

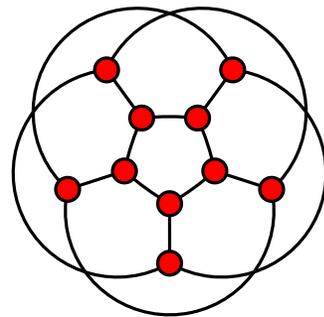
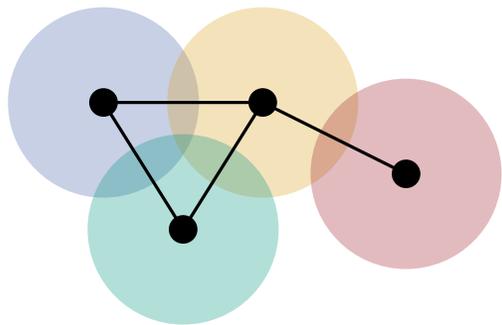
Capturing the Computational Complexity of Geometric Problems by the First-Order Theory of the Reals



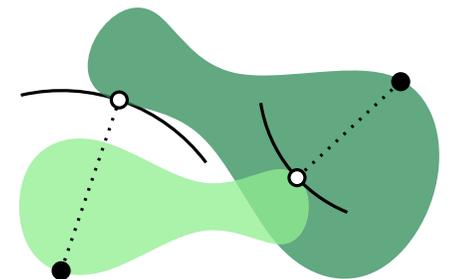
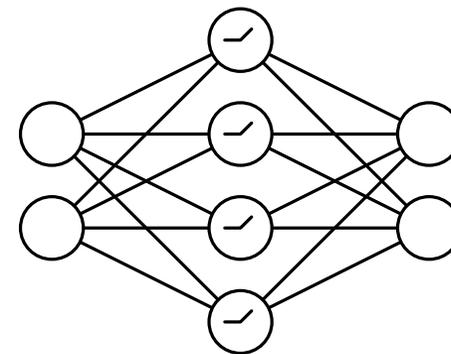
Paul Jungeblut

Betreut durch: PD Dr. Torsten Ueckerdt

Mündliche Promotionsprüfung · 26. April 2024



$\exists \mathbb{R}$



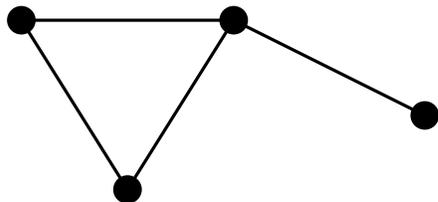
Problem 1: Erkennung von Unit-Disk-Graphen

Problem: Unit-Disk-Graphen erkennen

Eingabe: Graph G

Finde: Schnittrepräsentation von G
bestehend aus Einheitskreisen.

Beispiel: Graph G



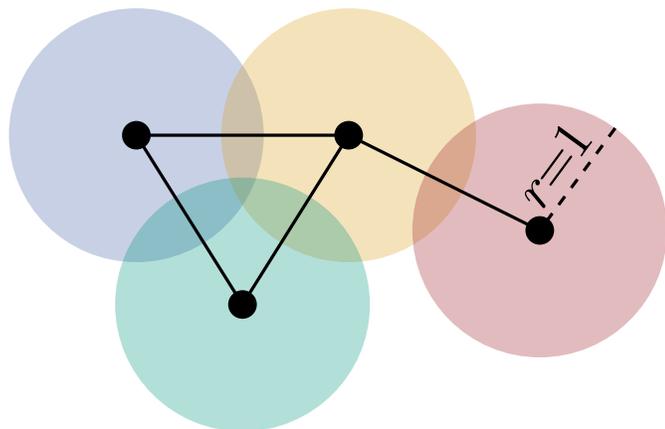
Problem 1: Erkennung von Unit-Disk-Graphen

Problem: Unit-Disk-Graphen erkennen

Eingabe: Graph G

Finde: Schnittrepräsentation von G
bestehend aus Einheitskreisen.

Beispiel: Graph G



Problem 1: Erkennung von Unit-Disk-Graphen

Problem: Unit-Disk-Graphen erkennen

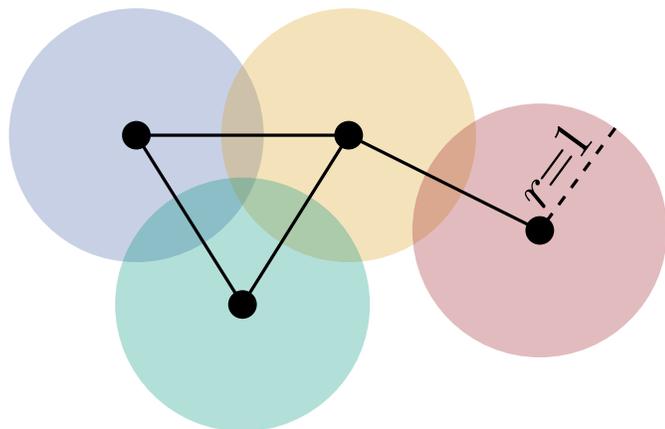
Eingabe: Graph G

Finde: Schnittrepräsentation von G
bestehend aus Einheitskreisen.

Lösungen:

- Punkt aus \mathbb{R}^2 für jeden Knoten
- Kante \iff Abstand ≤ 2

Beispiel: Graph G



Problem 1: Erkennung von Unit-Disk-Graphen

Problem: Unit-Disk-Graphen erkennen

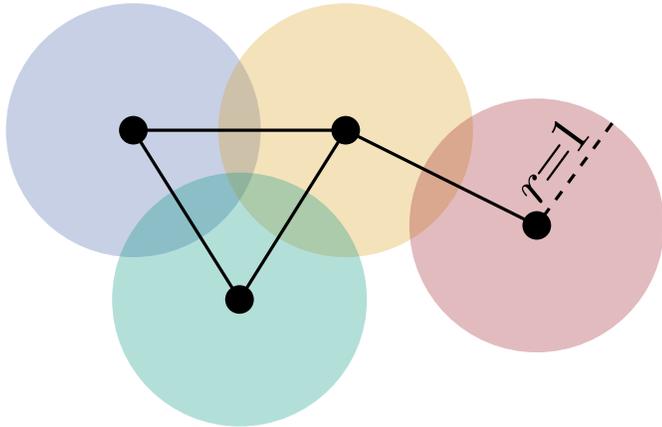
Eingabe: Graph G

Finde: Schnittrepräsentation von G
bestehend aus Einheitskreisen.

Lösungen:

- Punkt aus \mathbb{R}^2 für jeden Knoten
- Kante \iff Abstand ≤ 2

Beispiel: Graph G



Komplexität:

- NP-schwer [Breu, Kirkpatrick 1998]
- Überhaupt berechenbar?
 \rightsquigarrow ja: polynomielles Ungleichungssystem

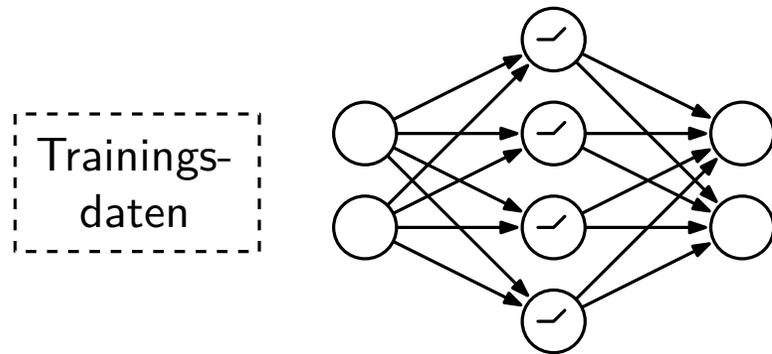
Problem 2: Training neuronaler Netze

Problem: TRAINNN

Eingabe: Netzwerk + Trainingsdaten

Finde: Parameter, sodass Trainingsdaten möglichst gut abgebildet werden.

Beispiel:



Problem 2: Training neuronaler Netze

Problem: TRAINNN

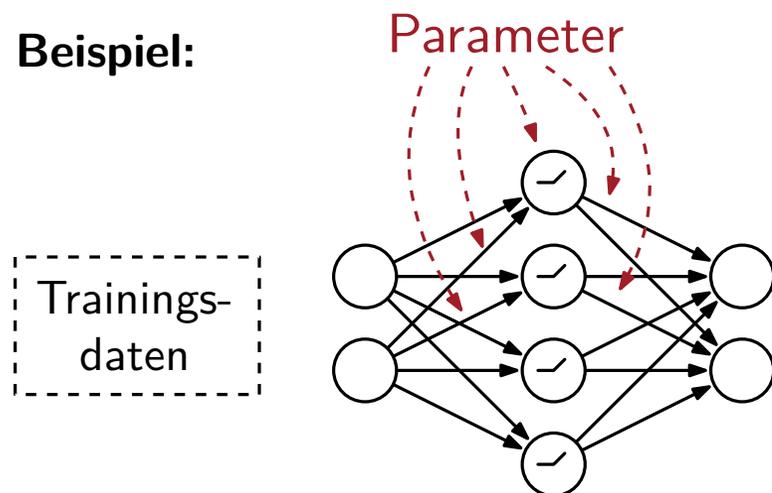
Eingabe: Netzwerk + Trainingsdaten

Finde: Parameter, sodass Trainingsdaten möglichst gut abgebildet werden.

Lösungen:

- Parameter aus \mathbb{R} (Gewichte + Bias)
- Trainingsdaten „gelernt“

Beispiel:



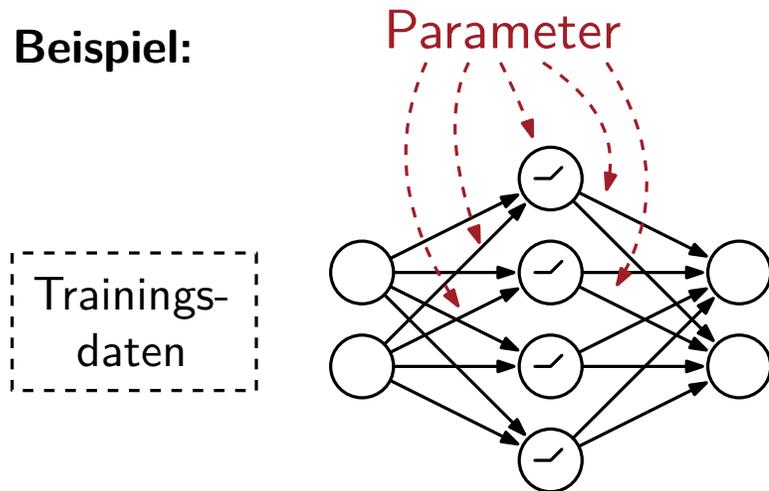
Problem 2: Training neuronaler Netze

Problem: TRAINNN

Eingabe: Netzwerk + Trainingsdaten

Finde: Parameter, sodass Trainingsdaten möglichst gut abgebildet werden.

Beispiel:



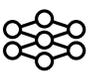
Lösungen:

- Parameter aus \mathbb{R} (Gewichte + Bias)
- Trainingsdaten „gelernt“

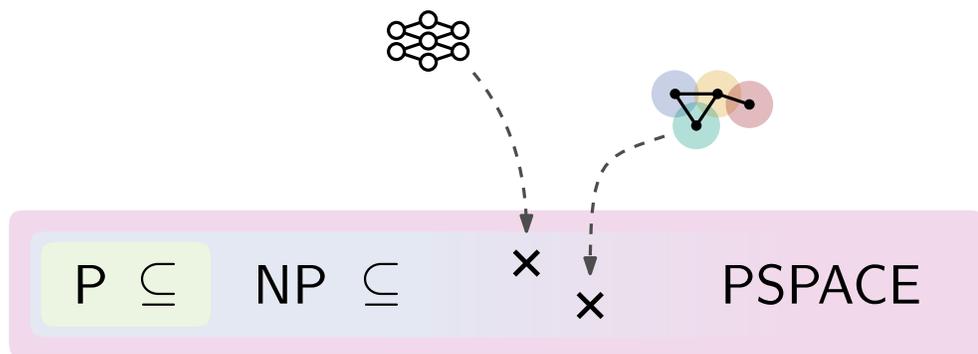
Komplexität:

- NP-schwer [Blum, Rivest 1992]
- Überhaupt berechenbar?
 \rightsquigarrow ja: polynomielles Ungleichungssystem

Komplexitätsklasse $\exists\mathbb{R}$

Wie schwierig sind  und  wirklich?

- beide sind NP-schwer
 - beide sind in PSPACE
- gleiche Wissenslücke bei vielen (geometrischen) Problemen



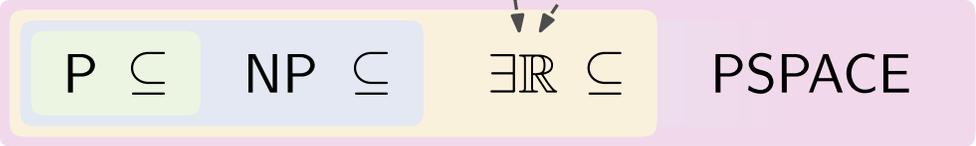
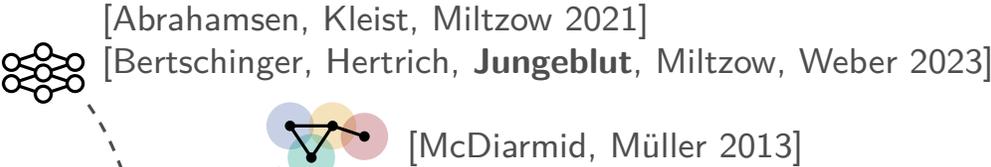
Komplexitätsklasse $\exists\mathbb{R}$

Wie schwierig sind  und  wirklich?

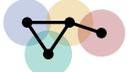
- beide sind NP-schwer
 - beide sind in PSPACE
- gleiche Wissenslücke bei vielen (geometrischen) Problemen

Beide sind $\exists\mathbb{R}$ -vollständig.

→ „gleich schwierig“



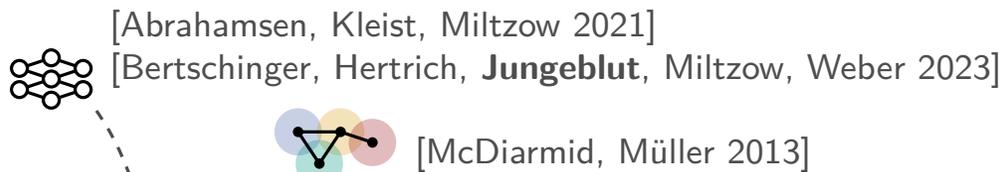
Komplexitätsklasse $\exists\mathbb{R}$

Wie schwierig sind  und  wirklich?

- beide sind NP-schwer
 - beide sind in PSPACE
- gleiche Wissenslücke bei vielen (geometrischen) Problemen

Beide sind $\exists\mathbb{R}$ -vollständig.

↪ „gleich schwierig“



In meiner Arbeit:

- **exakte Komplexität** bekannter offener Probleme bestimmt
 - zugrundeliegende Geometrie ausgenutzt
 - Wissen über $\exists\mathbb{R}$ bot richtige Perspektive
- neue **Beweistechniken** entwickelt und bekannte verfeinert
 - bereits in nachfolgender Literatur aufgegriffen worden
- natürliche **Erweiterungen von $\exists\mathbb{R}$**

Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: ETR (**E**xistential **T**heory of the **R**eals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (**E**xistential **T**heory of the **R**eals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

$$\exists x \in \mathbb{R}: x^2 < 0$$

Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (Existential Theory of the Reals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

$$\exists x \in \mathbb{R}: x^2 < 0 \quad \mathbf{X}$$

Quadrate sind immer nichtnegativ

Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (**E**xistential **T**heory of the **R**eals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

$$\exists x \in \mathbb{R}: x^2 < 0 \quad \times$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1$$

Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: ETR (Existential Theory of the Reals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

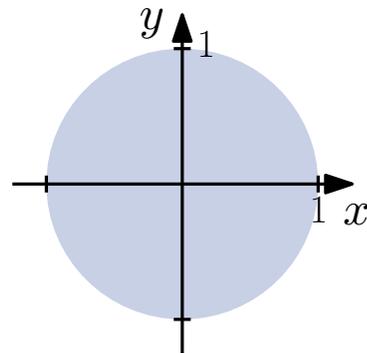
$$\exists x \in \mathbb{R}: x^2 < 0 \quad \text{X}$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1$$



4 Capturing the Computational Complexity of Geometric Problems by the First-Order Theory of the Reals

Paul Jungeblut

Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: ETR (Existential Theory of the Reals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

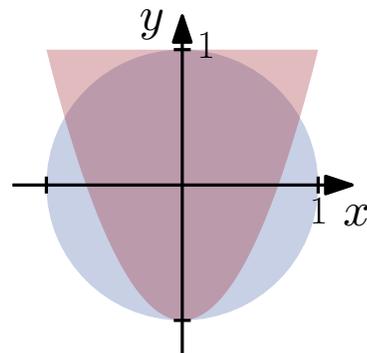
$$\exists x \in \mathbb{R}: x^2 < 0 \quad \text{X}$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1$$



Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (**E**xistential **T**heory of the **R**eals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

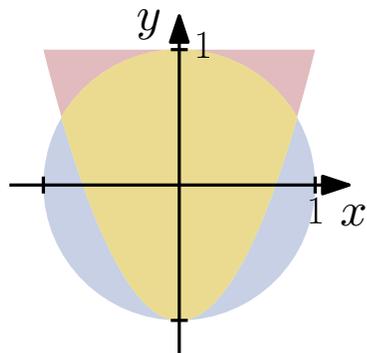
$$\exists x \in \mathbb{R}: x^2 < 0 \quad \times$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1 \quad \checkmark$$



Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (Existential Theory of the Reals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Wie schwierig ist ETR?

- überabzählbar viele Lösungskandidaten
- entscheidbar [Tarski 1951]

Beispiel 1:

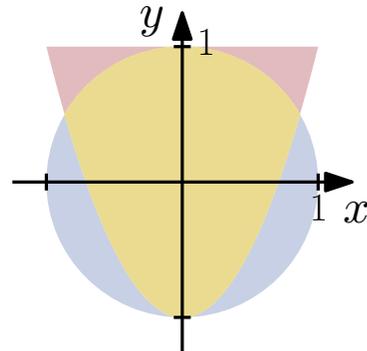
$$\exists x \in \mathbb{R}: x^2 < 0 \quad \times$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1 \quad \checkmark$$



Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (Existential Theory of the Reals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Wie schwierig ist ETR?

- überabzählbar viele Lösungskandidaten
- entscheidbar [Tarski 1951]
- ETR ist NP-schwer [Shor 1991]
- ETR ist in PSPACE [Canny 1988]

Beispiel 1:

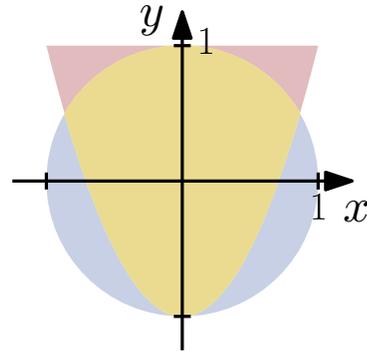
$$\exists x \in \mathbb{R}: x^2 < 0 \quad \text{X}$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1 \quad \checkmark$$



Existenzielle Theorie der reellen Zahlen & $\exists\mathbb{R}$

Definition: **ETR** (Existential Theory of the Reals)

Eingabe: Formel $\exists x, y, \dots \in \mathbb{R}: \varphi(x, y, \dots)$

Polynom(un)gleichungen \nearrow

Frage: Ist die Formel wahr oder falsch?

