheit gesehen und eine arithmetisch-logische Grundoperation auf zwei Zahlen zählt als 1 Rechenschritt. Beim *logarithmischen Kostenmaß* wird die Länge einer Zahl mit der Anzahl der Bits in ihrer Binärcodierung gemessen (was auch bei der Bestimmung der Eingabelänge eine Rolle spielt) und die Kosten einer arithmetisch-logischen Operation auf zwei Zahlen werden gleich gesetzt mit der Summe ihrer Bitlängen (d.h. im Wesentlichen: es wird die Anzahl der benötigten Bitoperationen gezählt).

Wir werden in diesem Abschnitt zeigen, dass das Konsistenzproblem für die Klasse  $\mathcal{H}_d$  effizient (in Anhängigkeit vom Komplexitätsparameter  $d$ ) lösbar ist, wenn wir  $\mathbb{Q}^d$  (statt  $\mathbb{R}^d$ ) als den Grundbereich ansehen und das logarithmische Kostenmaß zugrunde legen. Wir nutzen dabei aus, dass das Problem der linearen Programmierung — Optimierung einer linearen Zielfunktion unter linearen Randbedingungen vom Typ „ $\geq$ “ oder „ $\leq$ “ — effizient lösbar ist (zumindest bei Zugrundelegung des logarithmischen Kostenmaßes).<sup>1</sup>

Ein Spezialfall von linearer Programmierung ist das Problem zu entscheiden, ob vorgegebene lineare Randbedingungen (in Variablen mit Werten in  $\mathbb{Q}$ ) simultan erfüllt werden können. Wir werden im Beweis zu folgendem Satz zeigen, dass sich das Konsistenzproblem für affine Halbräume als ein solches Erfüllbarkeitsproblem darstellen lässt.

**Theorem 9.6** *Das Konsistenzproblem zur Klasse  $\text{HS} = (\text{HS}_d)_{d \geq 1}$  der affinen Halbräume (über dem Grundbereich  $(\mathbb{Q}^d)_{d \geq 1}$ ) ist ein Teilproblem von linearer Programmierung und daher (bezüglich des logarithmischen Kostenmaßes) effizient lösbar.*

---

<sup>1</sup>Die Frage, ob lineare Programmierung auch bezüglich uniformem Kostenmaß in Polynomialzeit lösbar ist, ist völlig offen. Bei logarithmischem Kostenmaß gibt es Polynomialzeitalgorithmen (zum Beispiel der Ellipsoid-Algorithmus oder „Interior-Point“-Methoden).

**Beweis** Das Konsistenzproblem zu  $\text{HS} = (\text{HS}_d)_{d \geq 1}$  ist, wie wir wissen, folgendes Problem:

**Eingabeinstanz:** zwei endliche Punktmenge  $S^+, S^- \subset \mathbb{Q}^d$  (wobei der obere Index „+“ bzw. „-“ die binäre Markierung anzeigt und  $d \geq 1$  variabel ist)

**Frage:** Existieren  $w \in \mathbb{Q}^d$  und  $b \in \mathbb{Q}$ , so dass  $S^+ \subseteq \text{HS}_{w,b}^+$  und  $S^- \subseteq \text{HS}_{w,b}^-$ ?

Mit Lemma 9.5 ergibt sich, dass folgende Aussagen äquivalent sind:

$$\begin{aligned} \exists w \in \mathbb{Q}^d, b \in \mathbb{Q} : & \quad (S^+ \subseteq \text{HS}_{w,b}^+) \wedge (S^- \subseteq \text{HS}_{w,b}^-) \\ \exists w \in \mathbb{Q}^d, b \in \mathbb{Q} : & \quad (\forall x \in S^+ : \langle w, x \rangle + b \geq 0) \wedge (\forall x \in S^- : \langle w, x \rangle + b < 0) \\ \exists w' \in \mathbb{Q}^d, b' \in \mathbb{Q} : & \quad (\forall x \in S^+ : \langle w', x \rangle + b' \geq 1) \wedge (\forall x \in S^- : \langle w', x \rangle + b' \leq -1) \end{aligned}$$

Wir landen somit bei der Frage, ob wir Werte an die Variablen  $w = (w_1, \dots, w_d)$  und  $b$  so zuweisen können, dass die linearen Randbedingungen

$$(\forall x \in S^+ : \langle w, x \rangle + b \geq 1) \wedge (\forall x \in S^- : \langle w, x \rangle + b \leq -1)$$

simultan erfüllt sind (Spezialfall von linearer Programmierung).

