

Über Finanzderivate, den Fluch der Dimensionalität und künstliche Intelligenz

Arnulf Jentzen (Departement für Mathematik, ETH Zürich)

ETH Zürich, Raum HG E7, Rämistrasse 101, 8092 Zürich

14:00-15:00, 18. Januar 2018

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Finanzderivat (von Basiswerten abgeleitetes Finanzprodukt)

Eine **europäische Verkaufsoption** ist ein Vertrag zwischen zwei Parteien,

- dem **Aussteller** der europäischen Verkaufsoption und
- dem **Inhaber** der europäischen Verkaufsoption,

welche dem Inhaber der Verkaufsoption das **Recht**, aber nicht die Pflicht, einräumt zu einem vertraglich festgelegten Zeitpunkt $T > 0$ einen vertraglich festgelegten Wert (**Basiswert**) zu einem vertraglich festgelegten Preis (**Ausübungspreis**) $K > 0$ zu verkaufen.

Beispiele für **Basiswerte**: Aktien, Indizes, Anleihen, Rohstoffe, Devisen, Zinsen

Profit durch **europäische Verkaufsoption**: Sei $x_T \geq 0$ Preis des Basiswertes zur Zeit T .

- Der Fall $x_T > K$ liefert Profit $K - x_T$.
- Der Fall $x_T \leq K$ liefert Profit 0 .

Insgesamt also Profit $\max\{K - x_T, 0\}$ (Preis der Verkaufsoption zur Zeit T).

Derivatebewertung: Preis der **Verkaufsoption** zur Zeit 0 .

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T)$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T]$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T]$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T]$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T]$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Geeignete Modellannahmen liefern:

Funktionaler Zusammenhang zwischen Preise der Basiswerte und Preis des Derivates. **Wertfunktion**

$$u: [0, T] \times \mathbb{R}^d \rightarrow \mathbb{R}$$

für Derivat mit $d \in \mathbb{N} = \{1, 2, 3, \dots\}$ Basiswerten. Preis des Derivats

$$u(t, x) \in \mathbb{R}$$

zur Zeit $t \in [0, T]$ in Abhängigkeit der Preise $x = (x_1, \dots, x_d) \in \mathbb{R}^d$ der Basiswerte. Wertfunktion erfüllt **partielle Differentialgleichung**

$$\frac{\partial u}{\partial t}(t, x) + f(x, u(t, x), (\nabla_x u)(t, x), (\text{Hess}_x u)(t, x)) = 0 \quad (\text{PDGL})$$

mit $u(T, x) = g(x)$ für $t \in [0, T]$, $x \in \mathbb{R}^d$ mit geeigneten Funktionen $f: \mathbb{R}^d \times \mathbb{R} \times \mathbb{R}^d \times \mathbb{R}^{d \times d} \rightarrow \mathbb{R}$ und $g: \mathbb{R}^d \rightarrow \mathbb{R}$. **Ziel:** Näherungsweise lösen von (PDGL). Beispiel: **Wärmeleitungsgleichung**

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter **Fluch der Dimensionalität**.

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, \mathbf{x}) + (\Delta_{\mathbf{x}} u)(t, \mathbf{x}) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$\mathbf{x}_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, \mathbf{x}_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, \mathbf{x}_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (Räumliche Diskretisierung) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (Zeitliche Diskretisierung), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Beispiel: Wärmeleitungsgleichung

$$\frac{\partial u}{\partial t}(t, x) + (\Delta_x u)(t, x) = 0.$$

Klassische Näherungsverfahren für (PDGL) leiden unter dem **Fluch der Dimensionalität**.

Finite-Differenzen-Methode: Betrachte $N \in \mathbb{N}$, Gitterpunkte

$$x_m = \left(\frac{m_1}{N}, \frac{m_2}{N}, \dots, \frac{m_d}{N} \right)$$

für $m = (m_1, \dots, m_d) \in \mathbb{Z}^d$ (*Räumliche Diskretisierung*) und

$$t_n = \frac{nT}{N}$$

für $n \in \{0, 1, 2, \dots, N\}$ (*Zeitliche Diskretisierung*), Näherungen

$$\mathbb{U}_{n,m} \approx u(t_n, x_m) \in \mathbb{R}$$

und *Differenzen-Quotienten* in (PDGL). Diskretisierungsfehler $\exists C > 0: \forall N \in \mathbb{N}$:

$$\max_{m \in \{0,1,\dots,N\}^d} |u(t_0, x_m) - \mathbb{U}_{0,m}| \leq C \cdot N^{-1}$$

Rechenaufwand versus **Diskretisierungsfehler**:

N^{d+1} Gitterpunkte versus Diskretisierungsfehler $\varepsilon = C \cdot N^{-1}$.

Also $C^{d+1} \varepsilon^{-(d+1)}$ Gitterpunkte. Rechenaufwand wächst **exponentiell** in d .

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung $\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}$.