Beispiel 1:

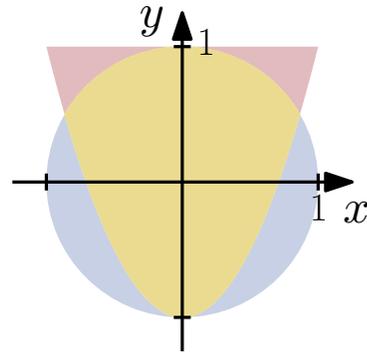
$$\exists x \in \mathbb{R}: x^2 < 0 \quad \text{X}$$

Quadrate sind immer nichtnegativ

Beispiel 2:

$$\exists x, y \in \mathbb{R}: x^2 + y^2 \leq 1$$

$$\wedge y \geq 2x^2 - 1 \quad \checkmark$$

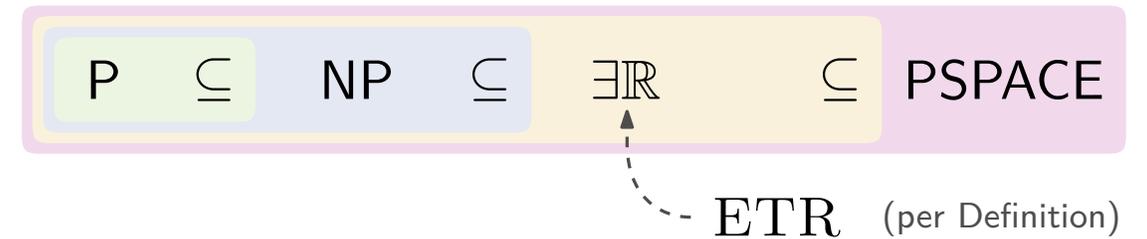


Wie schwierig ist ETR?

- überabzählbar viele Lösungskandidaten
- entscheidbar [Tarski 1951]
- ETR ist NP-schwer [Shor 1991]
- ETR ist in PSPACE [Canny 1988]

Definition: [Schaefer 2009]

$\exists\mathbb{R}$ enthält alle Probleme, die in polynomieller Zeit auf ETR reduziert werden können.



Bedeutung von $\exists\mathbb{R}$ -Vollständigkeit

Wahre Schwierigkeit

- Schwierigkeit nur relativ zu ETR
- nicht: „irgendwo“ zwischen NP und PSPACE
sondern: „gleich schwierig“ wie ETR

Bedeutung von $\exists\mathbb{R}$ -Vollständigkeit

Wahre Schwierigkeit

- Schwierigkeit nur relativ zu ETR
- nicht: „irgendwo“ zwischen NP und PSPACE
sondern: „gleich schwierig“ wie ETR

Perspektivwechsel

- im Kern: reelle algebraische Geometrie
 \rightsquigarrow alle bekannten Algorithmen algebraisch
- algorithmische Fortschritte am ehesten durch
mathematische Durchbrüche zu erwarten

Bedeutung von $\exists\mathbb{R}$ -Vollständigkeit

Wahre Schwierigkeit

- Schwierigkeit nur relativ zu ETR
- nicht: „irgendwo“ zwischen NP und PSPACE
sondern: „gleich schwierig“ wie ETR

Hohe Genauigkeit

- Lösungen doppelt exponentiell groß
 \rightsquigarrow exponentiell viele Bits
- algebraische/topologische Universalität

Perspektivwechsel

- im Kern: reelle algebraische Geometrie
 \rightsquigarrow alle bekannten Algorithmen algebraisch
- algorithmische Fortschritte am ehesten durch
mathematische Durchbrüche zu erwarten

Bedeutung von $\exists\mathbb{R}$ -Vollständigkeit

Wahre Schwierigkeit

- Schwierigkeit nur relativ zu ETR
- nicht: „irgendwo“ zwischen NP und PSPACE
sondern: „gleich schwierig“ wie ETR

Perspektivwechsel

- im Kern: reelle algebraische Geometrie
 \rightsquigarrow alle bekannten Algorithmen algebraisch
- algorithmische Fortschritte am ehesten durch
mathematische Durchbrüche zu erwarten

Hohe Genauigkeit

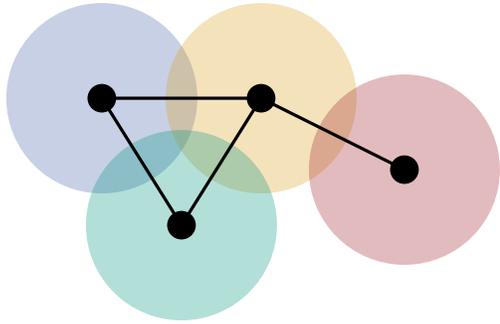
- Lösungen doppelt exponentiell groß
 \rightsquigarrow exponentiell viele Bits
- algebraische/topologische Universalität

Lösbarkeit in der Praxis

- NP-vollständig \rightsquigarrow SAT-Solver
- keine solchen Universallöser für ETR
aber: gute Heuristiken für spezielle Probleme

Beitrag und Ergebnisse

Hyperbolische Geometrie

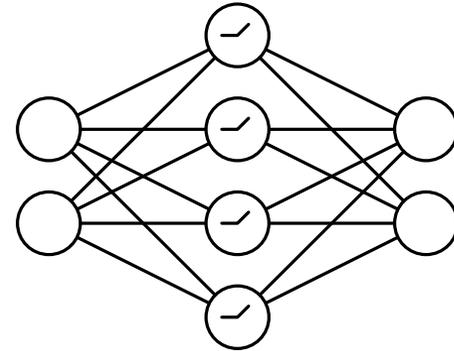


$\exists \mathbb{R}$ -Schwere in der hyperbolischen Ebene

[EuroCG 2023]

[Bieker, Bläsius, Dohse, **Jungeblut**]

Training neuronaler Netze

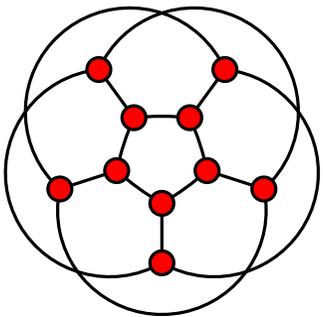


$\exists \mathbb{R}$ -vollständig unter realistischen Annahmen

[NeurIPS 2023]

[Bertschinger, Hertrich, **Jungeblut**, Miltzow, Weber]

Lombardi-Zeichnungen

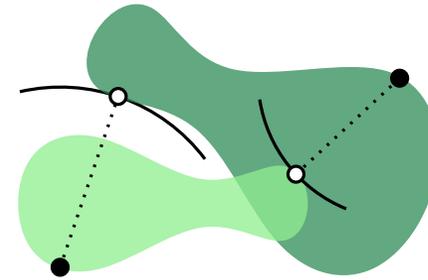


Graphvisualisierung unter geometrischen Nebenbedingungen

[GD 2023]

[**Jungeblut**]

Hausdorff-Distanz



Distanzmaß für Mengen
 $\rightsquigarrow \forall \exists \mathbb{R}$ -vollständig

[SoCG 2022]

[Discrete Comput. Geom. 2024]

[**Jungeblut**, Kleist, Miltzow]

Beitrag und Ergebnisse

Hyperbolische Geometrie

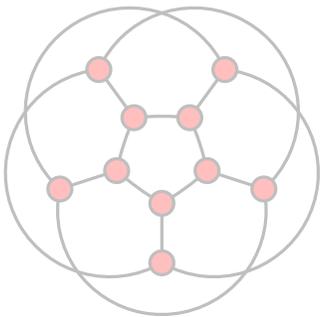


$\exists\mathbb{R}$ -Schwere in der hyperbolischen Ebene

[EuroCG 2023]

[Bieker, Bläsius, Dohse, Jungeblut]

Lombardi-Zeichnungen



Graphvisualisierung unter geometrischen Nebenbedingungen

[GD 2023]

[Jungeblut]

STRETCHABILITY-Problem:

- $\exists\mathbb{R}$ -vollständig in \mathbb{R}^2 [Mnev 1988]
- Startpunkt für viele $\exists\mathbb{R}$ -Schwerebeweise

Theorem:

STRETCHABILITY ist $\exists\mathbb{R}$ -vollständig in der hyperbolischen Ebene \mathbb{H}^2 .

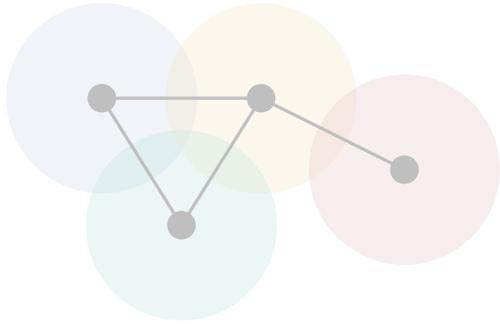
Framework:

$\exists\mathbb{R}$ -Vollständigkeit von der euklidischen in die hyperbolische Ebene übertragen.

\rightsquigarrow  $\exists\mathbb{R}$ -vollständig in \mathbb{H}^2

Beitrag und Ergebnisse

Hyperbolische Geometrie

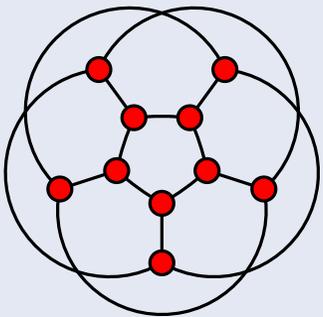


$\exists \mathbb{R}$ -Schwere in der hyperbolischen Ebene

[EuroCG 2023]

[Bieker, Bläsius, Dohse, Jungeblut]

Lombardi-Zeichnungen



Graphvisualisierung unter geometrischen Nebenbedingungen

[GD 2023]

[Jungeblut]

Knoten: Punkte aus \mathbb{R}^2

Kanten: Kreisbögen

gleiche Winkel um jeden Knoten

\rightsquigarrow Symmetrien des Graphen gut erkennbar

Theorem:

Lombardi-Zeichnen ist $\exists \mathbb{R}$ -vollständig.

- erstes Komplexitätsresultat
- eleganter Umweg über hyperbolisches STRETCHABILITY

Beitrag und Ergebnisse

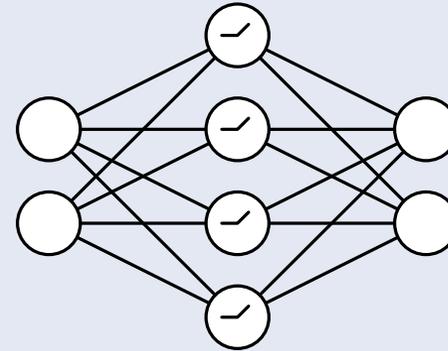
Theorem:

TRAINNN ist $\exists\mathbb{R}$ -vollständig.
Selbst unter **realistischen Annahmen**.

Algebraische Universalität:

Lösungen können beliebig komplizierte
irrationale Zahlen enthalten.

Training neuronaler Netze

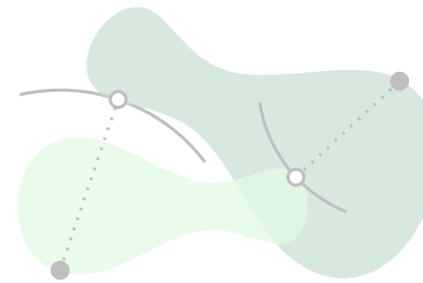


$\exists\mathbb{R}$ -vollständig unter
realistischen Annahmen

[NeurIPS 2023]

[Bertschinger, Hertrich, **Jungeblut**, Miltzow, Weber]

Hausdorff-Distanz



Distanzmaß für Mengen

$\rightsquigarrow \forall\exists\mathbb{R}$ -vollständig

[SoCG 2022]

[Discrete Comput. Geom. 2024]

[**Jungeblut**, Kleist, Miltzow]

Beitrag und Ergebnisse

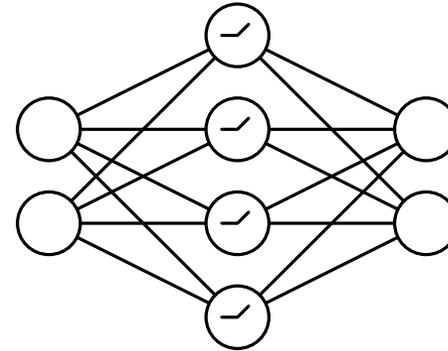
Wie „ähnlich“ sind sich zwei Mengen?

Theorem:

Die Hausdorff-Distanz zu berechnen ist $\forall\exists\mathbb{R}$ -vollständig.

- $\forall\exists\mathbb{R}$: **reelle polynomielle Hierarchie**
 \rightsquigarrow noch schwieriger als $\exists\mathbb{R}$
- erster $\forall\exists\mathbb{R}$ -Vollständigkeitsbeweis für ein natürliches Problem

Training neuronaler Netze

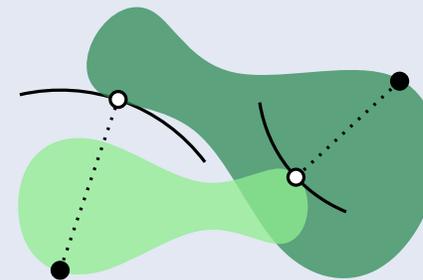


$\exists\mathbb{R}$ -vollständig unter realistischen Annahmen

[NeurIPS 2023]

[Bertschinger, Hertrich, **Jungeblut**, Miltzow, Weber]

Hausdorff-Distanz



Distanzmaß für Mengen

$\rightsquigarrow \forall\exists\mathbb{R}$ -vollständig

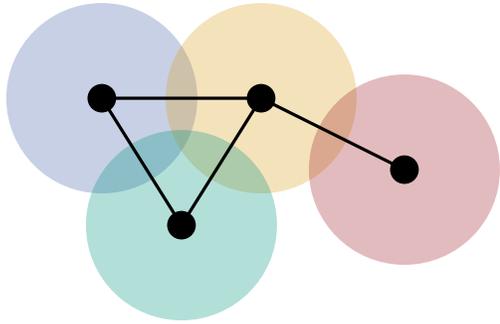
[SoCG 2022]

[Discrete Comput. Geom. 2024]

[**Jungeblut**, Kleist, Miltzow]

Beitrag und Ergebnisse

Hyperbolische Geometrie

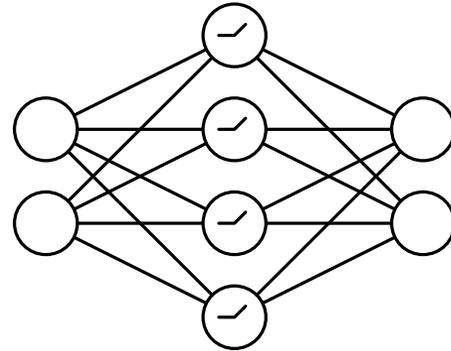


$\exists \mathbb{R}$ -Schwere in der hyperbolischen Ebene

[EuroCG 2023]

[Bieker, Bläsius, Dohse, **Jungeblut**]

Training neuronaler Netze

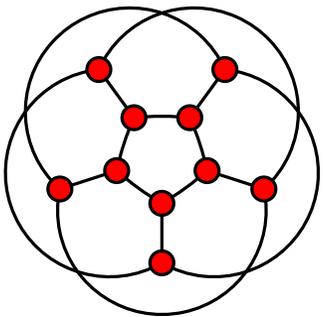


$\exists \mathbb{R}$ -vollständig unter realistischen Annahmen

[NeurIPS 2023]

[Bertschinger, Hertrich, **Jungeblut**, Miltzow, Weber]

Lombardi-Zeichnungen

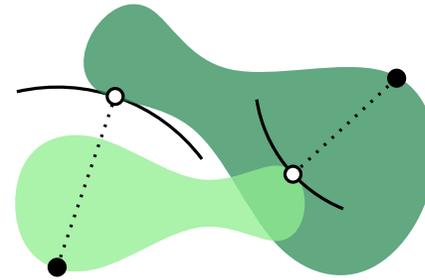


Graphvisualisierung unter geometrischen Nebenbedingungen

[GD 2023]

[**Jungeblut**]

Hausdorff-Distanz



Distanzmaß für Mengen
 $\rightsquigarrow \forall \exists \mathbb{R}$ -vollständig

[SoCG 2022]

[Discrete Comput. Geom. 2024]

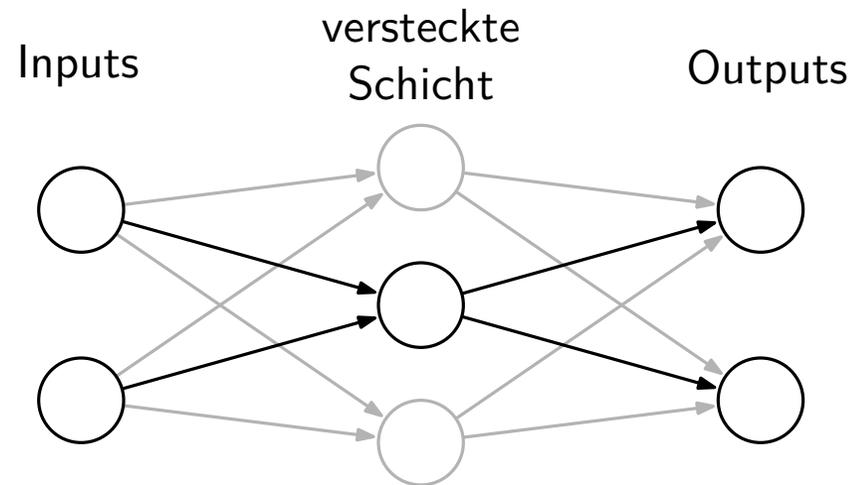
[**Jungeblut**, Kleist, Miltzow]

Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter

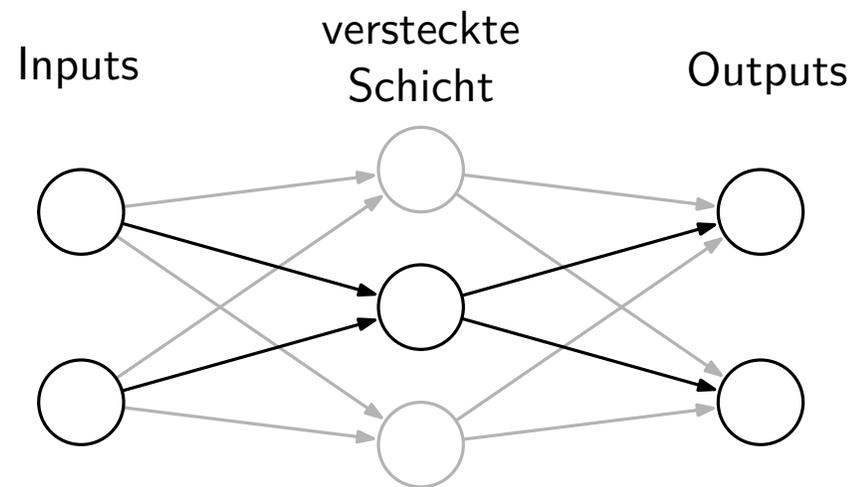


Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter



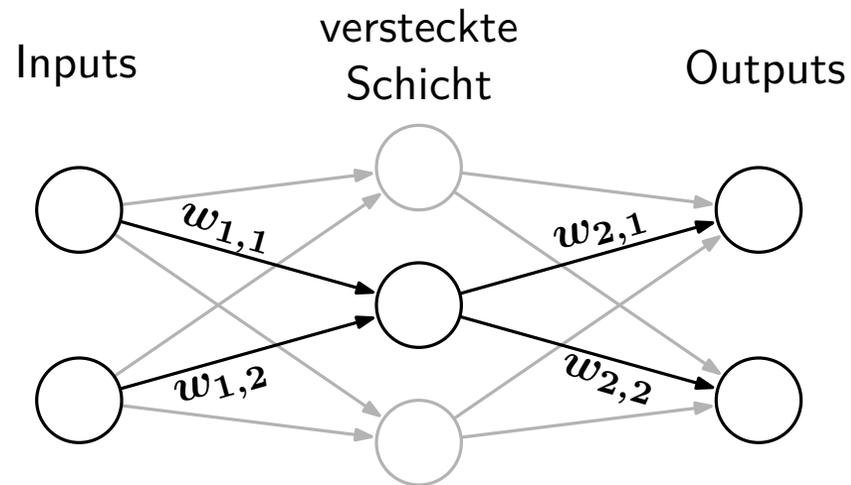
Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter



Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Parameter Θ :

