

# Regularisierung

M. Gruber

KW 49

Wir folgen [1], Lec 12.

Bei der Regularisierung wird ein modifizierter *in-sample error* minimiert. Regularisierung ist ein Mittel zur Vermeidung von Überanpassung.

## Lösung eines einfachen Lernproblems mit Regularisierung

- Zielfunktion mit stochastischem Rauschen

$$y = f(x) + \varepsilon(x) \text{ mit } \mathbf{E} \varepsilon(x) = 0, \mathbf{Var} \varepsilon(x) = \sigma^2.$$

- Lernmenge

$$D = \left\{ \begin{bmatrix} x^{(i)} \\ y^{(i)} \end{bmatrix} \mid i = 1, \dots, N \right\} \subset [-1, 1] \times \mathbf{R}.$$

- Hypothesenraum: Polynome  $Q$ -ter Ordnung,

$$H_Q = \left\{ \sum_{0 \leq q \leq Q} w_q \tilde{L}_q \mid \tilde{L}_q \text{ normierte Legendre-Polynome, } w \in \mathbf{R}^{Q+1} \right\}.$$

Es besteht eine 1-zu-1-Beziehung zwischen den  $h \in H_Q$  und den Gewichten  $w \in \mathbf{R}^{n+1}$ .

- *Erweiterter (augmented) in-sample error*

$$\text{Err}_{\text{aug}}(w) = \frac{1}{N} \|Zw - y\|^2 + \frac{\lambda}{N} \|w\|^2 = \frac{1}{N} (Zw - y)^T (Zw - y) + \frac{\lambda}{N} w^T w.$$

Dabei ist  $Z = \begin{bmatrix} \tilde{L}_0(x^{(1)}) & \dots & \tilde{L}_Q(x^{(1)}) \\ \vdots & \ddots & \vdots \\ \tilde{L}_0(x^{(N)}) & \dots & \tilde{L}_Q(x^{(N)}) \end{bmatrix}$  und  $\lambda > 0$  der "geeignet gewählte" Regularisierungsparameter.

- Der Lernalgorithmus minimiert  $\text{Err}_{\text{aug}}(w)$ , d.h. hier: er löst

$$\frac{N}{2} \nabla \text{Err}_{\text{aug}}(w) = Z^T (Zw - y) + \lambda w = 0.$$

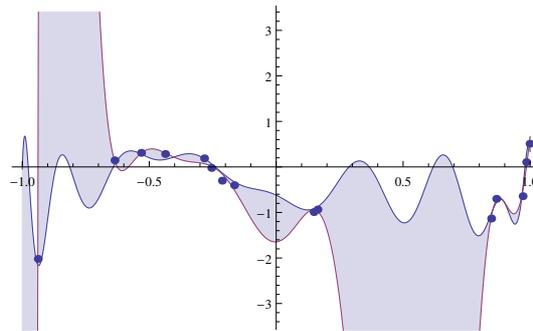
Die Lösung ist

$$w_{\text{aug}} = (Z^T Z + \lambda I)^{-1} Z^T y.$$

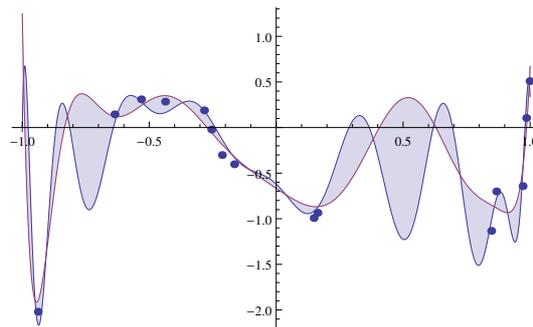
### Diskussion

- Der Regularisierungsparameter  $\lambda > 0$  entspricht einer Beschränkung  $\|w\| \leq C$  des Hypothesenraums. Eine Zunahme von  $\lambda$  entspricht einer Abnahme von  $C$ .
- Mögliche Gefahren:  $\lambda$  zu klein—*overfitting*,  $\lambda$  zu groß—*underfitting*.
- Welcher  $\lambda$ -Wert ist gut? Nächste Vorlesung (über Validierung) abwarten!

**Beispiel 1** Zielfunktion (blau) ist ein Polynom 19. Ordnung. Die Lernmenge ( $N = 15$ ) ist stochastisch verrauscht ( $\sigma = 0.1$ ). Der Hypothesenraum besteht aus den Polynomen 11. Ordnung. Der out-of-sample-error der finalen Hypothese (rot) ist das Quadratintegral des schattierten Bereichs. Es beträgt 1130.13.



Zum Vergleich dasselbe Problem, gelöst mit Regularisierung. Der Regularisierungsparameter  $\lambda = 0.8$  bewirkt eine Beschränkung der Gewichte  $w_k$ . Der out-of-sample-error beträgt hier 0.274898.



### Referenzen

- [1] Y. S. Abu-Mostafa. Learning from Data.