**qed.**

Wir merken kurz an, dass die Punktmenge  $S^+, S^-$  *linear separierbar* heißen, falls eine sie trennende Hyperebene  $H_{w,b}$  im Sinne von

$$(\forall x \in S^+ : \langle w, x \rangle + b > 0) \wedge (\forall x \in S^- : \langle w, x \rangle + b < 0) \quad (4)$$

existiert. Unter der Realisierbarkeitsannahme des PAC-Lernmodells gilt, dass die durch  $S \sim \mathcal{D}^m$  gegebenen Mengen  $S^+, S^-$  linear separierbar sind. Beim agnostischen PAC-Lernmodell befinden wir uns dagegen dann im nicht-separierbaren Fall. Es lässt sich zeigen (hier ohne Beweis), dass das Problem  $\text{MinDis-E}(\text{HS})$  NP-hart ist.

Effiziente Lösbarkeit des Konsistenzproblems und NP-Härte von „Minimum Disagreement“ haben Konsequenzen:

**Theorem 9.7** 1. Die Klasse der affinen Halbräume ist unter der Realisierbarkeitsannahme effizient PAC-lernbar.

2. Die Klasse der affinen Halbräume ist nicht effizient agnostisch PAC-lernbar (außer wenn  $RP = NP$ ).

## 9.2 Das Rosenblatt'sche Perzeptron

Es sei  $(x_1, y_1), \dots, (x_m, y_m) \in \mathbb{R}^d \times \{-1, 1\}$  eine Folge von markierten Trainingsbeispielen. Die Menge  $\{x_1, \dots, x_m\}$  zerfällt dann in  $S^+ = \{x_i : y_i = 1\}$  und  $S^- = \{x_i : y_i = -1\}$ . Die Bedingung (4) für eine  $S^+$  und  $S^-$  linear separierende Hyperebene lässt sich mit Hilfe der Labels  $y_i$  auch schreiben wie folgt:

$$\forall i = 1, \dots, m : y_i(\langle w, x_i \rangle + b) > 0 \quad . \quad (5)$$

Im Jahre 1958 publizierte Rosenblatt einen Algorithmus, genannt Perzeptron, welcher  $w, b$  iterativ modifiziert, solange die Bedingung (5) verletzt ist. Wir beschreiben diesen Algorithmus der Einfachheit halber für den homogenen Fall (mit  $b = 0$ ), wobei wir voraussetzen dürfen, dass alle  $x_i$  vom Nullvektor verschieden sind.<sup>2</sup>

**Initialisierung:** Setze  $w^{(1)} = \vec{0}$ .

**Hauptschleife:** Für  $t = 1, 2, 3, \dots$  mache folgendes:

Falls ein  $i \in [m]$  mit  $y_i \langle w^{(t)}, x_i \rangle \leq 0$  existiert, dann setze

$$w^{(t+1)} = w^{(t)} + y_i x_i \quad . \quad (6)$$

Falls nicht, dann gibt  $w^{(t)}$  aus und stoppe.

Die Aktualisierung (6) arbeitet (im Sinne der Bedingung (5)) in die richtige Richtung, da

$$y_i \langle w^{(t+1)}, x_i \rangle = y_i \langle w^{(t)} + y_i x_i, x_i \rangle = y_i \langle w^{(t)}, x_i \rangle + \langle x_i, x_i \rangle$$

und für  $x_i \neq \vec{0}$  gilt  $\langle x_i, x_i \rangle > 0$ .

Das folgende Resultat zeigt, dass das Perzeptron nach endlich vielen Iterationen eine separierende Hyperebene findet (sofern sie existiert):

**Theorem 9.8** *Wir setzen den separablen Fall voraus. Es sei*

$$\begin{aligned} B &= \min\{\|w\| : y_i \langle w, x_i \rangle \geq 1 \text{ für alle } i \in [m]\} \quad , \\ R &= \max\{\|x_i\| : i \in [m]\} \quad . \end{aligned}$$

*Sei  $T$  die Anzahl der Iterationen, die (6) durchlaufen. Mit diesen Notationen gilt:  $T \leq R^2 B^2$  und der ausgegebene Gewichtsvektor  $w^{(T+1)}$  erfüllt die Separabilitätsbedingung (5).*