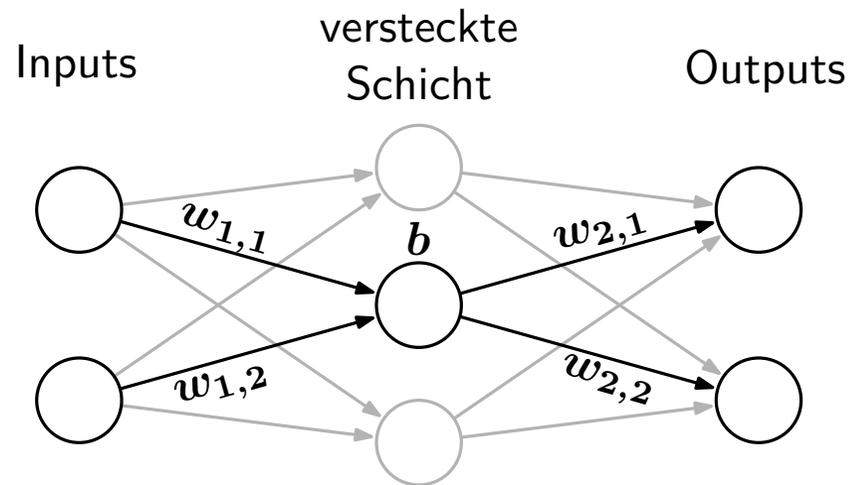
Gewichte auf den Kanten

Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter



Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

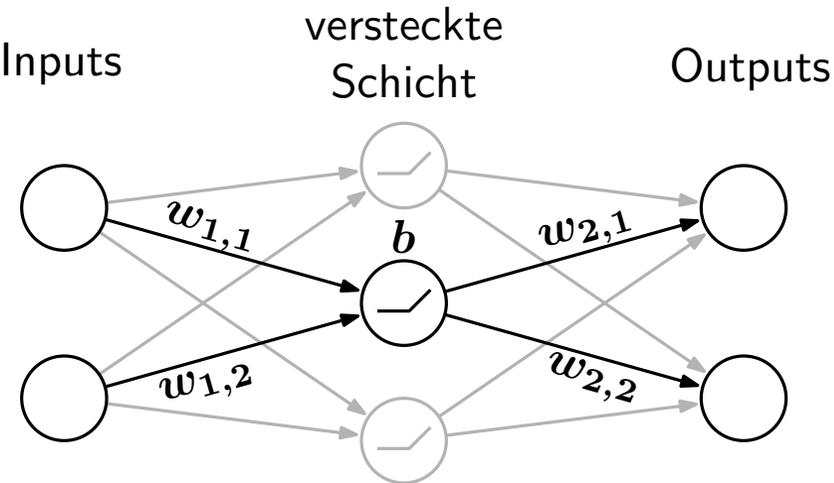
Parameter Θ :

Gewichte auf den Kanten

Bias pro verstecktem Neuron

Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**
Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$
 \uparrow Parameter



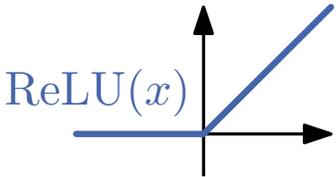
Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Parameter Θ :

Gewichte auf den Kanten
Bias pro verstecktem Neuron

Aktivierungsfunktion: ReLU = 

$$\text{ReLU} : \mathbb{R} \rightarrow \mathbb{R}$$
$$x \mapsto \max\{0, x\}$$

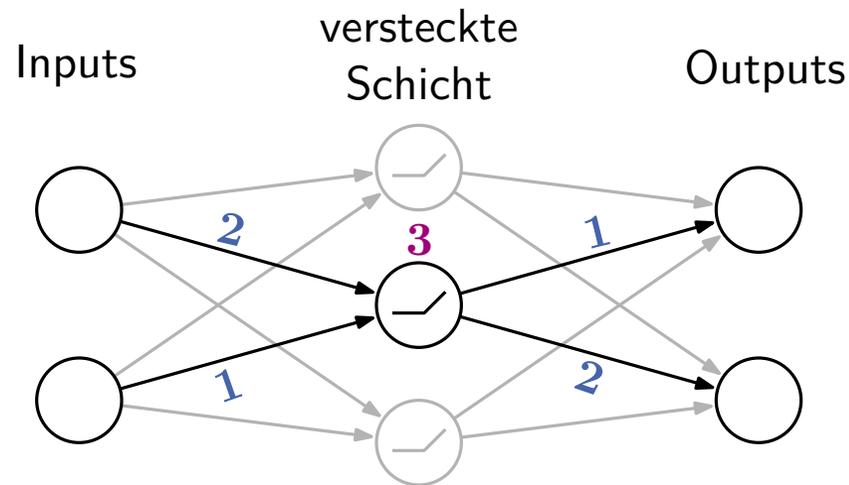


Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter



Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Parameter Θ :

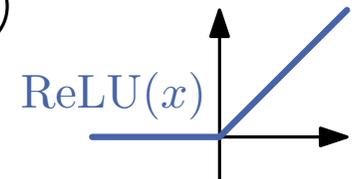
Gewichte auf den Kanten

Bias pro verstecktem Neuron

Aktivierungsfunktion: ReLU =

$$\text{ReLU} : \mathbb{R} \rightarrow \mathbb{R}$$

$$x \mapsto \max\{0, x\}$$

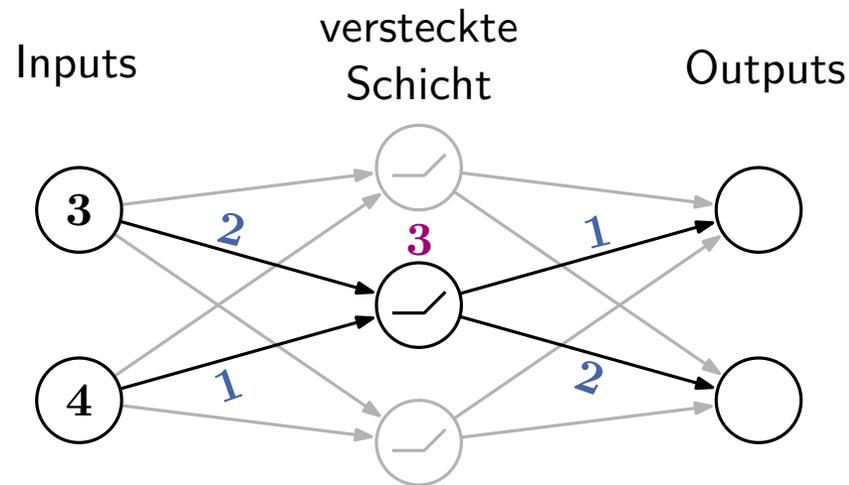


Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter



Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Parameter Θ :

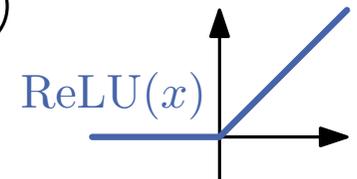
Gewichte auf den Kanten

Bias pro verstecktem Neuron

Aktivierungsfunktion: ReLU =

$\text{ReLU} : \mathbb{R} \rightarrow \mathbb{R}$

$x \mapsto \max\{0, x\}$

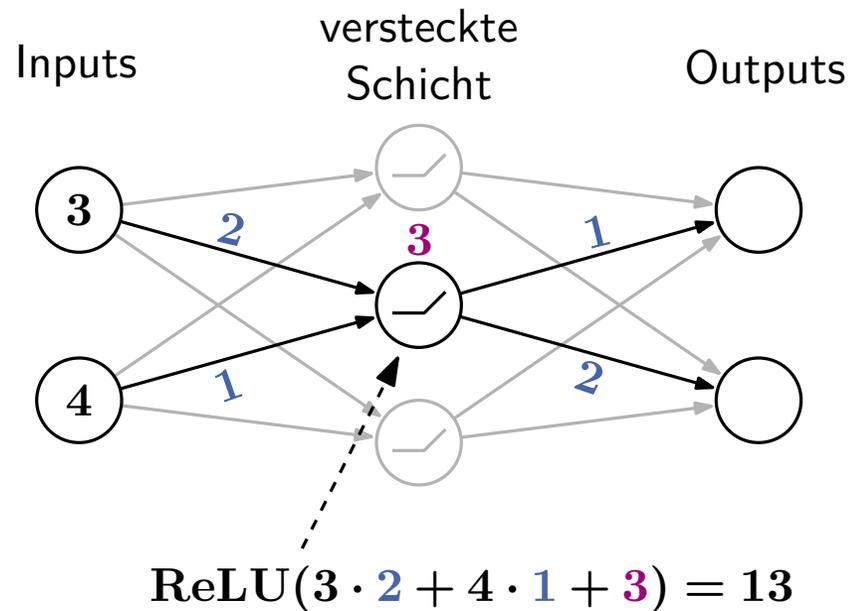


Neuronale Netze

Neuronales Netz \longleftrightarrow **Funktion**

Hier: $f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$

\uparrow Parameter



Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Parameter Θ :

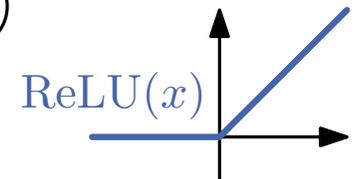
Gewichte auf den Kanten

Bias pro verstecktem Neuron

Aktivierungsfunktion: ReLU =

$\text{ReLU} : \mathbb{R} \rightarrow \mathbb{R}$

$x \mapsto \max\{0, x\}$

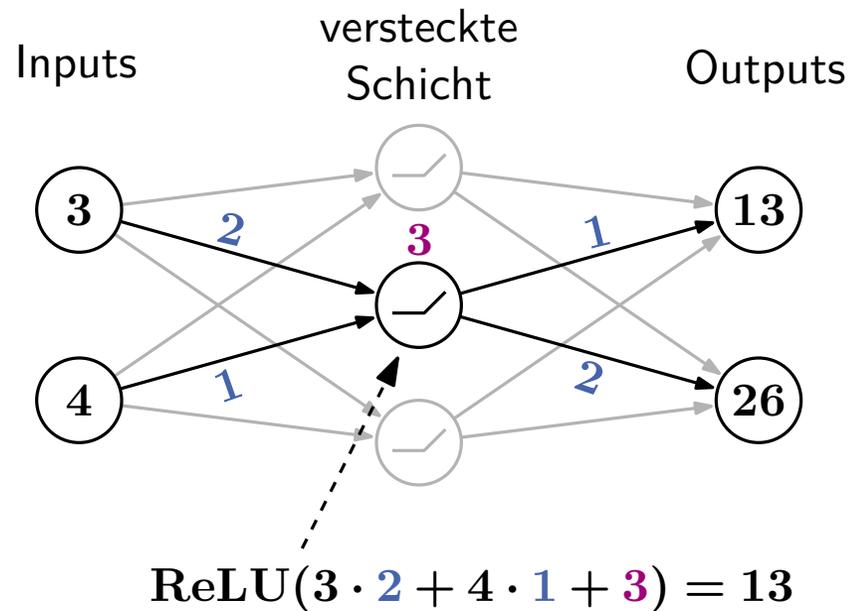


Neuronale Netze

Neuronales Netz \longleftrightarrow Funktion

Hier: $f_{\Theta}: \mathbb{R}^2 \rightarrow \mathbb{R}^2$

Parameter



Architektur: gerichteter, azyklischer Graph
(Knoten = Neuronen)

Parameter Θ :

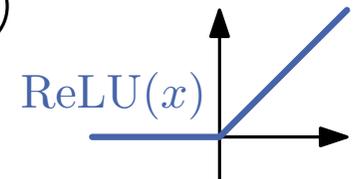
Gewichte auf den Kanten

Bias pro verstecktem Neuron

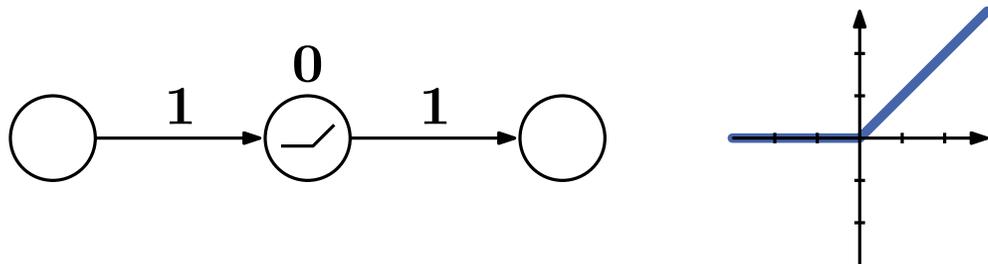
Aktivierungsfunktion: ReLU =

$$\text{ReLU}: \mathbb{R} \rightarrow \mathbb{R}$$

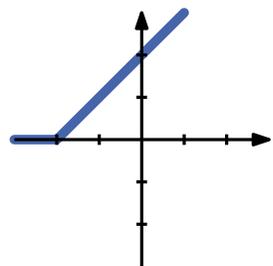
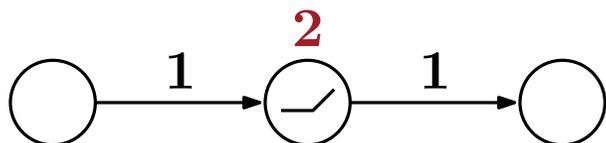
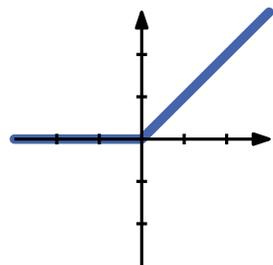
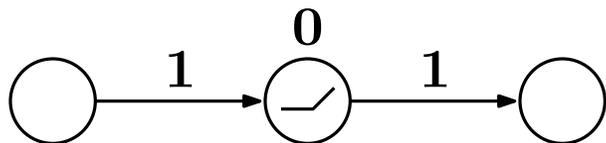
$$x \mapsto \max\{0, x\}$$



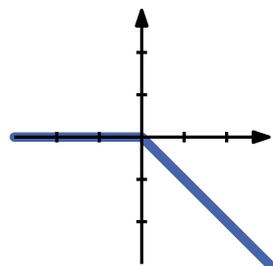
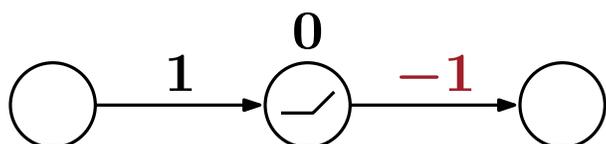
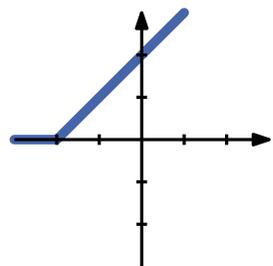
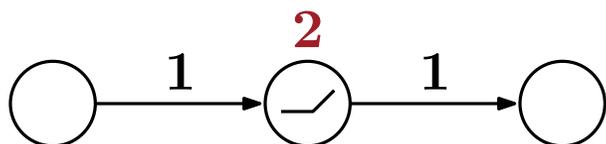
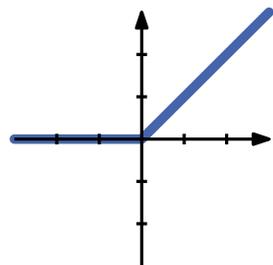
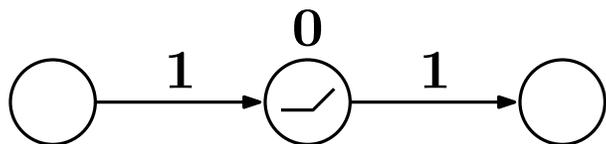
Funktionen von ReLU-Netzwerken



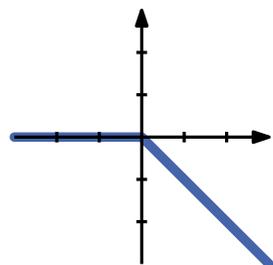
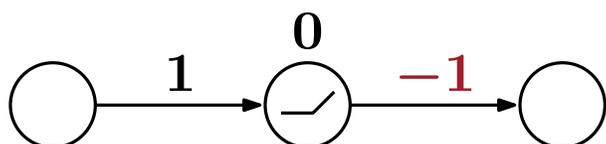
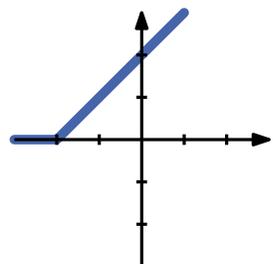
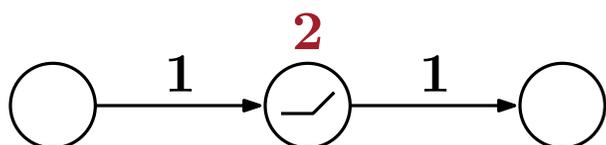
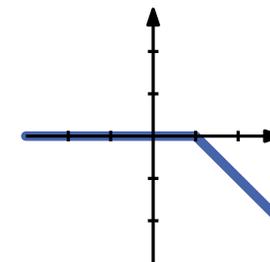
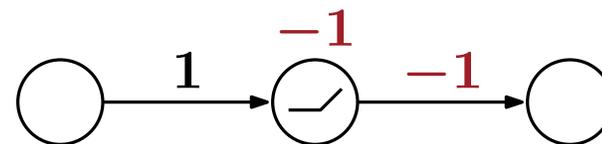
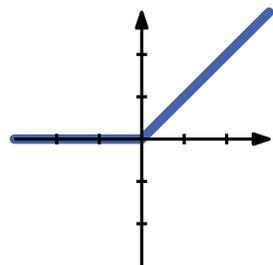
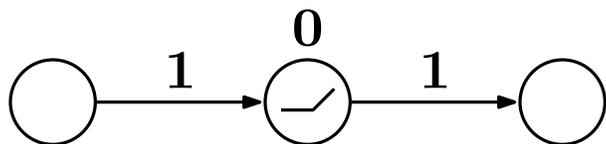
Funktionen von ReLU-Netzwerken



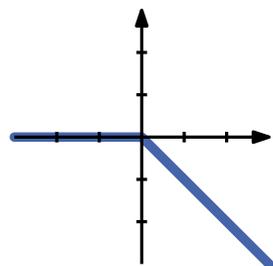
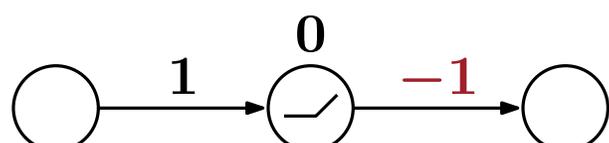
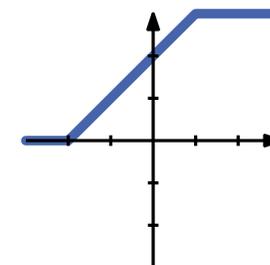
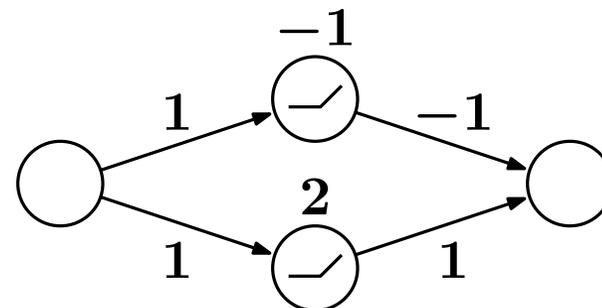
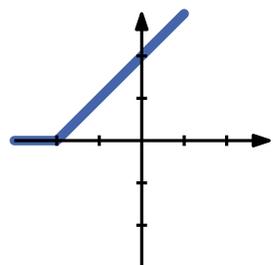
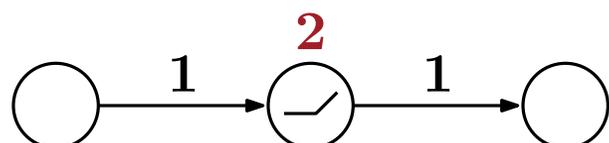
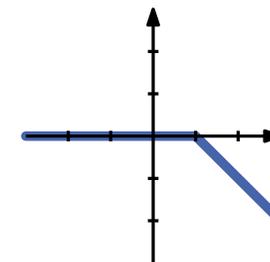
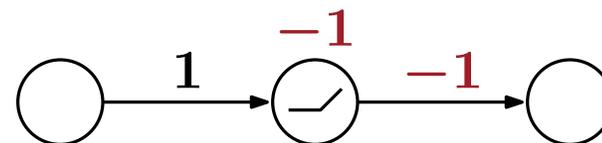
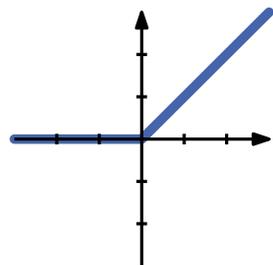
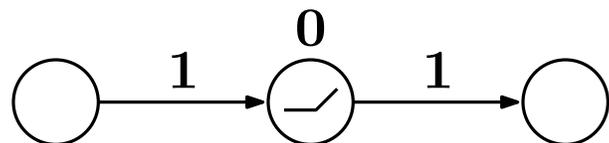
Funktionen von ReLU-Netzwerken