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung

$$\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}.$$

Künstliches neuronales Netz mit $s \in \mathbb{N}$ verborgenen Schichten

- $\rho \in \mathbb{N}$ hinreichend groß,
- Funktion $\mathcal{R}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ mit $\forall x = (x_1, \dots, x_d) \in \mathbb{R}^d$:

$$\mathcal{R}(x) = (\max\{x_1, 0\}, \dots, \max\{x_d, 0\}),$$

- $\forall \theta = (\theta_1, \dots, \theta_\rho) \in \mathbb{R}^\rho$, $v \in \mathbb{N}_0$, $k, l \in \mathbb{N}$ mit $v + k(l+1) \leq \rho$ Funktion $A_{k,l}^{\theta,v}: \mathbb{R}^l \rightarrow \mathbb{R}^k$ mit $\forall x = (x_1, \dots, x_l) \in \mathbb{R}^l$:

$$A_{k,l}^{\theta,v}(x) = \begin{pmatrix} \theta_{v+1} & \theta_{v+2} & \dots & \theta_{v+l} \\ \theta_{v+l+1} & \theta_{v+l+2} & \dots & \theta_{v+2l} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{v+(k-1)l+1} & \theta_{v+(k-1)l+2} & \dots & \theta_{v+kl} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_l \end{pmatrix} + \begin{pmatrix} \theta_{v+kl+1} \\ \theta_{v+kl+2} \\ \vdots \\ \theta_{v+kl+k} \end{pmatrix},$$

- $\forall \theta \in \mathbb{R}^\rho$ Funktion $\mathcal{U}_\theta: \mathbb{R}^d \rightarrow \mathbb{R}$ mit

$$\mathcal{U}_\theta = A_{1,d}^{\theta, sd(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, (s-1)d(d+1)} \circ \dots \circ \mathcal{R} \circ A_{d,d}^{\theta, d(d+1)} \circ \mathcal{R} \circ A_{d,d}^{\theta, 0}.$$

Für $x \in \mathbb{R}^d$ und geeignete $\theta \in \mathbb{R}^\rho$ betrachten wir die Näherung


$$\mathcal{U}_\theta(x) \approx u(\theta, x) \in \mathbb{R}.$$

Sowohl numerische Simulationen als auch erste theoretischen Ergebnisse legen die Vermutung nahe, dass **künstliche neuronale Netze** in vielen Fällen den **Fluch der Dimensionalität** überwinden.


100-dimensionale Allen-Cahn Gleichung

$$\frac{\partial u}{\partial t}(t, x) = (\Delta_x u)(t, x) + u(t, x) - [u(t, x)]^3$$

mit $u(0, x) = \frac{1}{(2+0.4\|x\|^2)}$ für $t \in [0, \frac{3}{10}]$, $x \in \mathbb{R}^{100}$.



(a) Relativer Fehler für $u(\frac{3}{10}, 0) \approx 0.0528$



(b) Näherungsw. Darst. von $u(t, 0), 0 \leq t \leq \frac{3}{10}$

Fehler: 0.3%, Laufzeit: 647 Sekunden. PYTHON, TENSORFLOW, MACBOOK PRO 2.9 GHz (INTEL i5, 16 GB RAM)

Details finden sich in

- C. Beck, W. E., & A. Jentzen. Machine learning approximation algorithms for high-dimensional fully nonlinear partial differential equations and second-order backward stochastic differential equations. *arXiv* (2017).
- R. E. Bellman. Dynamic programming. *Princeton University Press* (1957).
- W. E, J. Han, & A. Jentzen. Deep learning-based numerical methods for high-dimensional parabolic partial differential equations and backward stochastic differential equations. *Comm. Math. Stat.* (2017).
- J. Han, A. Jentzen, & W. E. Overcoming the curse of dimensionality: Solving high-dimensional partial differential equations using deep learning. *arXiv* (2017).
- D. J. Higham. An introduction to financial option valuation. *Cambridge University Press* (2004).
- J. Kallsen. Option pricing. In T. Andersen, R. Davis, J. Kreiß, and T. Mikosch, Handbook of Financial Time Series, *Springer* (2009).

und in den dort genannten Referenzen.

Vielen Dank für Ihre Aufmerksamkeit!

Details finden sich in

- C. Beck, W. E., & A. Jentzen. Machine learning approximation algorithms for high-dimensional fully nonlinear partial differential equations and second-order backward stochastic differential equations. *arXiv* (2017).
- R. E. Bellman. Dynamic programming. *Princeton University Press* (1957).
- W. E, J. Han, & A. Jentzen. Deep learning-based numerical methods for high-dimensional parabolic partial differential equations and backward stochastic differential equations. *Comm. Math. Stat.* (2017).
- J. Han, A. Jentzen, & W. E. Overcoming the curse of dimensionality: Solving high-dimensional partial differential equations using deep learning. *arXiv* (2017).
- D. J. Higham. An introduction to financial option valuation. *Cambridge University Press* (2004).
- J. Kallsen. Option pricing. In T. Andersen, R. Davis, J. Kreiß, and T. Mikosch, Handbook of Financial Time Series, *Springer* (2009).

und in den dort genannten Referenzen.

Vielen Dank für Ihre Aufmerksamkeit!