**Beweis** Das Perzeptron steigt aus der Hauptschleife nur dann aus, wenn die Separabilitätsbedingung erfüllt ist. Es genügt also zu zeigen, dass die Anzahl  $T$  der Aktualisierungen des Gewichtsvektors durch  $R^2 B^2$  nach oben beschränkt ist. Der Parameter  $B$  (s. oben) gibt die kleinstmögliche Euklidische Länge eines Gewichtsvektors an, der die Bedingung (5) mit einem funktionalen Randabstand von mindestens 1 erfüllt. Es sei  $w^*$  ein Gewichtsvektor mit  $\|w^*\| = B$ , der das leistet. Unser Ziel ist der Nachweis von folgender Bedingung:

$$1 \geq \underbrace{\frac{\langle w^*, w^{(T+1)} \rangle}{\|w^*\| \cdot \|w^{(T+1)}\|}}_{=\cos(w^*, w^{(T+1)})} \geq \frac{\sqrt{T}}{RB} \quad . \quad (7)$$

Wenn wir die Ungleichungen in (7) nach  $T$  auflösen, ergibt sich sofort  $T \leq R^2 B^2$ . Die erste Ungleichung in (7) ergibt sich aus „Cauchy-Schwartz“. Der Nachweis der zweiten Ungleichung in (7) ergibt sich aus folgenden Rechnungen:

---

<sup>2</sup>Vergleiche mit der Reduktion des  $d$ -dimensionalen inhomogenen Falles auf den  $(d + 1)$ -dimensionalen homogenen Fall.

$$1. \langle w^*, w^{(t+1)} \rangle - \langle w^*, w^{(t)} \rangle = \langle w^*, y_i x_i \rangle = y_i \langle w^*, x_i \rangle \geq 1.$$

Mit  $\langle w^*, w^{(1)} \rangle = \langle w^*, \vec{0} \rangle = 0$  ergibt sich induktiv  $\langle w^*, w^{(T+1)} \rangle \geq T$ .

$$2. \|w^{(t+1)}\|^2 = \|w^{(t)} + y_i x_i\|^2 = \|w^{(t)}\|^2 + \underbrace{2y_i \langle w^{(t)}, x_i \rangle}_{\leq 0} + \|x_i\|^2 \leq \|w^{(t)}\|^2 + R^2.$$

Mit  $\|w^{(1)}\|^2 = \|\vec{0}\|^2 = 0$  ergibt sich hieraus induktiv  $\|w^{(T+1)}\|^2 \leq TR^2$  und somit  $\|w^{(T+1)}\| \leq \sqrt{TR}$ .

Aus  $\langle w^*, w^{(T+1)} \rangle \geq T$ ,  $\|w^*\| = B$  und  $\|w^{(T+1)}\| \leq \sqrt{TR}$  folgt unmittelbar

$$\frac{\langle w^*, w^{(T+1)} \rangle}{\|w^*\| \cdot \|w^{(T+1)}\|} \geq \frac{T}{B\sqrt{TR}} = \frac{\sqrt{T}}{RB},$$

was den Beweis abschließt. **qed.**

Im „worstcase“ können  $B$  und  $R$  exponentiell von der Eingabelänge (in binärer Kodierung) abhängen. I.A. ist also das Perzeptron kein effizienter Algorithmus. Wenn jedoch die Parameter  $R$  und  $B$  nur moderat groß sind (was bei vielen Anwendungen der Fall sein mag), dann ist die obere Schranke  $R^2 B^2$  gar nicht so übel.

### 9.3 Lineare Regression

In diesem Abschnitt operieren wir mit dem Grundbereich  $\mathcal{X} = \mathbb{R}^d$  und der Labelmenge  $\mathcal{Y} = \mathbb{R}$ . Eine Trainingssequenz hat daher die Form

$$S = [(x_1, y_1), \dots, (x_m, y_m)] \in (\mathbb{R}^d \times \mathbb{R})^m. \quad (8)$$

Wir betrachten die Hypothesenklasse  $\text{LIN}_d$  der affinen Funktionen gemäß (1) und die quadratische Verlustfunktion

$$\ell(h, (x, y)) = (h(x) - y)^2.$$

Es sei  $\mathcal{D}$  eine Verteilung auf  $\mathbb{R}^d \times \mathbb{R}$ . Wie üblich setzen wir uns das Ziel, eine Hypothese  $h \in \text{LIN}_d$  mit möglichst kleinem Wert von  $L_{\mathcal{D}}(h)$  (dem erwarteten quadratischen Fehler von  $h$  bezüglich  $\mathcal{D}$ ) zu finden.