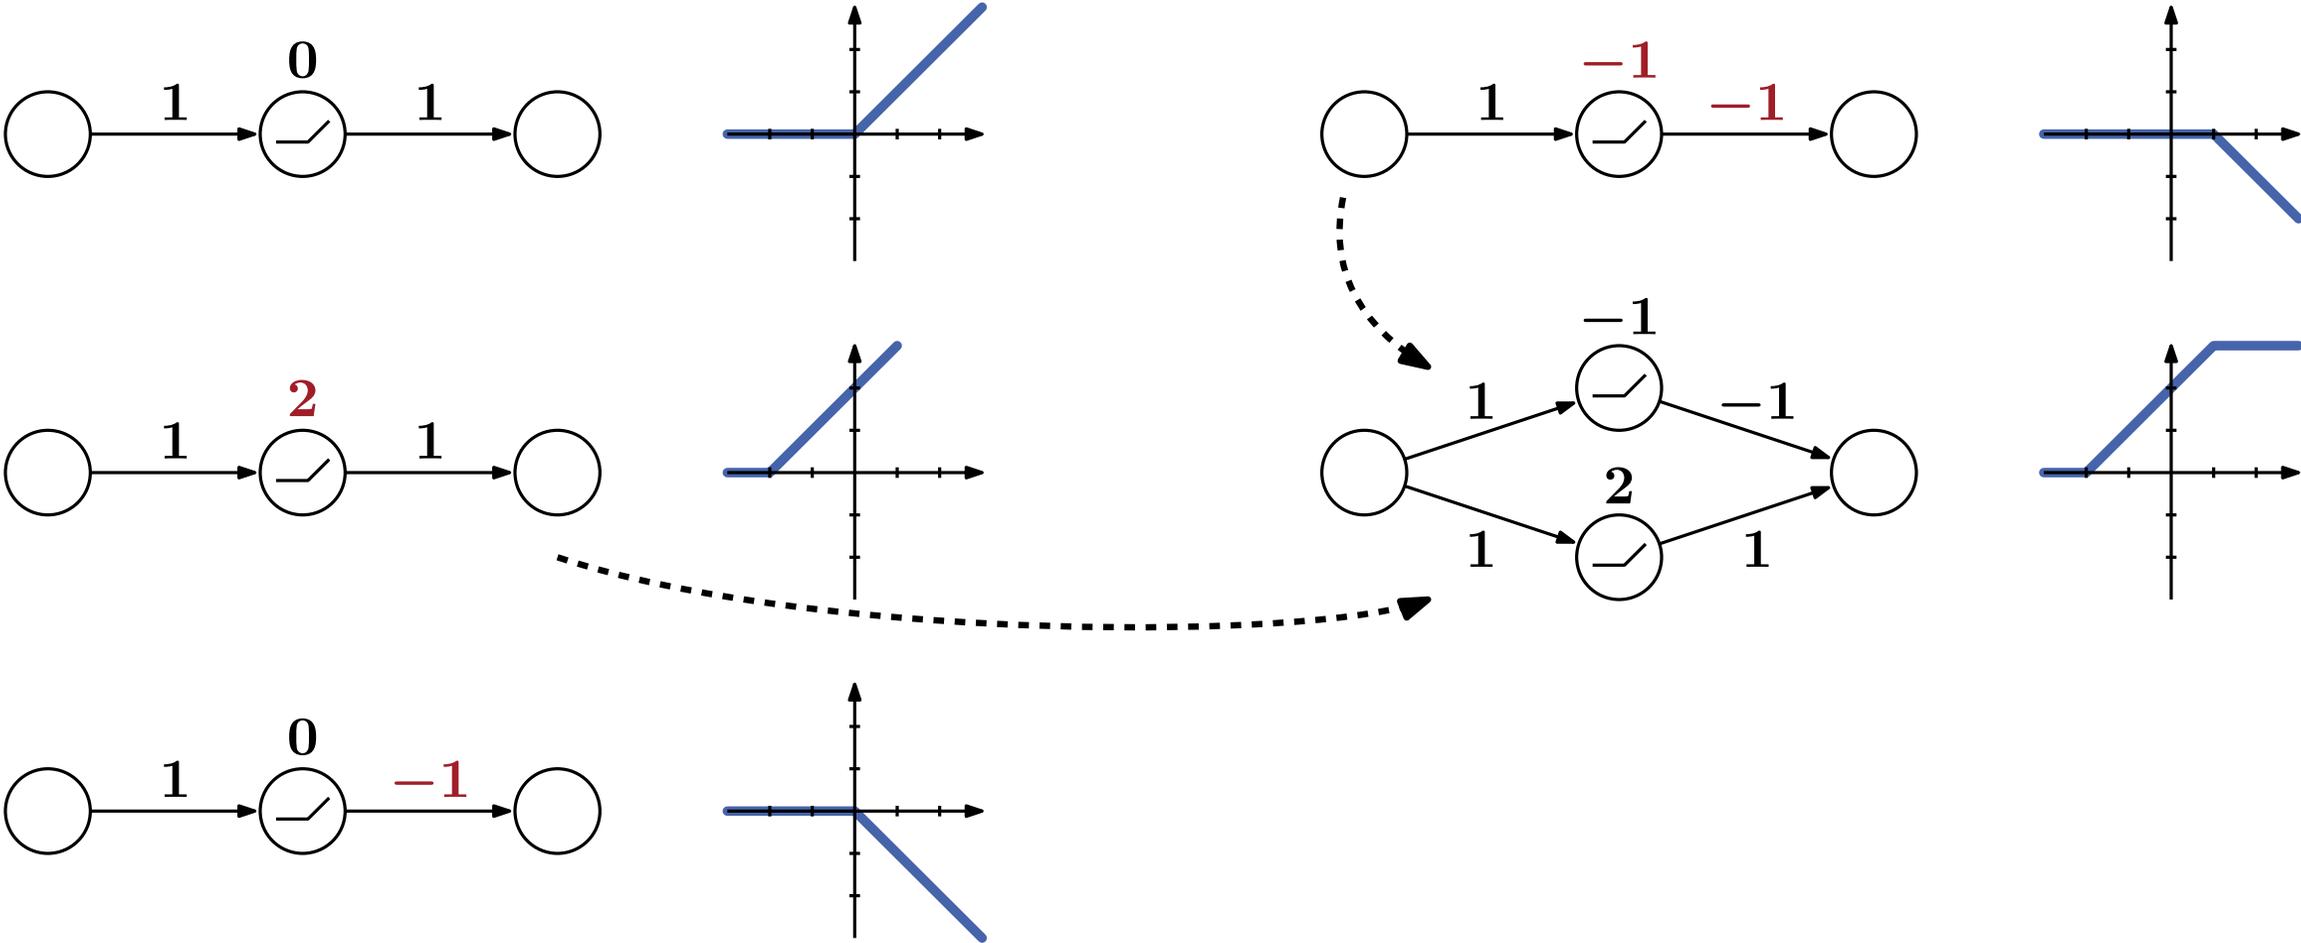
Funktionen von ReLU-Netzwerken



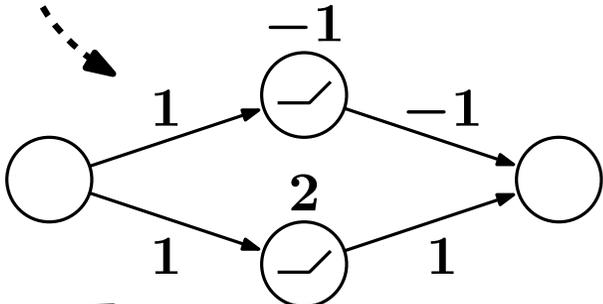
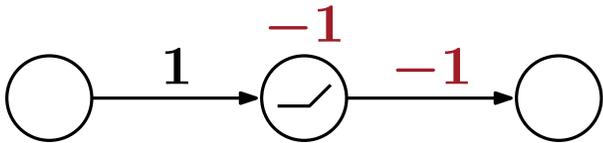
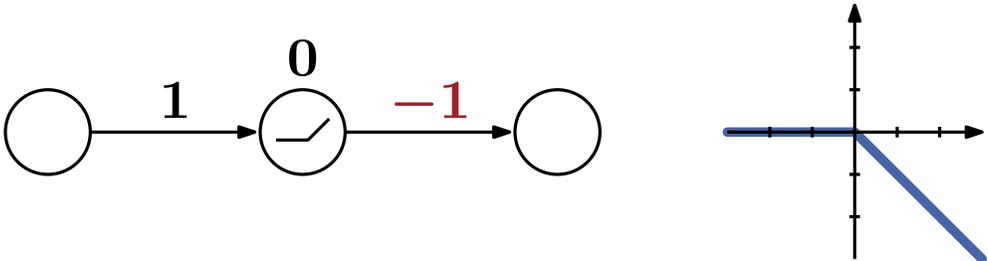
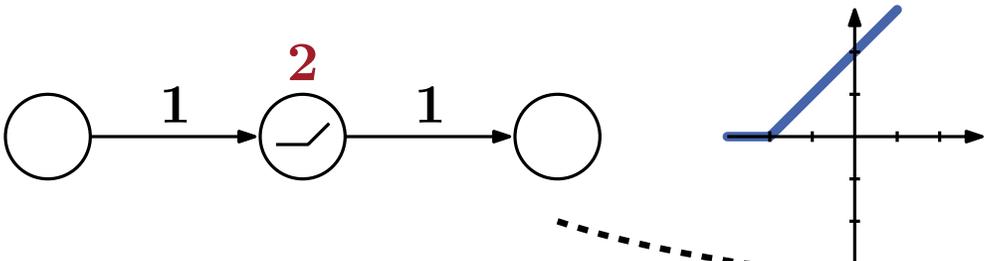
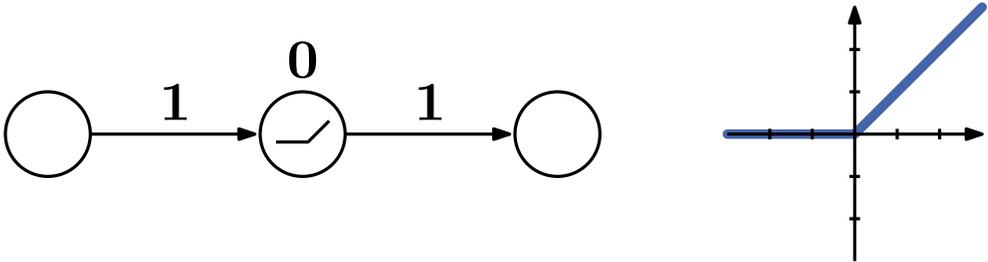
Funktionen von ReLU-Netzwerken



Funktionen von ReLU-Netzwerken



Funktionen von ReLU-Netzwerken



Beobachtungen:

- stetig und stückweise linear
- #Knickstellen = #ReLU

Das Trainingsproblem

Trainingsproblem: TRAINNN

Eingabe: Architektur (Graph) +
 n Datenpunkte: $(x_i, y_i)_{i=1, \dots, n}$
Eingabe \uparrow \uparrow Soll-Ausgabe

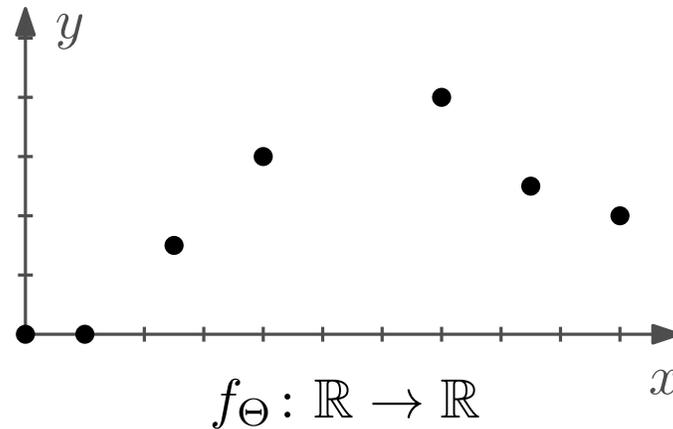
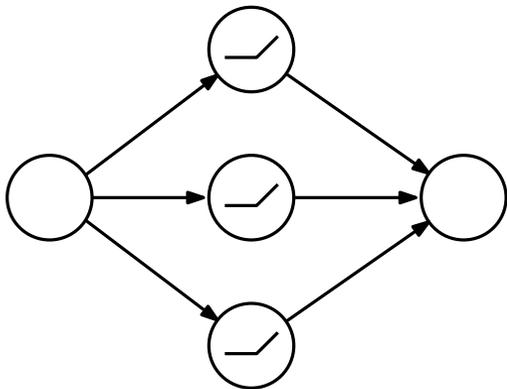
Frage: Existieren Parameter Θ , sodass für alle
Datenpunkte gilt: $f_{\Theta}(x_i) = y_i$

Das Trainingsproblem

Trainingsproblem: TRAINNN

Eingabe: Architektur (Graph) +
 n Datenpunkte: $(x_i, y_i)_{i=1, \dots, n}$
Eingabe \uparrow \uparrow Soll-Ausgabe

Frage: Existieren Parameter Θ , sodass für alle
Datenpunkte gilt: $f_{\Theta}(x_i) = y_i$

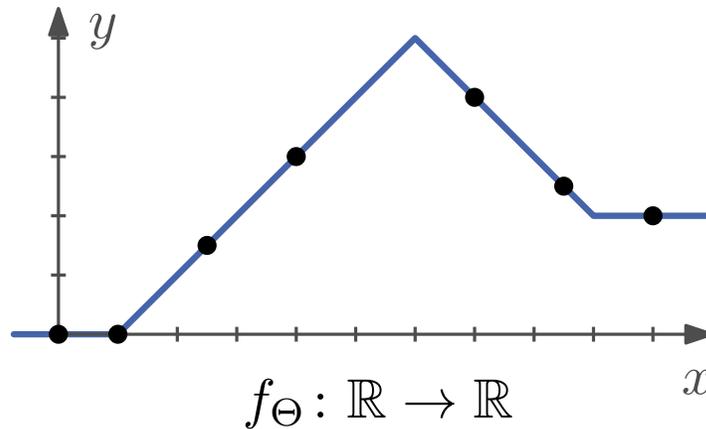
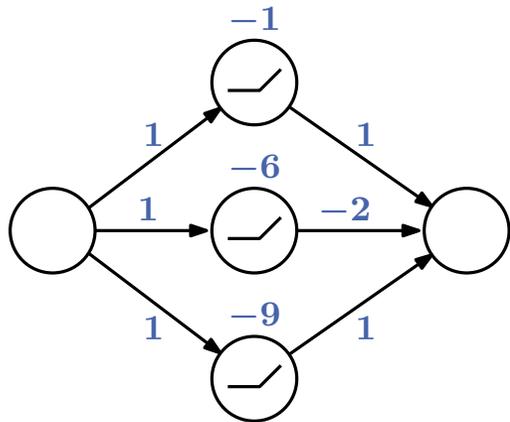


Das Trainingsproblem

Trainingsproblem: TRAINNN

Eingabe: Architektur (Graph) +
 n Datenpunkte: $(x_i, y_i)_{i=1, \dots, n}$
Eingabe \uparrow \uparrow Soll-Ausgabe

Frage: Existieren Parameter Θ , sodass für alle
Datenpunkte gilt: $f_{\Theta}(x_i) = y_i$

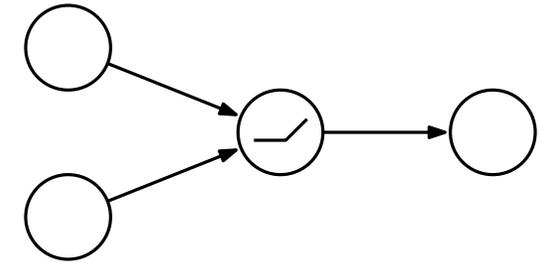
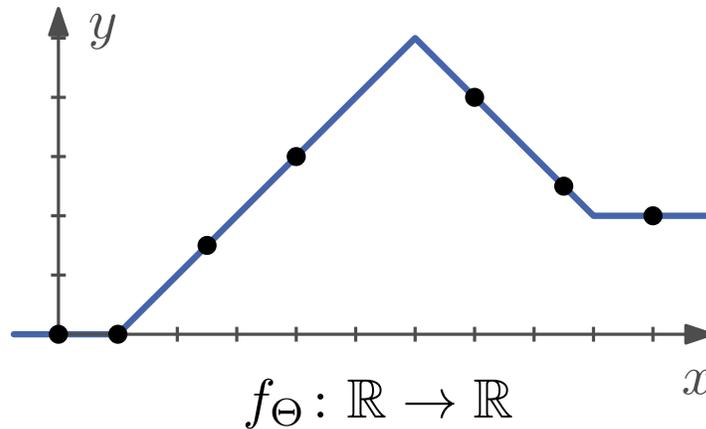
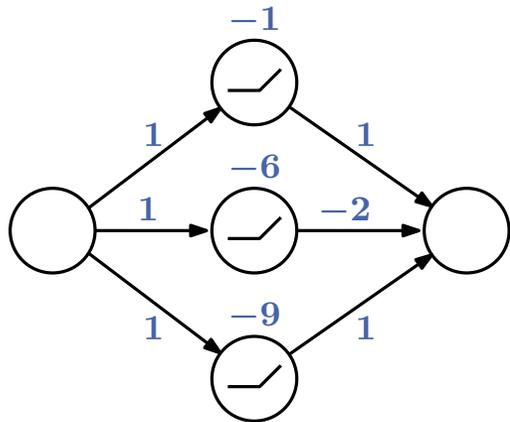


Das Trainingsproblem

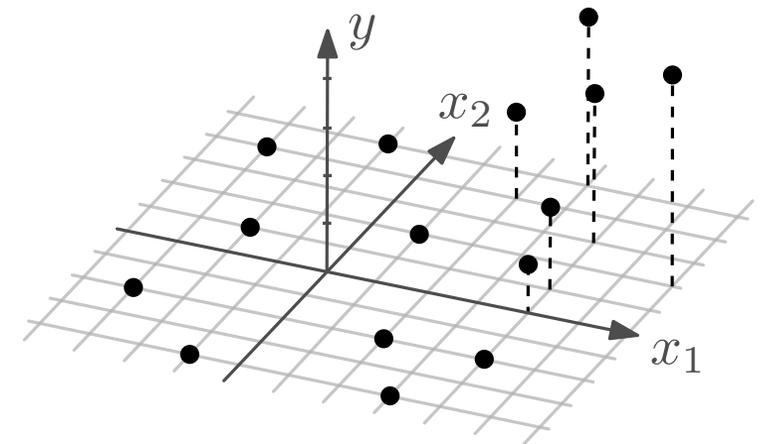
Trainingsproblem: TRAINNN

Eingabe: Architektur (Graph) +
 n Datenpunkte: $(x_i, y_i)_{i=1, \dots, n}$
Eingabe \uparrow \uparrow Soll-Ausgabe