**Warnung:** Die auf VC-Dimension aufbauende Theorie ist nicht unmittelbar auf nicht-binäre Voraussageprobleme anwendbar. Evtl. werden wir zu einem späteren Zeitpunkt der Vorlesung klären, wie groß Trainingsmengen bei Regressionsproblemen (oder allgemeiner bei nicht-binären Voraussageproblemen) zu sein haben.

**Beispiel 9.9** *Das Erraten des Gewichtes eines Babys anhand seines Geburtsgewichtes und seines Alters (auf Basis einer gegebenen Trainingsmenge) ist ein 2-dimensionales Regressionsproblem.*



Wir betrachten im Folgenden die ERM-Lernregel: gegeben eine Trainingsmenge  $S$ , finde eine Hypothese  $h \in \text{LIN}_d$  mit möglichst kleinem Wert von  $\hat{L}_S(h)$  (dem mittleren quadratischen Fehler von  $h$  auf der Trainingsmenge  $S$ ). Im Falle  $d = 1$  wird eine der ERM-Lernregel entsprechende Hypothese als „Ausgleichsgrade“ bezeichnet. Die Methode zum Berechnen einer Hypothese  $h$  gemäß der ERM-Lernregel bei beliebig hoher Dimension  $d$  ist unter dem Namen „Least Squares“ bekannt.

### 9.3.1 Die „Least Squares“-Methode

Wir beschränken uns der Einfachheit halber wieder auf den homogenen Fall (mit  $b = 0$ ) und betrachten das Problem

$$\operatorname{argmin}_{w \in \mathbb{R}^d} \hat{L}_S(h_{w,0}) = \operatorname{argmin}_{w \in \mathbb{R}^d} \left\{ \frac{1}{m} \cdot \sum_{i=1}^m (\langle w, x_i \rangle - y_i)^2 \right\} .$$

Wenn wir den Gradienten der Zielfunktion auf Null setzen, erhalten wir die Gleichung

$$\frac{2}{m} \sum_{i=1}^m (\langle w, x_i \rangle - y_i) x_i = 0 .$$

Dies ist äquivalent zu

$$0 = \sum_{i=1}^m x_i (x_i^\top w - y_i) = \left( \sum_{i=1}^m x_i x_i^\top \right) w - \sum_{i=1}^m y_i x_i .$$

Wenn wir

$$A = \sum_{i=1}^m x_i x_i^\top \quad \text{und} \quad b = \sum_{i=1}^m y_i x_i \tag{9}$$

setzen, haben wir also das lineare Gleichungssystem  $Aw = b$  zu lösen.

**Beachte:**  $x_i \in \mathbb{R}^d$  ist ein Spaltenvektor und, als Matrix aufgefasst, eine  $(d \times 1)$ -Matrix. Somit ist  $x_i^\top$  eine  $(1 \times d)$ -Matrix und  $x_i x_i^\top$  (sowie die Matrix  $A$ ) eine  $(d \times d)$ -Matrix. Der Eintrag in Zeile  $j$  und Spalte  $k$  von  $x_i x_i^\top$  ist gleich  $x_i(j) x_i(k)$ , also die  $j$ -te Komponente des Vektors  $x_i$  multipliziert mit seiner  $k$ -ten Komponente.

Setze  $r = \operatorname{rank}(A)$ . Ein sympathisch einfacher Fall wäre  $r = d$ . Dann besitzt  $A$  eine Inverse  $A^{-1}$  und  $w = A^{-1}b$  wäre eine optimale Wahl von  $w$ . Wir wollen uns im Folgenden aber mit dem interessanteren Fall  $r < d$  beschäftigen.

Mit  $\operatorname{span}(A)$  bezeichnen wir den Vektorraum, der von den Spaltenvektoren von  $A$  aufgespannt wird. Das Gleichungssystem  $Aw = b$  ist genau dann lösbar, wenn  $b \in \operatorname{span}(A)$ . Dies ist bei unserer Anwendung glücklicherweise der Fall:

**Lemma 9.10** *Wenn  $A$  und  $b$  gemäß (9) gewählt werden, dann gilt  $b \in \operatorname{span}(A)$ .*

Den Beweis des Lemmas holen wir weiter unten nach.