Frage: Existieren Parameter Θ , sodass für alle
Datenpunkte gilt: $f_{\Theta}(x_i) = y_i$



$$f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}$$

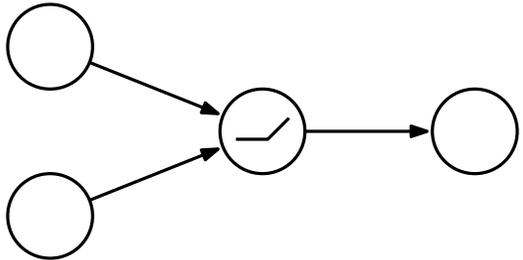
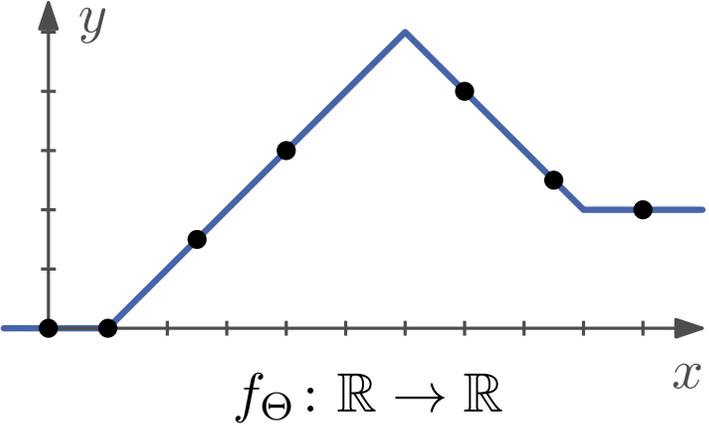
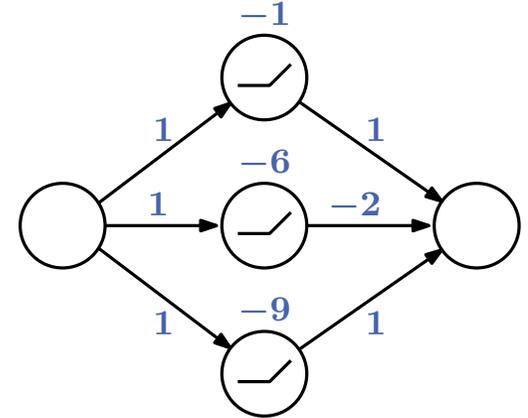


Das Trainingsproblem

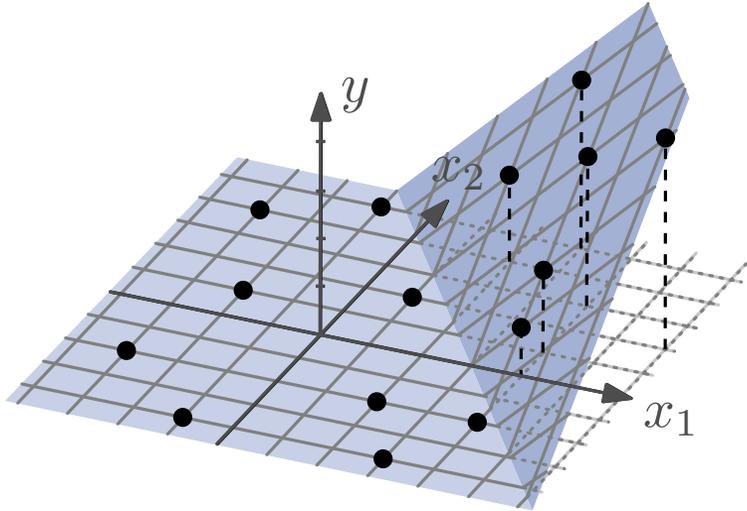
Trainingsproblem: TRAINNN

Eingabe: Architektur (Graph) +
 n Datenpunkte: $(x_i, y_i)_{i=1, \dots, n}$
 Eingabe \uparrow \uparrow Soll-Ausgabe

Frage: Existieren Parameter Θ , sodass für alle
 Datenpunkte gilt: $f_{\Theta}(x_i) = y_i$



$$f_{\Theta} : \mathbb{R}^2 \rightarrow \mathbb{R}$$



Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- NP-schwer [Blum, Rivest 1992]

Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- **NP-schwer** [Blum, Rivest 1992]
- **in NP** für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- **NP-schwer** [Blum, Rivest 1992]
- **in NP** für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- **$\exists\mathbb{R}$ -schwer** [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- NP-schwer [Blum, Rivest 1992]
- in NP für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- $\exists\mathbb{R}$ -schwer [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- **NP-schwer** [Blum, Rivest 1992]
- **in NP** für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- **$\exists\mathbb{R}$ -schwer** [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

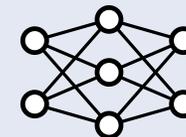
Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Sogar folgender Spezialfall:

- nur eine versteckte Schicht



Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- **NP-schwer** [Blum, Rivest 1992]
- **in NP** für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- **$\exists\mathbb{R}$ -schwer** [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

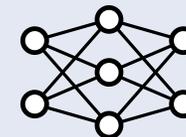
Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Sogar folgender Spezialfall:

- nur eine versteckte Schicht
- nur zwei Inputs und Outputs



Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- **NP-schwer** [Blum, Rivest 1992]
- **in NP** für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- **$\exists\mathbb{R}$ -schwer** [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

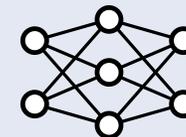
Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Sogar folgender Spezialfall:

- nur eine versteckte Schicht
- nur zwei Inputs und Outputs
- vollständig verbunden



Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- NP-schwer [Blum, Rivest 1992]
- in NP für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- $\exists\mathbb{R}$ -schwer [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

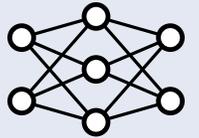
Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Sogar folgender Spezialfall:

- nur eine versteckte Schicht
- nur zwei Inputs und Outputs
- vollständig verbunden



← ~~X~~ $\exists\mathbb{R}$ -schwer schon bei zwei Outputs
(Annahme: $NP \neq \exists\mathbb{R}$)

Bisherige Ergebnisse & Beitrag

Literatur (Auswahl):

TRAINNN ist ...

- **NP-schwer** [Blum, Rivest 1992]
- **in NP** für einzelnes Output-Neuron [Arora et al. 2018]

Frage: Verallgemeinerbar auf kompliziertere Architekturen?

- **$\exists\mathbb{R}$ -schwer** [Zhang 1992] [Abrahamsen, Kleist, Miltzow 2021]

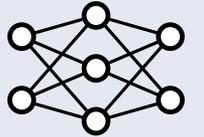
Jedoch unter unrealistischen Annahmen:

- keine Aktivierungsfunktion
- speziell gewählte Architekturen, die besonders schwierig zu trainieren sind

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Sogar folgender Spezialfall:

- nur eine versteckte Schicht
- nur zwei Inputs und Outputs
- vollständig verbunden



X $\exists\mathbb{R}$ -schwer schon bei zwei Outputs
(Annahme: $NP \neq \exists\mathbb{R}$)

✓ realistische Annahmen

Beweis (Skizze)

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Schritt 1: TRAINNN ist **in** $\exists\mathbb{R}$
„höchstens“ so schwierig wie ETR

Schritt 2: TRAINNN ist $\exists\mathbb{R}$ -**schwer**
„mindestens“ so schwierig wie ETR

Beweis (Skizze)

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Schritt 1: TRAINNN ist **in** $\exists\mathbb{R}$
„höchstens“ so schwierig wie ETR

Reduktion: TRAINNN \rightsquigarrow ETR

Schritt 2: TRAINNN ist **$\exists\mathbb{R}$ -schwer**
„mindestens“ so schwierig wie ETR

Reduktion: ETR \rightsquigarrow TRAINNN

Beweis (Skizze)

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Schritt 1: TRAINNN ist **in** $\exists\mathbb{R}$
„höchstens“ so schwierig wie ETR

Reduktion: TRAINNN \rightsquigarrow ETR

TRAINNN als äquivalente ETR-Formel:

$$\exists \underbrace{w_1, \dots, b_1, \dots}_{\ominus} \in \mathbb{R} : \bigwedge_{i=1}^n f_{\ominus}(x_i) = y_i$$

als Polynomgleichung
formulieren

\rightsquigarrow TRAINNN $\in \exists\mathbb{R}$ □

Schritt 2: TRAINNN ist **$\exists\mathbb{R}$ -schwer**
„mindestens“ so schwierig wie ETR

Reduktion: ETR \rightsquigarrow TRAINNN

Beweis (Skizze)

Theorem: TRAINNN ist $\exists\mathbb{R}$ -vollständig.

Schritt 1: TRAINNN ist **in** $\exists\mathbb{R}$
„höchstens“ so schwierig wie ETR

Reduktion: TRAINNN \rightsquigarrow ETR

TRAINNN als äquivalente ETR-Formel:

$$\exists \underbrace{w_1, \dots, b_1, \dots}_{\Theta} \in \mathbb{R} : \bigwedge_{i=1}^n f_{\Theta}(x_i) = y_i$$

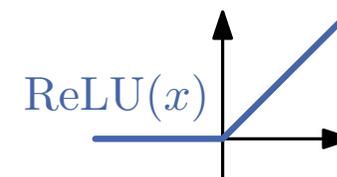
als Polynomgleichung formulieren

\rightsquigarrow TRAINNN $\in \exists\mathbb{R}$ □

Schritt 2: TRAINNN ist **$\exists\mathbb{R}$ -schwer**
„mindestens“ so schwierig wie ETR

Reduktion: ETR \rightsquigarrow TRAINNN

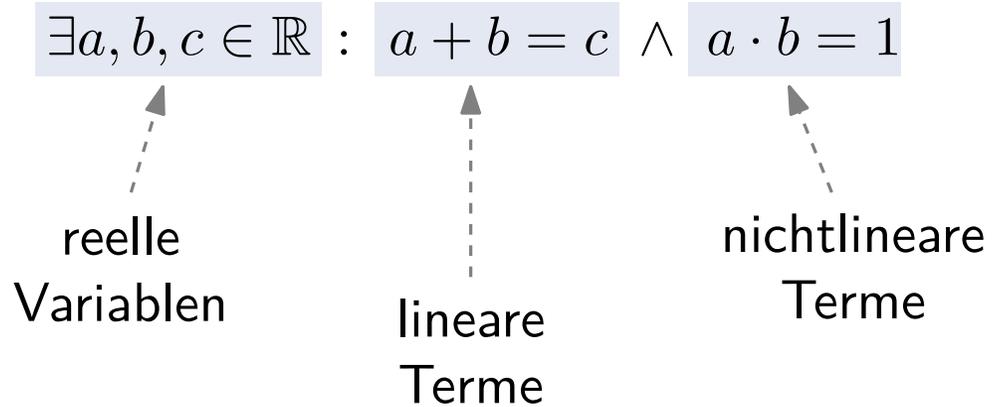
Geometrisch:
nutzt „Form“ der ReLU-Funktion



Reduktion: ETR \rightsquigarrow TRAINNN

Gegeben:

Beliebige Instanz von ETR, z.B.:



Reduktion: ETR \rightsquigarrow TRAINNN

Gegeben:

Beliebige Instanz von ETR, z.B.:

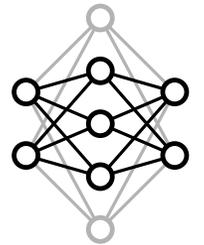
$$\exists a, b, c \in \mathbb{R} : a + b = c \wedge a \cdot b = 1$$

reelle Variablen lineare Terme nichtlineare Terme

Zu konstruieren:

Äquivalente Instanz von TRAINNN:

- Architektur
 - zwei Inputs und zwei Outputs
 - eine versteckte Schicht
 - feste Anzahl an ReLUs
- Trainingsdaten
 - Eingaben
 - Soll-Ausgaben



Reduktion: ETR \rightsquigarrow TRAINNN

Gegeben:

Beliebige Instanz von ETR, z.B.:

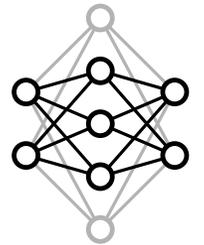
$$\exists a, b, c \in \mathbb{R} : a + b = c \wedge a \cdot b = 1$$

reelle Variablen \nearrow lineare Terme \nearrow nichtlineare Terme

Zu konstruieren:

Äquivalente Instanz von TRAINNN:

- Architektur
 - zwei Inputs und zwei Outputs
 - eine versteckte Schicht
 - feste Anzahl an ReLUs
- Trainingsdaten
 - Eingaben
 - Soll-Ausgaben



Formel wahr \iff

Instanz exakt trainierbar
(Funktion geht durch alle Datenpunkte)

Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

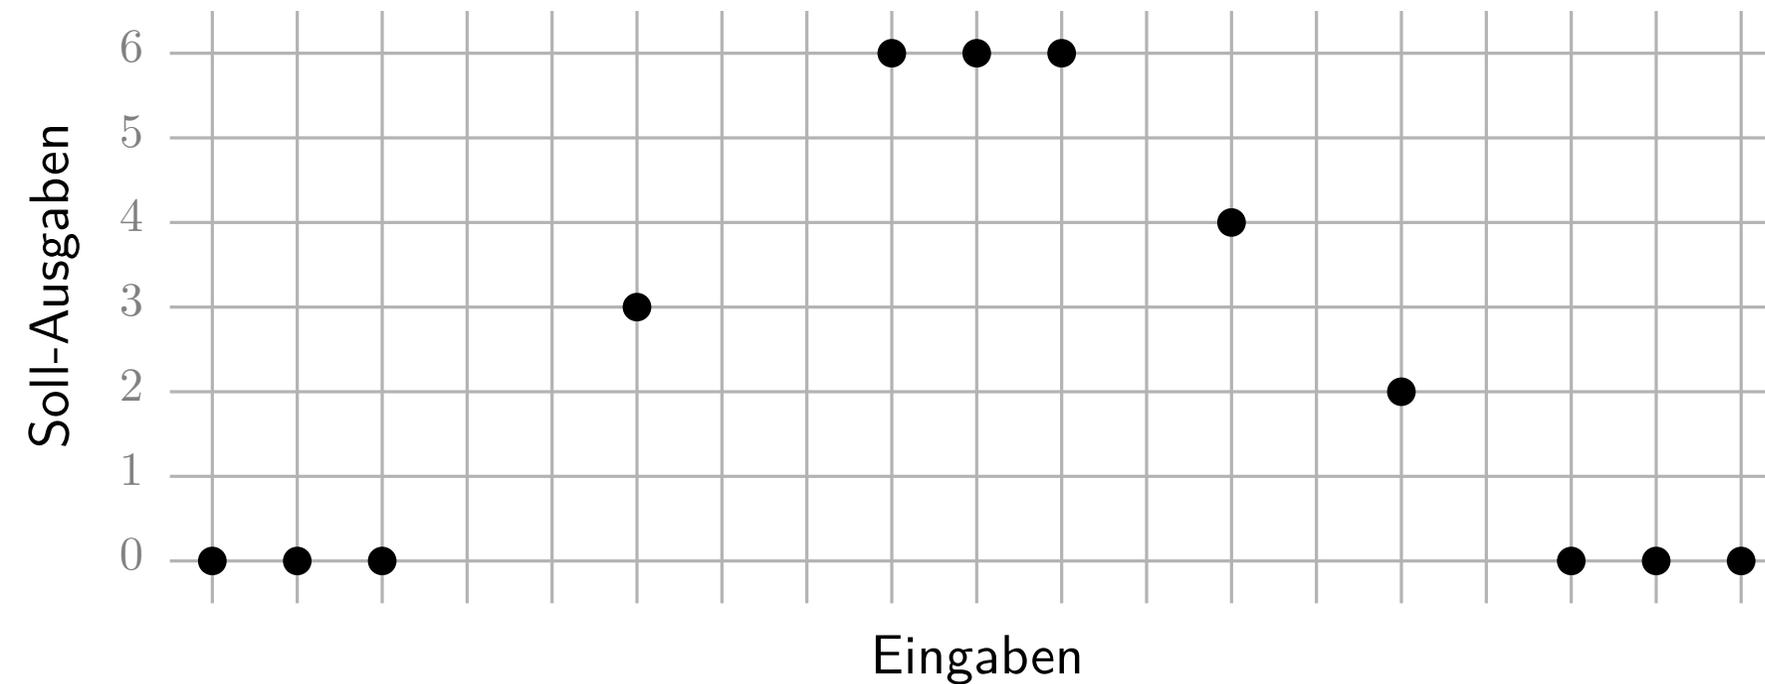
Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:

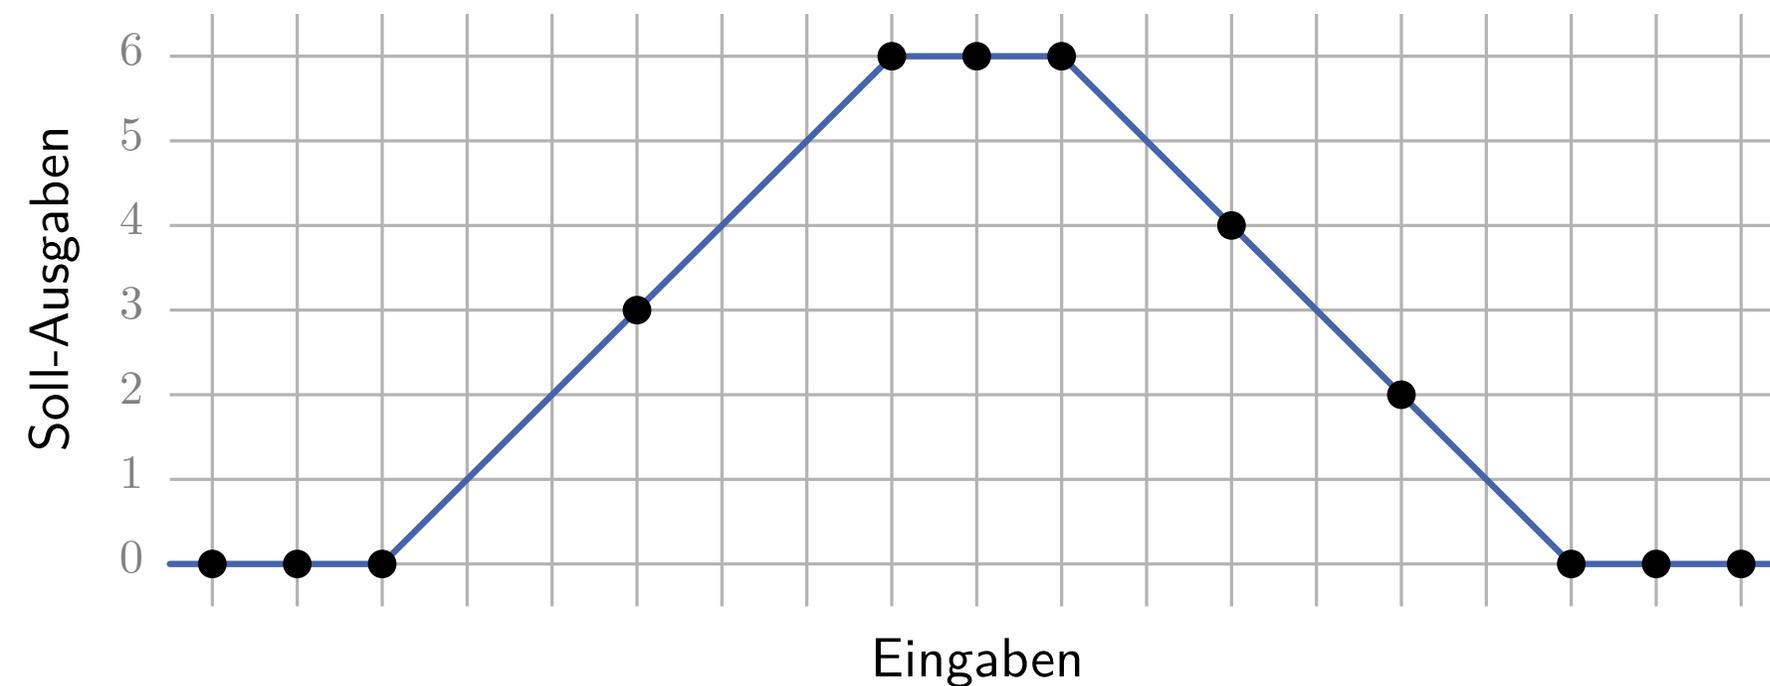


Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:

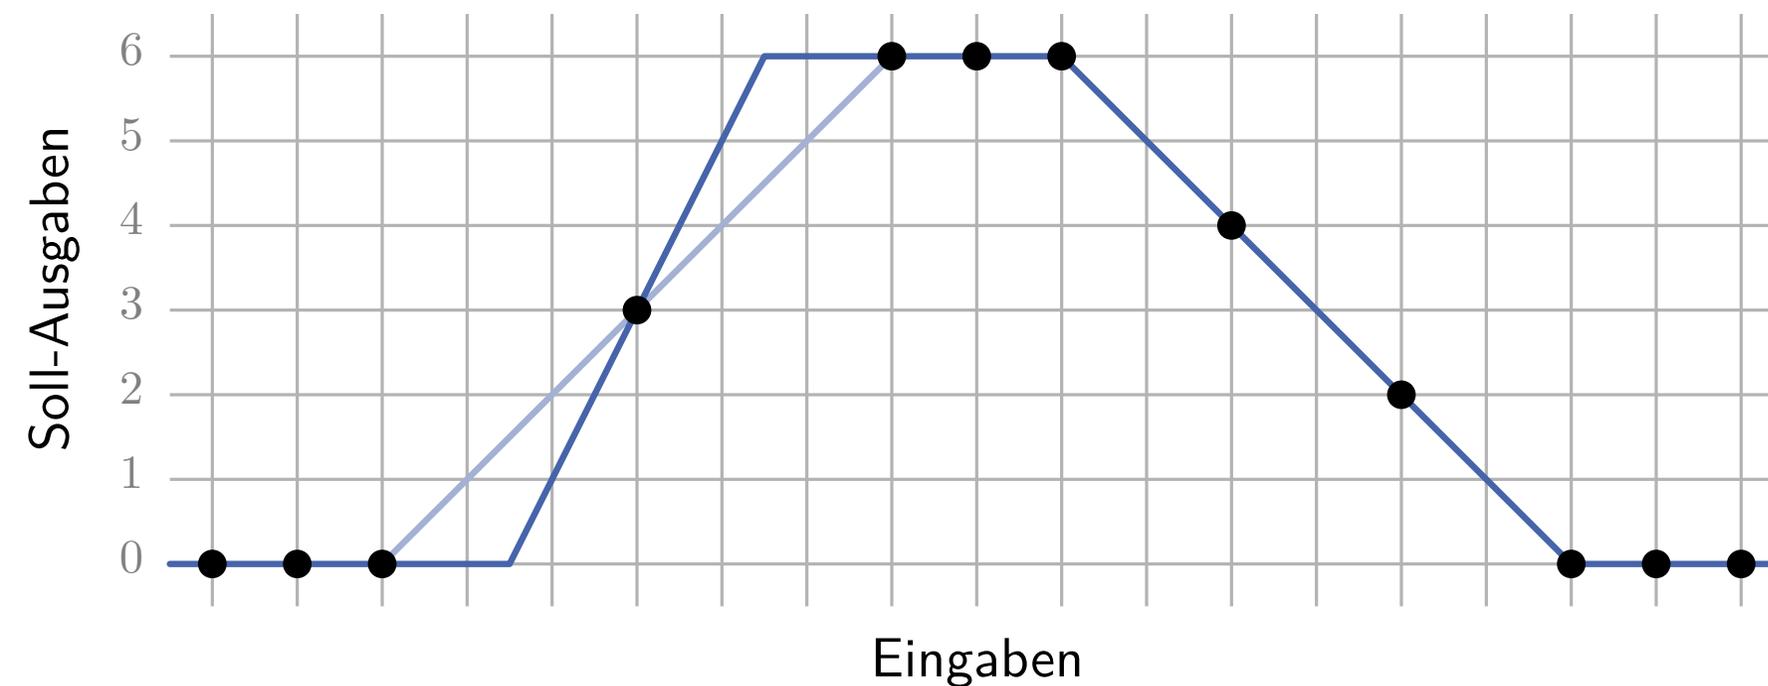


Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:

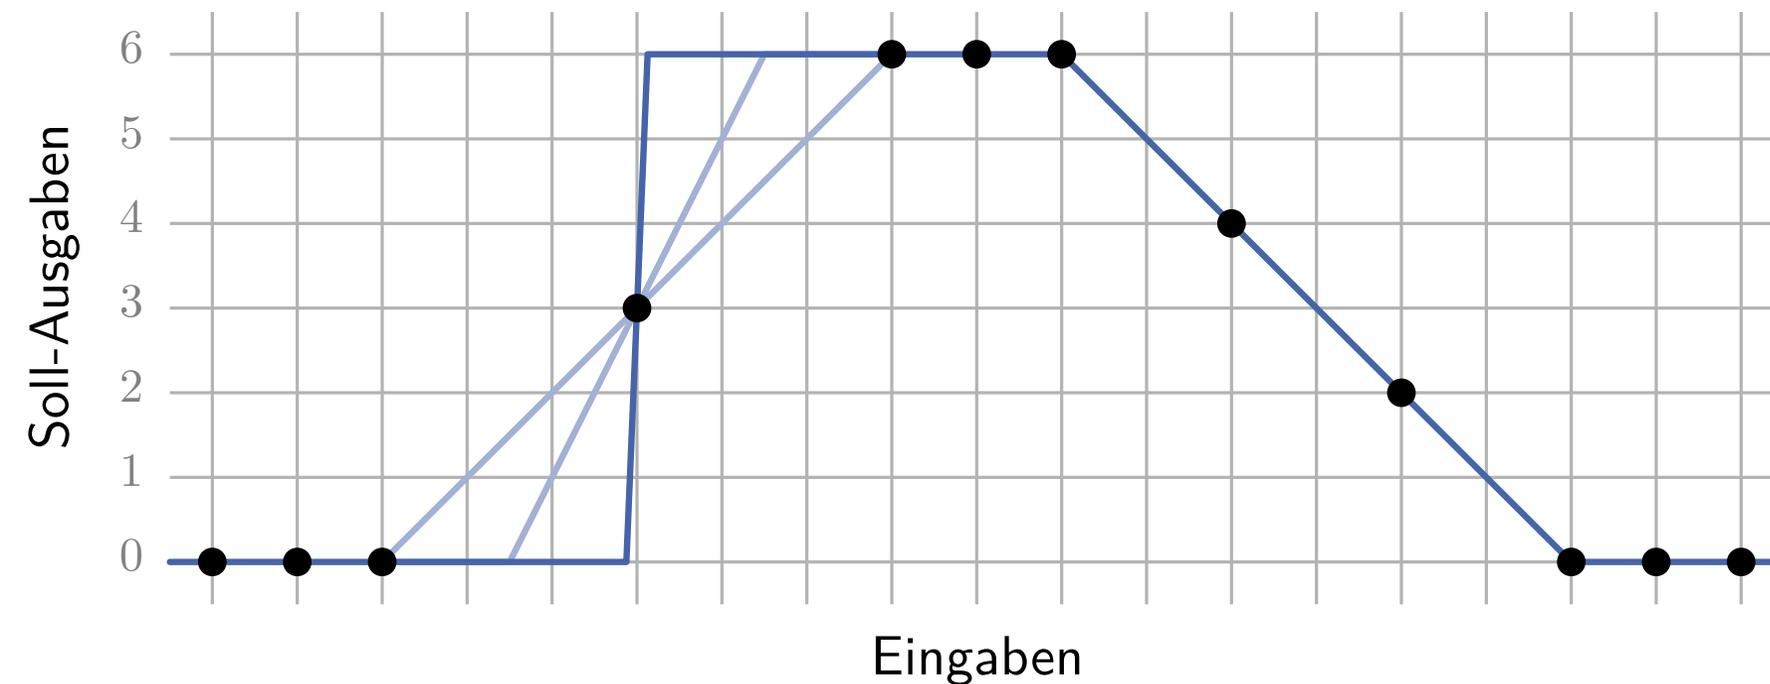


Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:

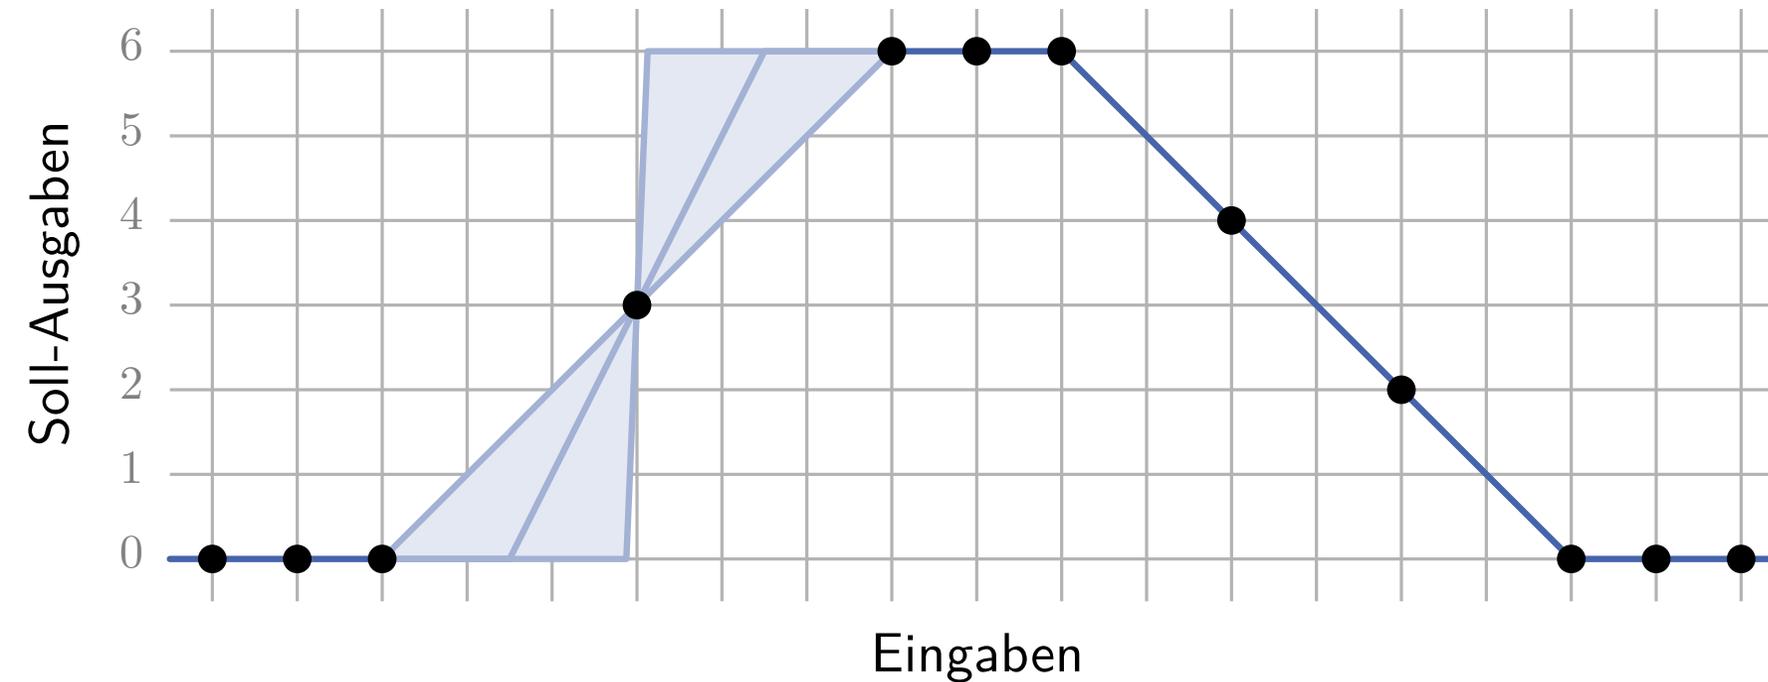


Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:

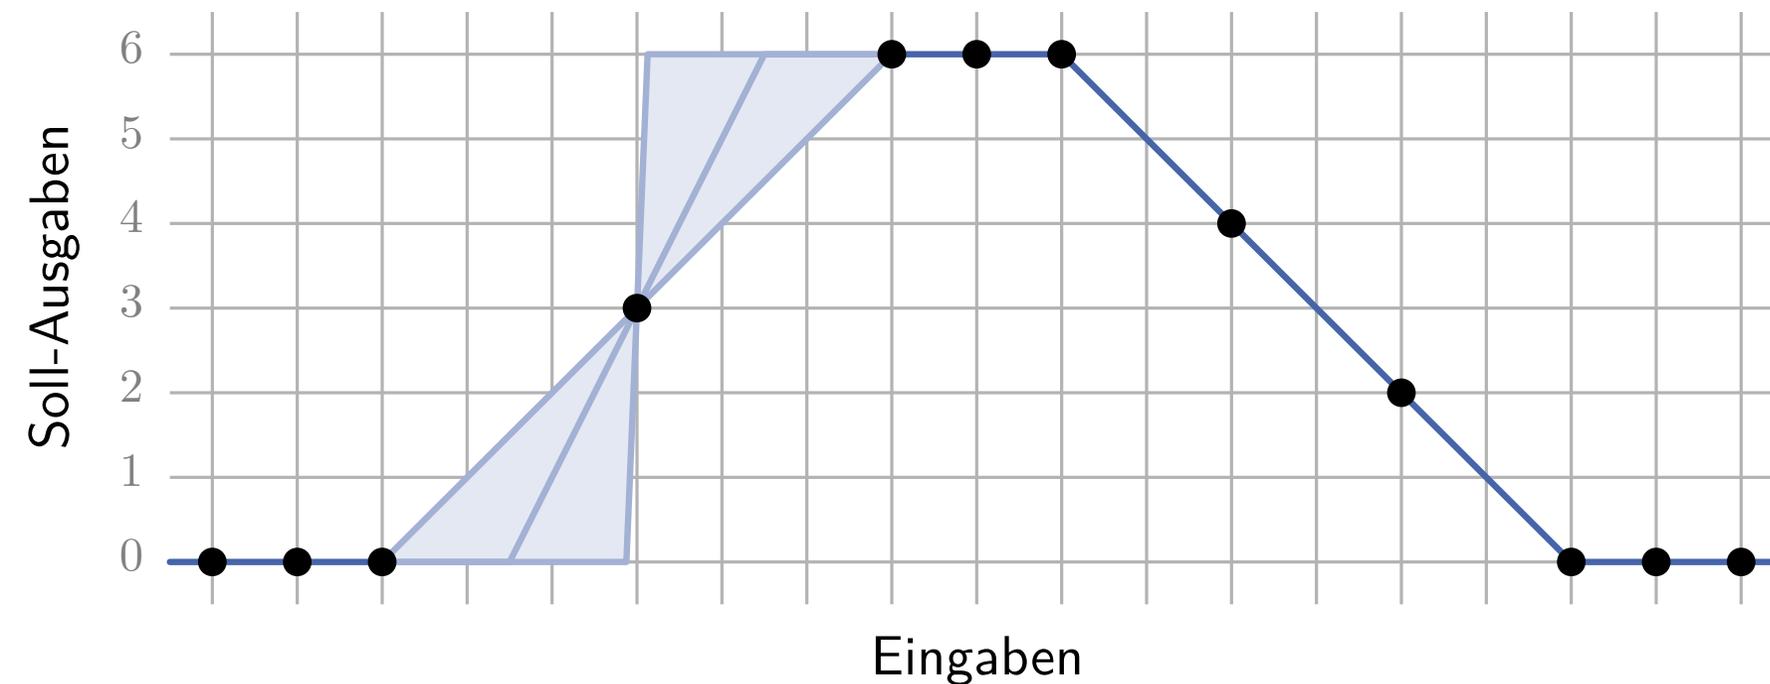


Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:



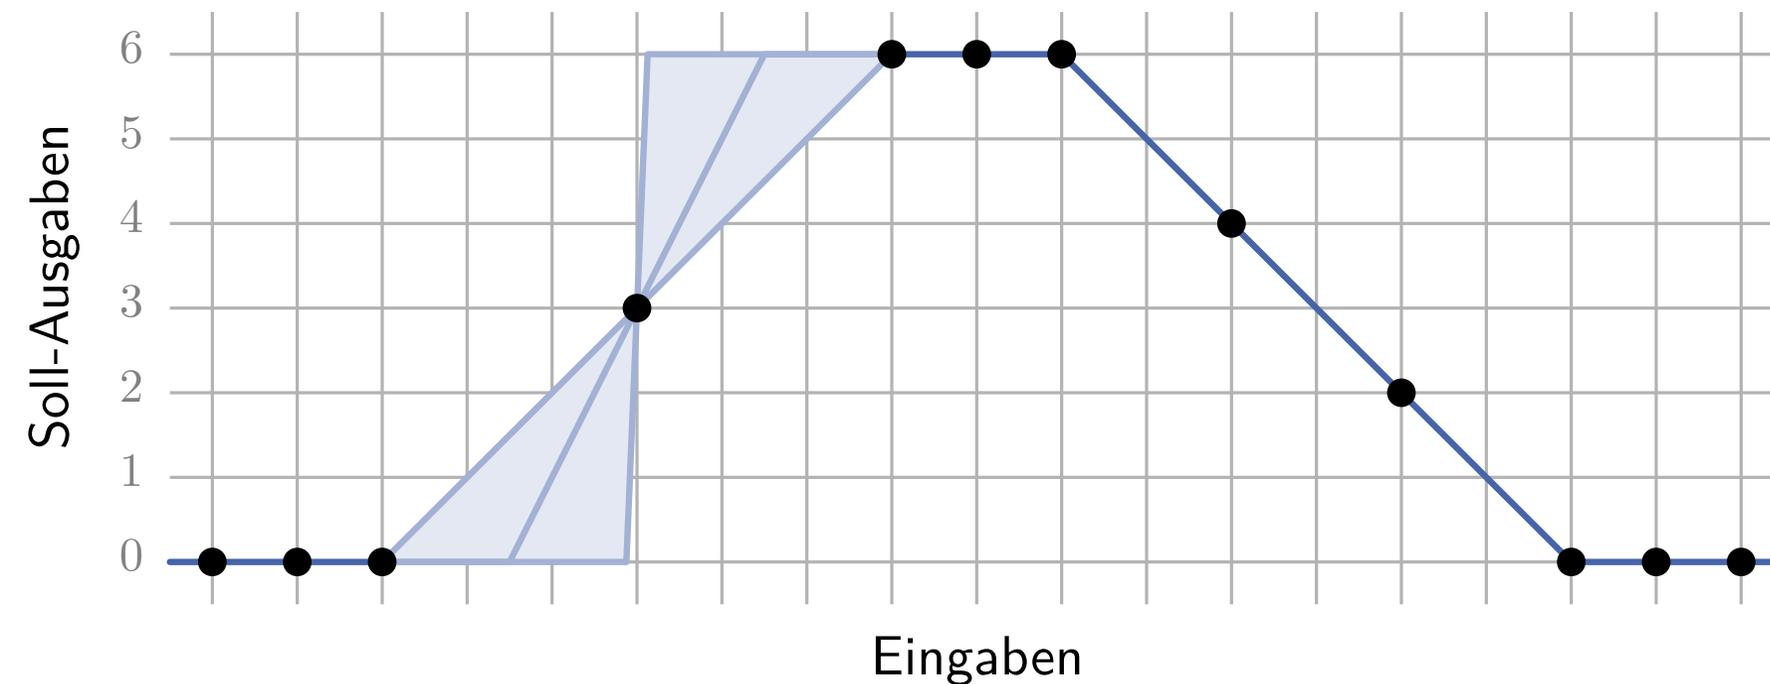
Beobachtung:
Funktionen unterscheiden sich nur in der Steigung.

Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:



Beobachtung:

Funktionen unterscheiden sich nur in der Steigung.