Das folgende Resultat klärt, wie wir im Falle der Lösbarkeit an eine Lösung  $w$  des Gleichungssystems  $Aw = b$  gelangen.

**Lemma 9.11** Falls  $b \in \text{span}(A)$ , dann existiert eine Matrix  $A^\dagger$  (genannt das Pseudo-Inverse zu  $A$ ) mit

$$A(A^\dagger b) = (AA^\dagger)b = b .$$

Weiterhin läßt sich  $A^\dagger$  aus  $A$  und  $b$  effizient berechnen.

Auch den Beweis dieses Lemmas holen wir weiter unten nach.

Im Falle  $r = d$  stimmt das Pseudo-Inverse  $A^\dagger$  von  $A$  mit der Inversen  $A^{-1}$  überein. Wir erhalten somit das Hauptresultat dieses Abschnittes:

**Theorem 9.12** Sei gemäß (8) und  $A, b$  seien gemäß (9) gegeben. Dann ist  $w = A^\dagger b$  ein der ERM-Lernregel (bezüglich quadratischem Fehler) entsprechender Gewichtsvektor. Er läßt sich effizient aus  $S$  ermitteln.

Am Ende dieses Abschnittes holen wir die zwei fehlenden Beweise nach.

**Beweis**[Lemma 9.10] Der Beweis benutzt die aus der linearen Algebra bekannte Tatsache, dass jede (reelle) Matrix  $M$  die Gleichung  $\text{rank}(MM^\top) = \text{rank}(M)$  erfüllt. Es ist leicht nachzurechnen, dass für  $M = [x_1 \dots x_m]$  (also die Matrix mit den Spaltenvektoren  $x_1, \dots, x_m$ ) die Gleichung

$$\sum_{i=1}^m x_i x_i^\top = MM^\top$$

gilt. Da  $A = \sum_{i=1}^m x_i x_i^\top = MM^\top$  und da die Spaltenvektoren der Matrix  $MM^\top$  Linearkombinationen von  $M$ 's Spaltenvektoren sind, können wir  $\text{span}(A) \subseteq \text{span}(M)$  folgern. Wegen  $A = MM^\top$  haben  $A$  und  $M$  den gleichen Rang. Daher gilt sogar  $\text{span}(A) = \text{span}(M)$ . Wegen  $b = \sum_{i=1}^m y_i x_i$  und  $M = [x_1 \dots x_m]$  gilt  $b \in \text{span}(M)$  und damit auch  $b \in \text{span}(A)$ . **qed.**

**Beweis**[Lemma 9.11] Der Beweis benutzt das aus der linearen Algebra bekannte Spektralthem, welches folgendes besagt. Jede symmetrische ( $d \times d$ )-Matrix  $A$  vom Range  $r$  (wie zum Beispiel  $A = \sum_{i=1}^m x_i x_i^\top$ ) besitzt eine (effizient berechenbare) Zerlegung der Form

$$A = VDV^\top \quad \text{mit} \quad D = \text{diag}(\lambda_1, \dots, \lambda_r, 0, \dots, 0) .$$

Hierbei gilt:

1.  $V = [v_1, \dots, v_d]$  bezeichnet eine orthogonale Matrix (d.h.,  $VV^\top = V^\top V = I$  mit  $I =$  Einheitsmatrix) und es gilt  $\text{span}(A) = \text{span}(v_1, \dots, v_r)$ .
2.  $\text{diag}(\dots)$  bezeichnet eine Diagonalmatrix mit den in „ $\dots$ “ aufgelisteten Werten auf der Hauptdiagonalen und  $\lambda_1, \dots, \lambda_r$  sind die  $r$  nicht-trivialen (also von 0 verschiedenen) reellen Eigenwerte von  $A$ .

Wir setzen nun  $D^\dagger = \text{diag}(\lambda_1^{-1}, \dots, \lambda_r^{-1}, 0, \dots, 0)$ ,  $A^\dagger = VD^\dagger V^\top$  und rechnen nach:

$$AA^\dagger b = VDV^\top VD^\dagger V^\top b = VDD^\dagger V^\top b = V \text{diag}(1, \dots, 1, 0, \dots, 0) V^\top b = \sum_{i=1}^r v_i v_i^\top b = \sum_{i=1}^r \langle v_i, b \rangle v_i .$$

Der letzte Ausdruck beschreibt die Projektion von  $b$  auf  $\text{span}(v_1, \dots, v_r) = \text{span}(A)$ . Da wir  $b \in \text{span}(A)$  vorausgesetzt haben, muss diese Projektion mit  $b$  übereinstimmen. **qed.**

### 9.3.2 Reduktion von polynomieller auf lineare Regression

Es seien  $\mathcal{H} = (\mathcal{H}_n)_{n \geq 1}$  und  $\mathcal{H}' = (\mathcal{H}'_n)_{n \geq 1}$  zwei parameterisierte Hypothesenklassen reellwertiger Funktionen;  $\mathcal{X} = (\mathcal{X}_n)_{n \geq 1}$  und  $\mathcal{X}' = (\mathcal{X}'_n)_{n \geq 1}$  seien die zugehörigen Grundbereiche. Eine *polynomielle L-Reduktion* von  $\mathcal{H}$  auf  $\mathcal{H}'$ , notiert als  $\mathcal{H} \leq_{pol}^L \mathcal{H}'$ , ist so definiert (mit einer Instanz- und zwei Hypothesentransformationen) wie wir das von binären Hypothesenklassen kennen. Der einzige Unterschied besteht darin, dass die beteiligten Klassen jetzt reellwertige Funktionen enthalten.

**Theorem 9.13** *Unter der Voraussetzung  $\mathcal{H} \leq_{pol}^L \mathcal{H}'$  gilt folgendes:*

1. *Wenn das Regressionsproblem zur Klasse  $\mathcal{H}'$  effizient lösbar ist (im Sinne des üblichen  $(\varepsilon, \delta)$ -Kriteriums), so gilt dies auch für das Regressionsproblem zur Klasse  $\mathcal{H}$ .*
2. *Wenn die ERM-Lernregel für  $\mathcal{H}'$  effizient implementiert werden kann (Auffinden einer Hypothese aus  $\mathcal{H}'$  mit kleinstmöglichem quadratischen Fehler auf den Trainingsdaten), so gilt dies entsprechend auch für die Klasse  $\mathcal{H}$ .*

**Beweis** Wir beschränken uns auf den Beweis der zweiten Aussage. Es sei

$$S = (x_1, y_1), \dots, (x_m, y_m) \in (\mathcal{X}_n \times \mathbb{R})^m$$

eine gegebene Sequenz von Trainingsdaten. Zum Auffinden einer ERM-Hypothese aus  $\mathcal{H}$  gehe vor wie folgt:

1. Berechne  $S' = (x'_1, y_1), \dots, (x'_m, y_m) \in (\mathcal{X}'_n \times \mathbb{R})^m$ . Dies ist eine  $m$ -fache Anwendung der Instanzentransformation  $x \mapsto x'$ .
2. Berechne eine ERM-Hypothese  $h' \in \mathcal{H}'_n$  zu der Trainingsmenge  $S'$ .
3. Berechne die Hypothese  $h \in \mathcal{H}_n$ , die sich aus  $h'$  gemäß der zweiten Hypothesentransformation ergibt.
4. Gib  $h$  als ERM-Hypothese zur Trainingsmenge  $S$  aus.

Fixiere eine beliebige Hypothese  $h_* \in \mathcal{H}_n$ . Wir haben  $\hat{L}_S(h) \leq \hat{L}_S(h_*)$  zu zeigen. Dies geht mit einem „Schach Matt“ in drei Zügen:

- Es sei  $h'_*$  die Hypothese, die sich aus  $h_*$  gemäß der ersten Hypothesentransformation ergibt. Da  $h_*(x_i) = h'_*(x'_i)$  und da  $S'$  die reellwertigen Labels von  $S$  übernommen hat, folgt  $\hat{L}_{S'}(h'_*) = \hat{L}_S(h_*)$ .
- Da  $h'$  eine ERM-Hypothese zu  $S'$  ist, folgt  $\hat{L}_{S'}(h') \leq \hat{L}_{S'}(h'_*)$ .
- Da  $h$  sich aus  $h'$  über  $h' \mapsto h$  ergibt, gilt wieder  $h(x_i) = h'(x'_i)$ , was  $\hat{L}_S(h) = \hat{L}_{S'}(h')$  zur Folge hat.

Wenn wir die drei Beobachtungen zusammensetzen, erhalten wir  $\hat{L}_S(h) = \hat{L}_{S'}(h') \leq \hat{L}_{S'}(h'_*) = \hat{L}_S(h_*)$ , was den Beweis abschließt. **qed.**

Es bezeichne  $\text{POL}_d$  die Klasse der Polynome in  $d$  Variablen über  $\mathbb{R}$ , d.h.,

$$\text{POL}_d = \{x \mapsto p(x) : p \in \mathbb{R}[X_1, \dots, X_d]\} .$$

Weiter bezeichne  $\text{POL}_d^n$  die Teilklasse der Polynome vom Maximalgrad  $n$ . Der Grad eines Monoms der Form  $X_1^{n_1} \dots X_d^{n_d}$  ist per Definition gleich  $n_1 + \dots + n_d$  (und der Grad eines Polynoms ist das Maximum der Grade seiner Monome).

**Lemma 9.14** *Es gibt  $\binom{n+d}{d}$  Monome vom Maximalgrad  $n$  in  $d$  Variablen.*

**Beweis** Es gibt genau  $\binom{n+d}{d}$  geordnete Partitionen der Zahl  $n$  in  $d+1$  Summanden aus  $\mathbb{N}_0$  (eine aus der Vorlesung über „Diskrete Mathematik“ bekannte Tatsache). Da diese Zahlpartitionen und die Monome vom Maximalgrad  $n$  in  $d$  Variablen sich 1-zu-1 entsprechen, ergibt sich die Aussage des Lemmas. **qed.**

**Beispiel 9.15** *Es sei  $n = 6$  und  $d = 3$ . Das Monom  $X_1 X_3^2 = 1^3 X_1^1 X_2^0 X_3^2$  entspricht der geordneten Partition von  $n = 6$  in die Summanden  $(3, 1, 0, 2)$ , und umgekehrt.*

**Theorem 9.16** *Es sei  $d$  eine beliebige aber fest gewählte Konstante,  $\text{LIN} = (\text{LIN}_n)_{n \geq 1}$  und  $\text{POL}_d = (\text{POL}_d^n)_{n \geq 1}$ . Mit diesen Bezeichnungen gilt:  $\text{POL}_d \leq_{\text{pol}}^L \text{LIN}$ .*

**Beweis** Wir setzen  $n' = \binom{n+d}{d} = O(n^d)$ . Die Abbildung  $n \mapsto n'$  ist injektiv und (da  $d$  eine Konstante ist) polynomiell in  $n$  beschränkt. Es sei  $M_1, \dots, M_{n'}$  eine beliebige aber feste Auflistung aller Monome vom Maximalgrad  $n$  in  $d$  Variablen. Es sei  $X'_1, \dots, X'_{n'}$  eine entsprechende Auflistung von neuen Variablen. Wenn wir in einem Polynom  $h \in \text{POL}_d^n$  jedes Monom  $M_i$  durch die Variable  $X'_i$  ersetzen, erhalten wir eine lineare Funktion  $h'$ . Dies liefert die Hypothesentransformation  $h \mapsto h'$ . Die Rücksubstitution von  $M_i$  für  $X'_i$  ergibt die Hypothesentransformation  $h' \mapsto h$ . Es sei  $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ . Es bezeichne  $M_i(x)$  die Auswertung von  $M_i$  an der Stelle  $x$ . Wir setzen  $x' = (M_1(x), \dots, M_{n'}(x))$ . Dies liefert die Instanzentransformation  $x \mapsto x'$ . Es ist leicht zu verifizieren, dass diese Transformationen alle Definitionskriterien einer polynomiellen L-Reduktion erfüllen. **qed.**

Indem wir die Theoreme 9.12, 9.13 und 9.16 kombinieren, erhalten wir die

**Folgerung 9.17** *Eine ERM-Hypothese (bezüglich quadratischem Fehler) ist für die Klasse  $\text{POL}_d$  in Polynomialzeit berechenbar.*

## 9.4 Logistische Regression

Es bezeichne

$$S(z) = \frac{1}{1 + \exp(-z)}$$

die sogenannte *Sigmoid-Funktion*. Sie hat folgende (leicht zu verifizierende) Eigenschaften:

1.  $S$  ist streng monoton wachsend.
2.  $\lim_{z \rightarrow -\infty} S(z) = 0$ ,  $\lim_{z \rightarrow \infty} S(z) = 1$  und  $S(0) = 1/2$ .

Wir können  $S$  als eine glatte Version einer von 0 auf 1 wechselnden Schwellenfunktion ansehen. Wir definieren die Klasse  $\text{SIG}_d^0$  wie folgt:

$$\text{SIG}_d^0 = S \circ \text{LIN}_d^0 = \{x \mapsto S(\langle w, x \rangle) : w \in \mathbb{R}^d\} .$$

Wir setzen der Kürze halber

$$h_w(x) = S(\langle w, x \rangle) = \frac{1}{1 + \exp(-\langle w, x \rangle)} .$$

**Lemma 9.18** *Wenn wir  $h_w(x)$  (bzw.  $1 - h_w(x)$ ) interpretieren als die Wahrscheinlichkeit, eine Instanz  $x$  mit dem Label 1 (bzw.  $-1$ ) zu versehen, dann ist die Wahrscheinlichkeit  $x$  mit dem Label  $y \in \{-1, 1\}$  zu versehen gegeben durch  $(1 + \exp(-y\langle w, x \rangle))^{-1}$ .*

**Beweis** Die Aussage ist für  $y = 1$  offensichtlich richtig. Eine einfache Rechnung zeigt, dass

$$1 - h_w(x) = \frac{1}{1 + \exp(\langle w, x \rangle)} .$$

Somit stimmt die Aussage auch für  $y = -1$ .

**qed.**

Die *logistische Verlustfunktion* ist definiert wie folgt:

$$\ell(h_w, (x, y)) = \ln(1 + \exp(-y\langle w, x \rangle)) .$$

Sie bestraft eine Hypothese, die das Label  $y$  für  $x$  mit Wahrscheinlichkeit  $p$  korrekt voraussagt, mit  $\ln(1/p)$ . Dieser Strafterm ist gleich 0 für  $p = 1$  und konvergiert mit logarithmischer Geschwindigkeit gegen  $\infty$  für  $p \rightarrow 0$ .

Wir sagen eine Verlustfunktion  $\ell$  entspricht dem „Maximum Likelihood (ML)“-Prinzip, wenn die ERM-Lernregel bezüglich  $\ell$  zu einer Hypothese führt, welche die Wahrscheinlichkeit einer gegebenen Trainingsmenge maximiert.

**Theorem 9.19** *Wir interpretieren  $h_w(x)$  (bzw.  $1 - h_w(x)$ ) als die Wahrscheinlichkeit, eine Instanz  $x$  mit dem Label 1 (bzw.  $-1$ ) zu versehen. Weiterhin unterstellen wir, dass die zufälligen Markierungen verschiedener Instanzen unabhängig von einander erfolgen. Unter diesen Voraussetzungen entspricht die logistische Verlustfunktion dem ML-Prinzip.*

**Beweis** Es sei  $S = (x_1, y_1), \dots, (x_m, y_m) \in \mathbb{R}^d \times \{-1, 1\}$  eine gegebene Sequenz von Trainingsdaten. Die  $S$  durch  $h_w$  zugewiesene Wahrscheinlichkeit ist dann gegeben durch

$$p_S(w) = \prod_{i=1}^m \frac{1}{1 + \exp(-y_i \langle w, x_i \rangle)} .$$

Offensichtlich sind die folgenden Optimierungsprobleme äquivalent:

- Maximieren von  $p_S(w)$ .
- Minimieren von  $\prod_{i=1}^m (1 + \exp(-y_i \langle w, x_i \rangle))$
- Minimieren von  $\frac{1}{m} \sum_{i=1}^m \ln(1 + \exp(-y_i \langle w, x_i \rangle))$ .

Die letzte Zielfunktion ist identisch zu  $\hat{L}_S(h_w)$ , wenn wir die logistische Verlustfunktion zugrunde legen. **qed.**

Wir merken kurz an, dass die Zielfunktion

$$\hat{L}_S(h_w) = \frac{1}{m} \sum_{i=1}^m \ln(1 + \exp(-y_i \langle w, x_i \rangle))$$

eine in  $w$  konvexe Funktion ist. Zur Minimierung konvexer Funktionen existieren effiziente Standardwerkzeuge (zum Beispiel „Interior Point“-Methoden). Die ERM-Lernregel bei Zugrundelegung der logistischen Verlustfunktion ist daher effizient implementierbar.