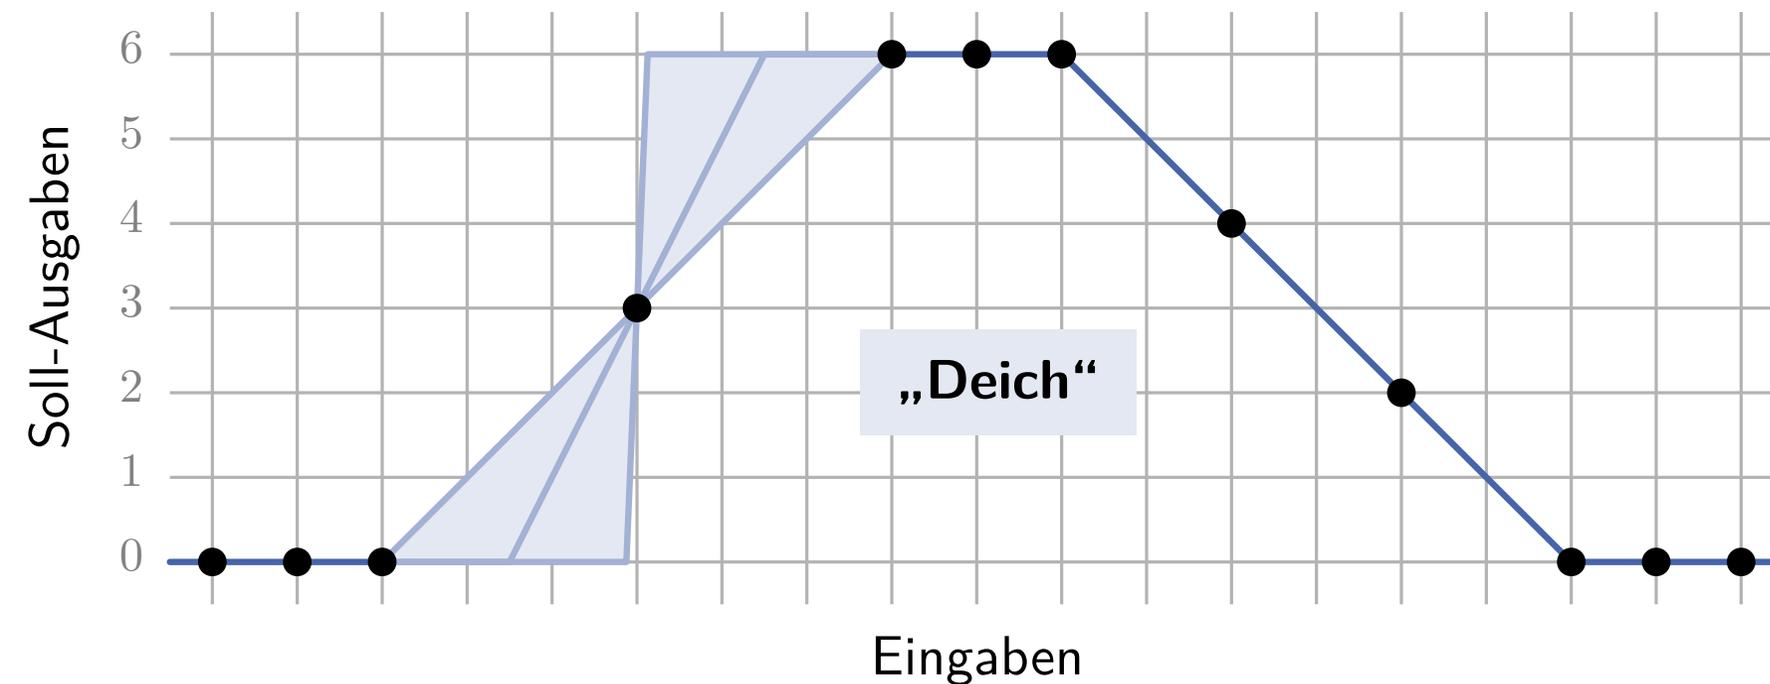
\rightsquigarrow Steigung $\hat{=}$ Wert

Teil 1: Reelle Variablen

ETR: $\exists a \in \mathbb{R}$

Ziel: Simulation von „ $\exists a \in \mathbb{R}$ “ als Instanz von TRAINNN

12 Datenpunkte und 4 ReLUs:



Beobachtung:

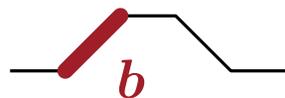
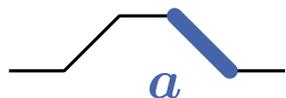
Funktionen unterscheiden sich nur in der Steigung.

\rightsquigarrow Steigung $\hat{=}$ Wert

Teil 2: Lineare Zusammenhänge

ETR: lineare Zusammenhänge, z.B. $a + b = 5$

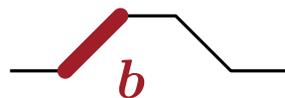
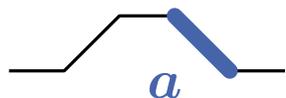
Ziel: Simulation von „ $a + b = 5$ “ als Instanz von TRAINNN



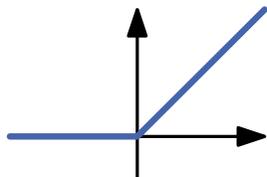
Teil 2: Lineare Zusammenhänge

ETR: lineare Zusammenhänge, z.B. $a + b = 5$

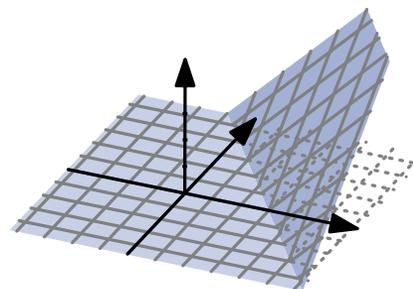
Ziel: Simulation von „ $a + b = 5$ “ als Instanz von TRAINNN



Idee: ausnutzen, dass es zwei Input-Neuronen gibt



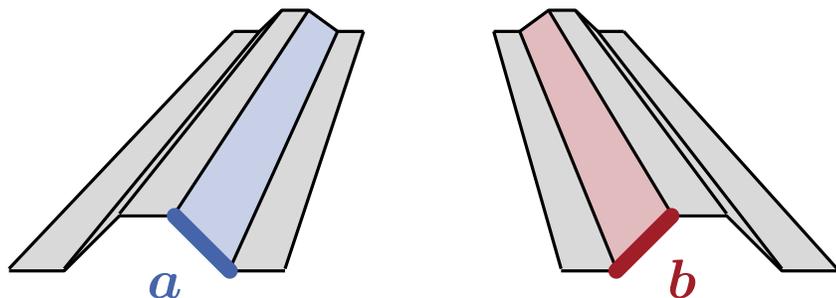
\leadsto



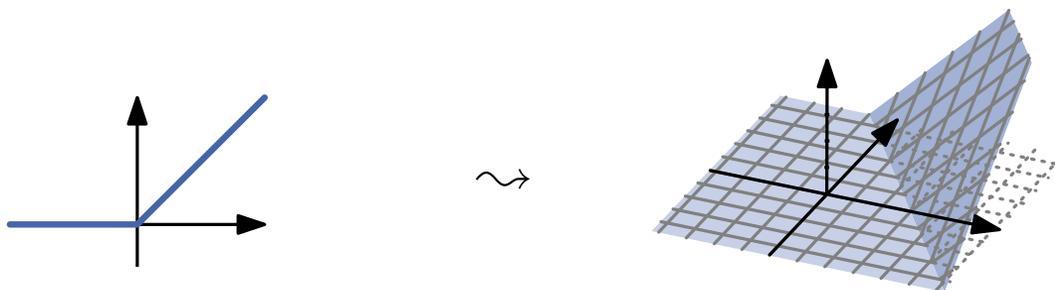
Teil 2: Lineare Zusammenhänge

ETR: lineare Zusammenhänge, z.B. $a + b = 5$

Ziel: Simulation von „ $a + b = 5$ “ als Instanz von TRAINNN



Idee: ausnutzen, dass es zwei Input-Neuronen gibt



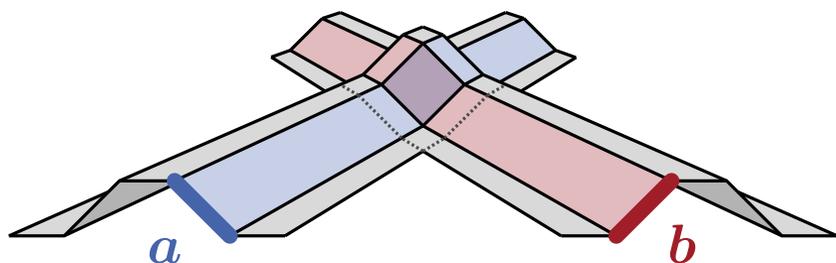
Beobachtungen:

- Variablen-Deiche: $2D \rightsquigarrow 3D$
Wie vorher: **Steigung** $\hat{=}$ **Wert**

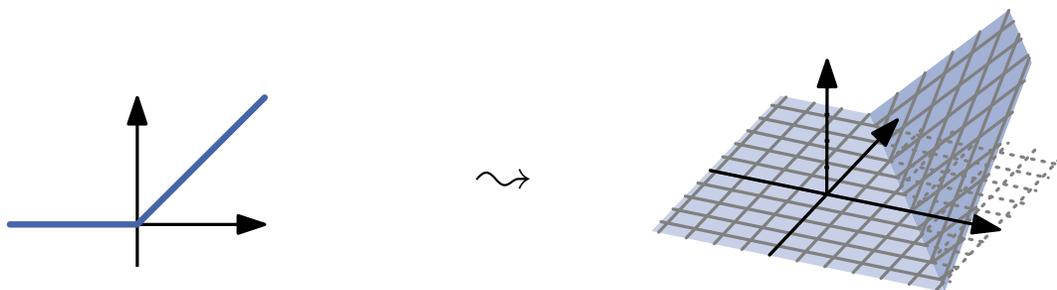
Teil 2: Lineare Zusammenhänge

ETR: lineare Zusammenhänge, z.B. $a + b = 5$

Ziel: Simulation von „ $a + b = 5$ “ als Instanz von TRAINNN



Idee: ausnutzen, dass es zwei Input-Neuronen gibt



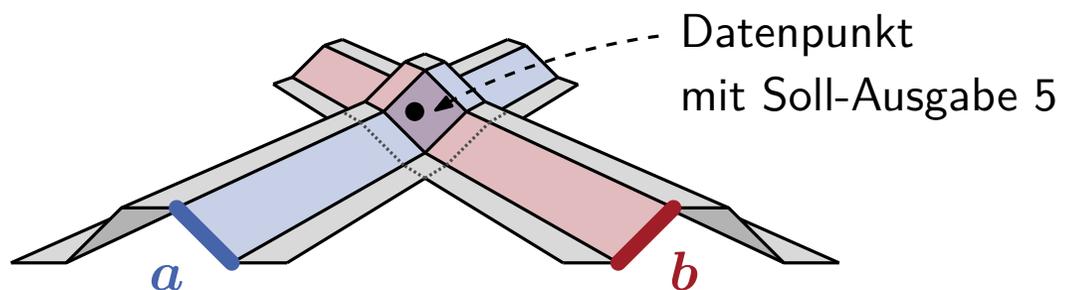
Beobachtungen:

- Variablen-Deiche: $2D \rightsquigarrow 3D$
Wie vorher: **Steigung $\hat{=}$ Wert**
- „Interferenz“ in Überlagerung

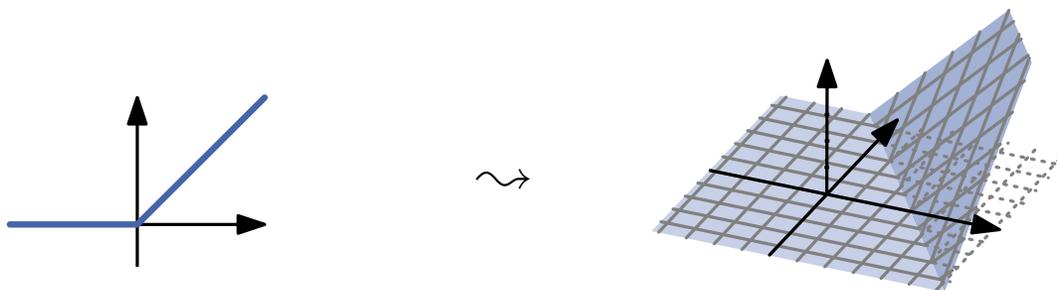
Teil 2: Lineare Zusammenhänge

ETR: lineare Zusammenhänge, z.B. $a + b = 5$

Ziel: Simulation von „ $a + b = 5$ “ als Instanz von TRAINNN



Idee: ausnutzen, dass es zwei Input-Neuronen gibt



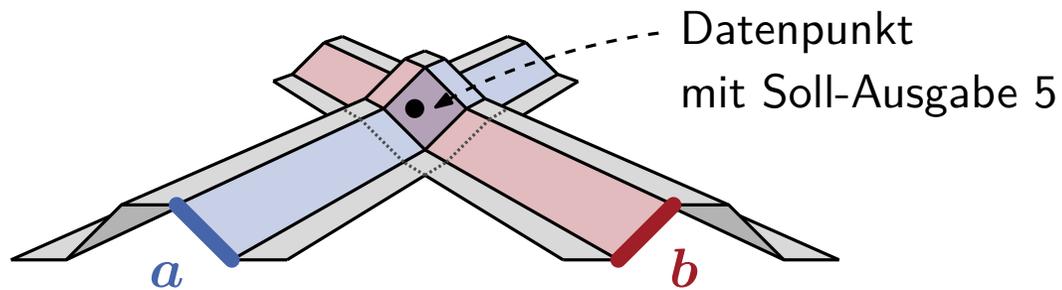
Beobachtungen:

- Variablen-Deiche: $2D \rightsquigarrow 3D$
Wie vorher: **Steigung $\hat{=}$ Wert**
- „Interferenz“ in Überlagerung
- Datenpunkt in Überlagerung
 - blau steiler \rightsquigarrow rot flacher
 - rot steiler \rightsquigarrow blau flacher

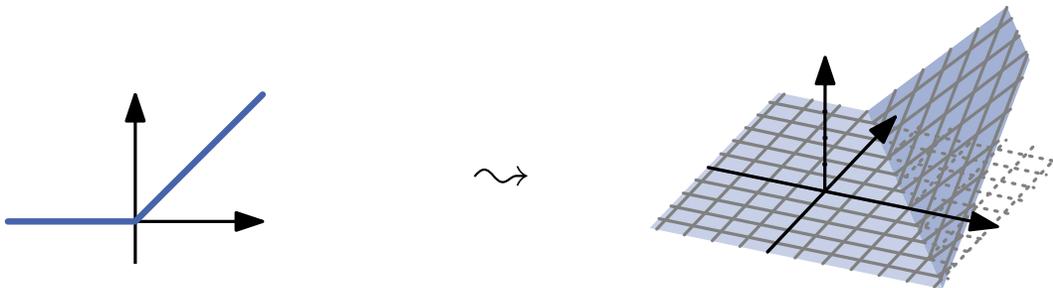
Teil 2: Lineare Zusammenhänge

ETR: lineare Zusammenhänge, z.B. $a + b = 5$

Ziel: Simulation von „ $a + b = 5$ “ als Instanz von TRAINNN



Idee: ausnutzen, dass es zwei Input-Neuronen gibt



Beobachtungen:

- Variablen-Deiche: $2D \rightsquigarrow 3D$
Wie vorher: **Steigung $\hat{=}$ Wert**
- „Interferenz“ in Überlagerung
- Datenpunkt in Überlagerung
 - blau steiler \rightsquigarrow rot flacher
 - rot steiler \rightsquigarrow blau flacher
- weitere lineare Terme, insb.:
 - Gleichheit
 - Addition (3er-Überlagerung)

Teil 3: Zusammensetzen

Reduktion: $\text{ETR} \rightsquigarrow \text{TRAINNN}$

Gegeben:

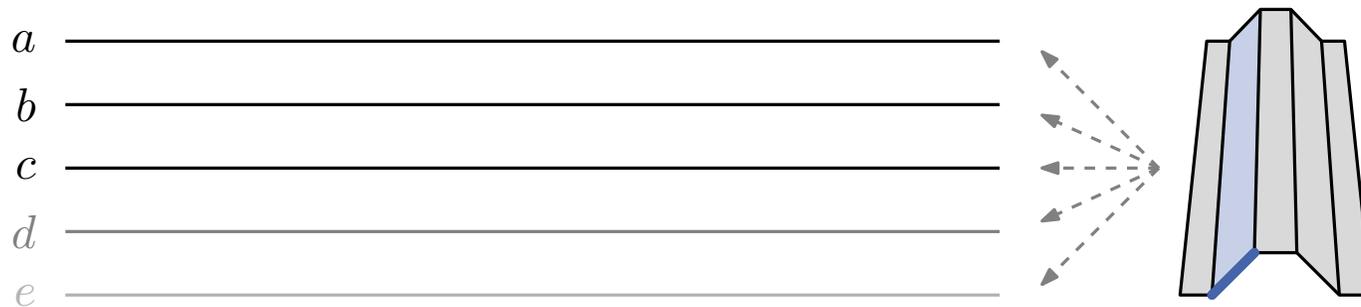
- Variablen: $a, b, c, \dots \in \mathbb{R}$
- lineare Terme: $a + b = c$
- nichtlineare Terme: $a \cdot b = 1$

Teil 3: Zusammensetzen

Reduktion: $\text{ETR} \rightsquigarrow \text{TRAINNN}$

Gegeben:

- Variablen: $a, b, c, \dots \in \mathbb{R}$
- lineare Terme: $a + b = c$
- nichtlineare Terme: $a \cdot b = 1$

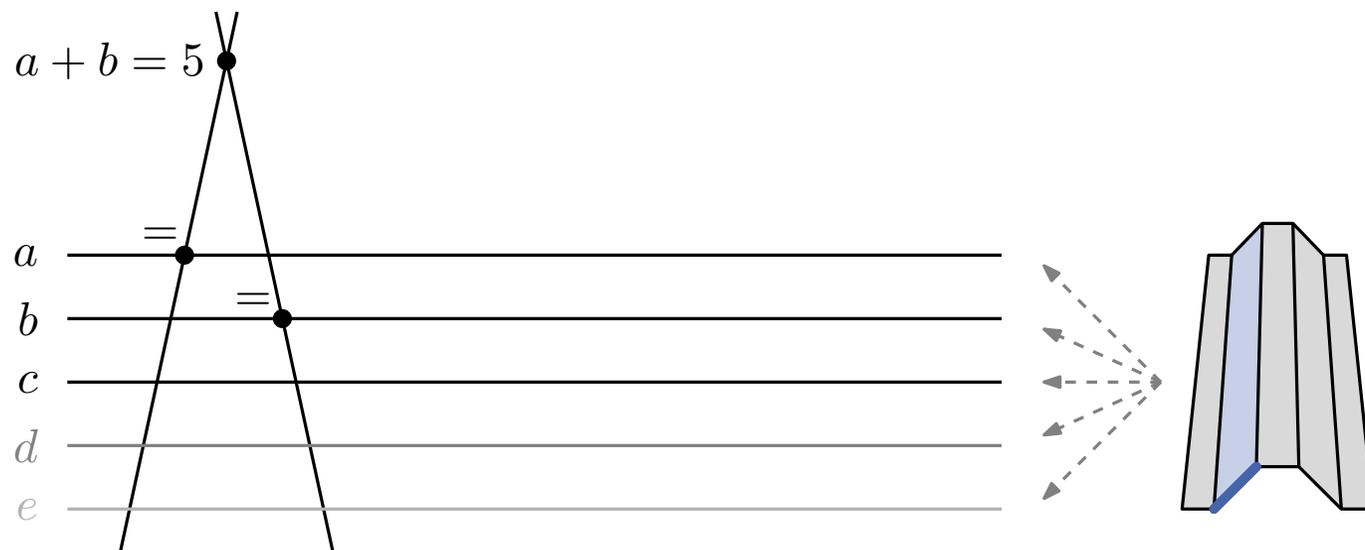


Teil 3: Zusammensetzen

Reduktion: $\text{ETR} \rightsquigarrow \text{TRAINNN}$

Gegeben:

- Variablen: $a, b, c, \dots \in \mathbb{R}$
- lineare Terme: $a + b = c$
- nichtlineare Terme: $a \cdot b = 1$

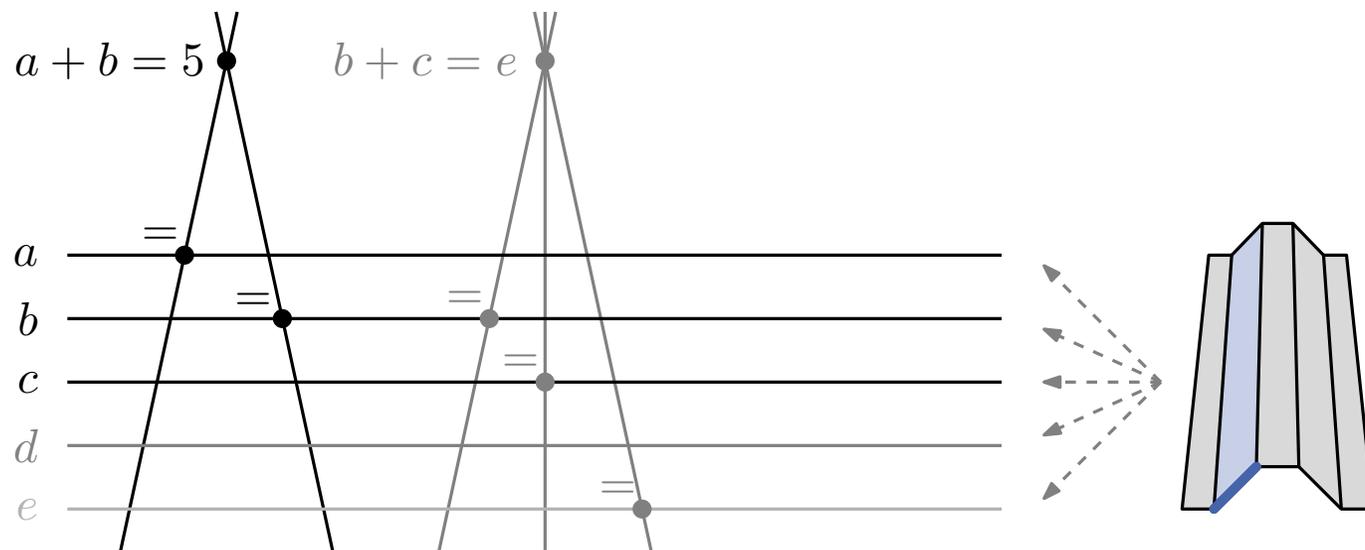


Teil 3: Zusammensetzen

Reduktion: $\text{ETR} \rightsquigarrow \text{TRAINNN}$

Gegeben:

- Variablen: $a, b, c, \dots \in \mathbb{R}$
- lineare Terme: $a + b = c$
- nichtlineare Terme: $a \cdot b = 1$

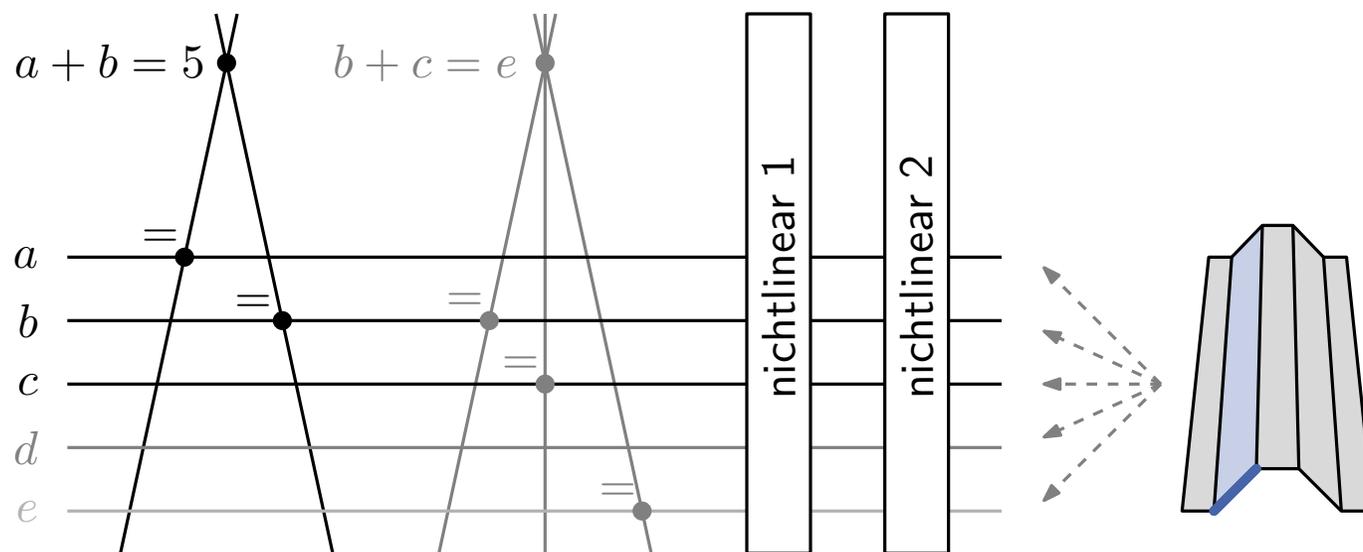


Teil 3: Zusammensetzen

Reduktion: $\text{ETR} \rightsquigarrow \text{TRAINNN}$

Gegeben:

- Variablen: $a, b, c, \dots \in \mathbb{R}$
- lineare Terme: $a + b = c$
- nichtlineare Terme: $a \cdot b = 1$

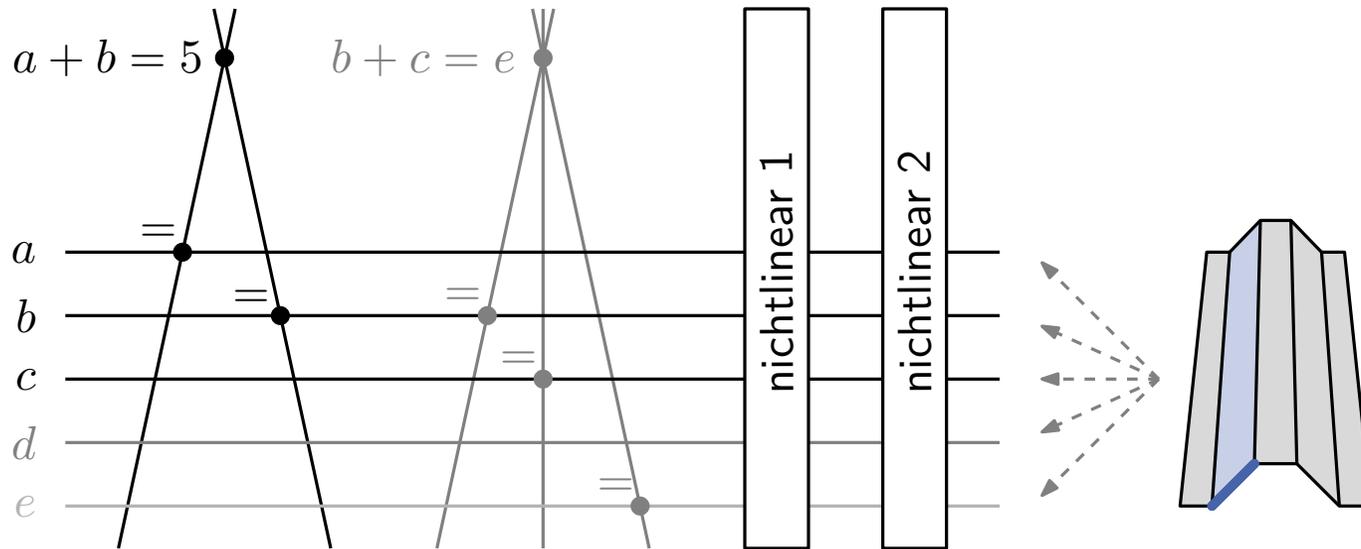


Teil 3: Zusammensetzen

Reduktion: $\text{ETR} \rightsquigarrow \text{TRAINNN}$

Gegeben:

- Variablen: $a, b, c, \dots \in \mathbb{R}$
- lineare Terme: $a + b = c$
- nichtlineare Terme: $a \cdot b = 1$

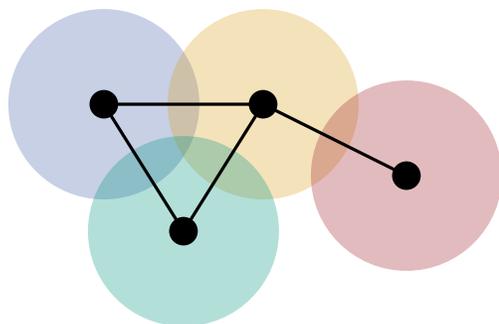


Zusammenfassung:

- TRAINNN simuliert ETR
 \rightsquigarrow TRAINNN is $\exists\mathbb{R}$ -schwer
- Schwere des Spezialfalls
 \rightsquigarrow Schwere im Allgemeinen
- keine unrealistischen Annahmen

Zusammenfassung

Hyperbolische Geometrie

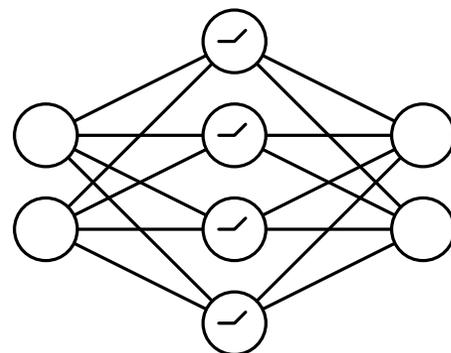


$\exists \mathbb{R}$ -Schwere in der hyperbolischen Ebene

[EuroCG 2023]

[Bieker, Bläsius, Dohse, **Jungeblut**]

Training neuronaler Netze

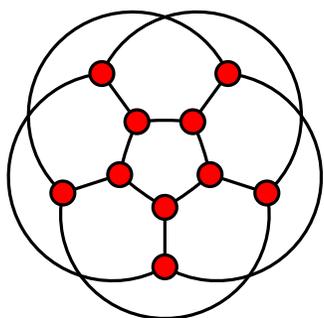


$\exists \mathbb{R}$ -vollständig unter realistischen Annahmen

[NeurIPS 2023]

[Bertschinger, Hertrich, **Jungeblut**, Miltzow, Weber]

Lombardi-Zeichnungen

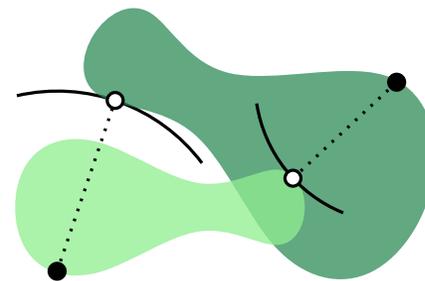


Graphvisualisierung unter geometrischen Nebenbedingungen

[GD 2023]

[**Jungeblut**]

Hausdorff-Distanz



Distanzmaß für Mengen
 $\rightsquigarrow \forall \mathbb{R}$ -vollständig

[SoCG 2022]

[Discrete Comput. Geom. 2024]

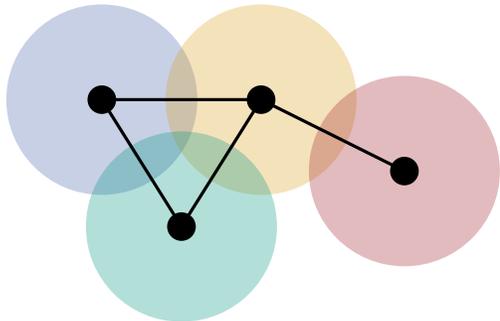
[**Jungeblut**, Kleist, Miltzow]

Erkennung von Unit-Disk-Graphen ist in $\exists\mathbb{R}$

Problem: Unit-Disk-Graphen erkennen

Eingabe: Graph $G = (V, E)$

Finde: Schnittrepräsentation von G
bestehend aus Einheitskreisen.



\iff

$$\exists p_1, \dots, p_n \in \mathbb{R}^2 : \bigwedge_{uv \in E} \|p_u - p_v\| \leq 2$$

$$\bigwedge_{uv \notin E} \|p_u - p_v\| > 2$$

←----- Kanten

←----- nicht-Kanten

$$(x_u - x_v)^2 + (y_u - y_v)^2 \leq 4$$



Quadrieren

$$\sqrt{(x_u - x_v)^2 + (y_u - y_v)^2} \leq 2$$



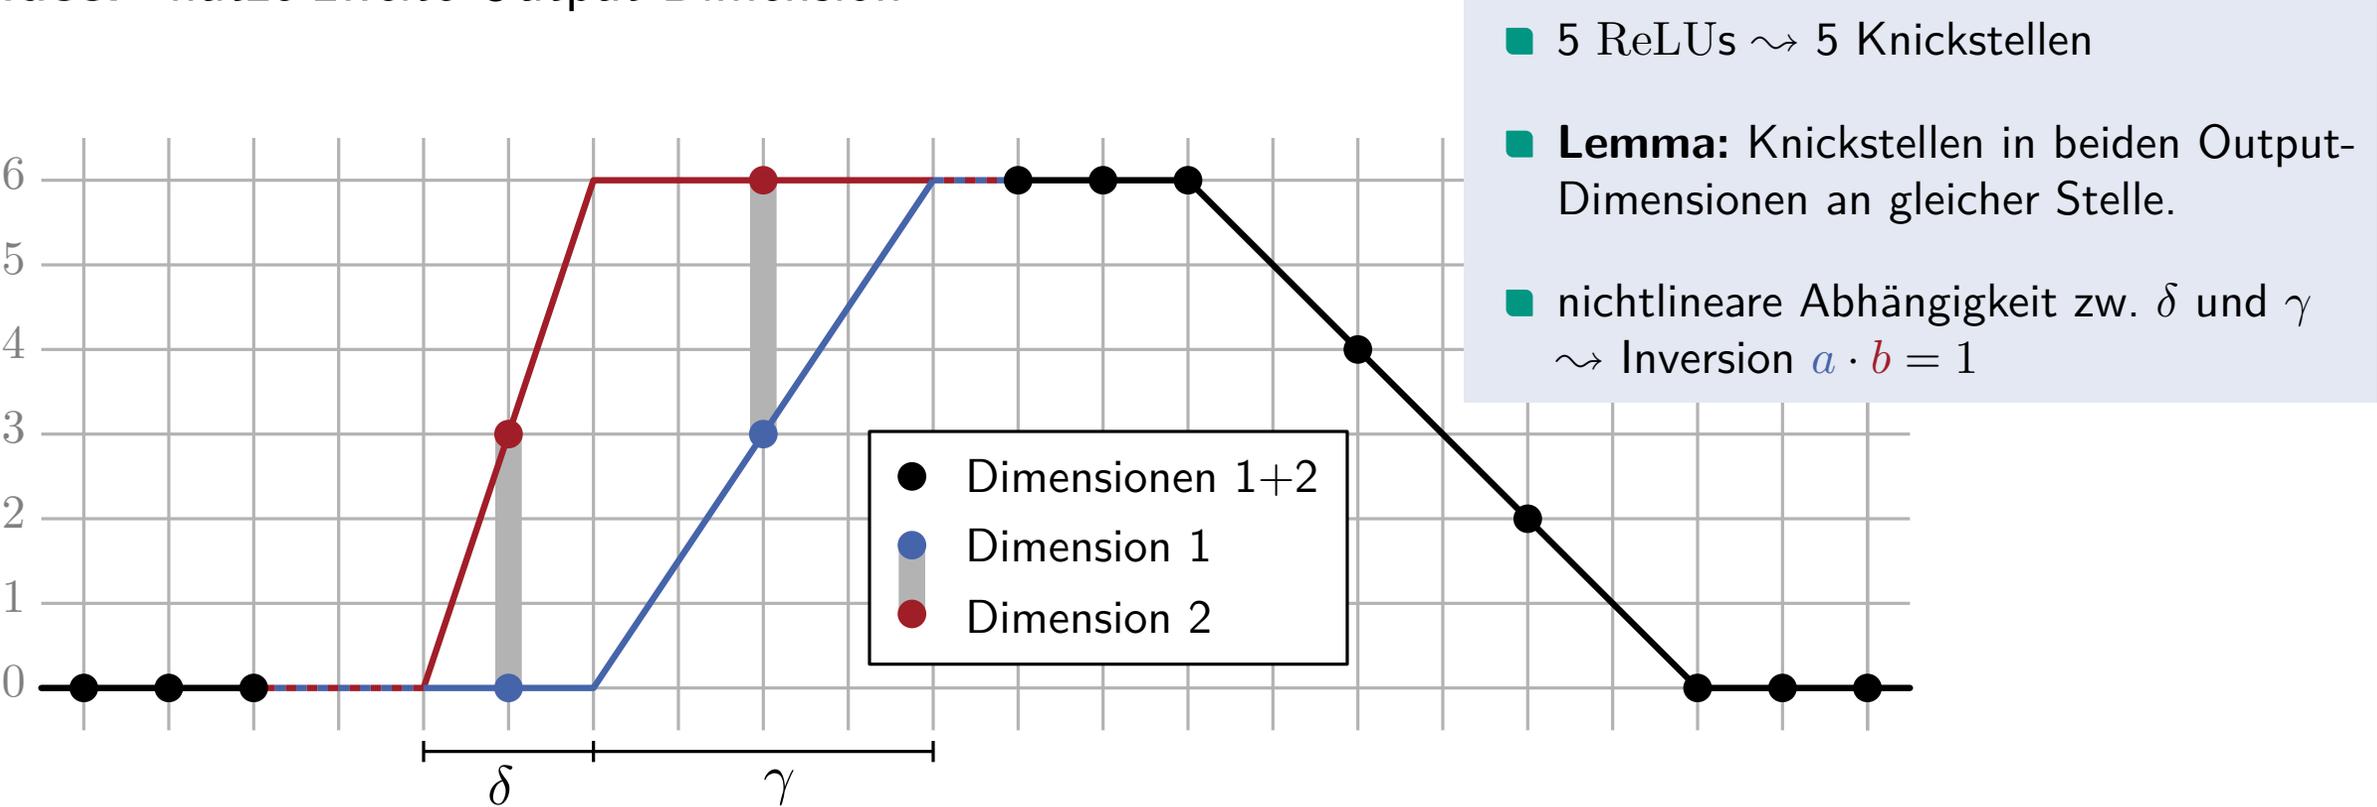
Satz des
Pythagoras

Reduktion: Nichtlineare Terme

ETR: nichtlinearer Zusammenhang, z.B. $a \cdot b = 1$

Ziel: Simulation von „ $a \cdot b = 1$ “ als Instanz von TRAINNN

Idee: nutze zweite Output-Dimension



Das STRETCHABILITY-Problem

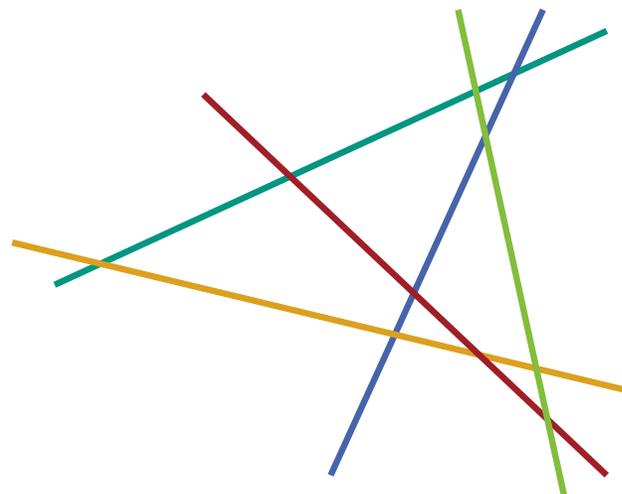
Eingabe:



Menge von **Pseudogeraden**



Gesucht:



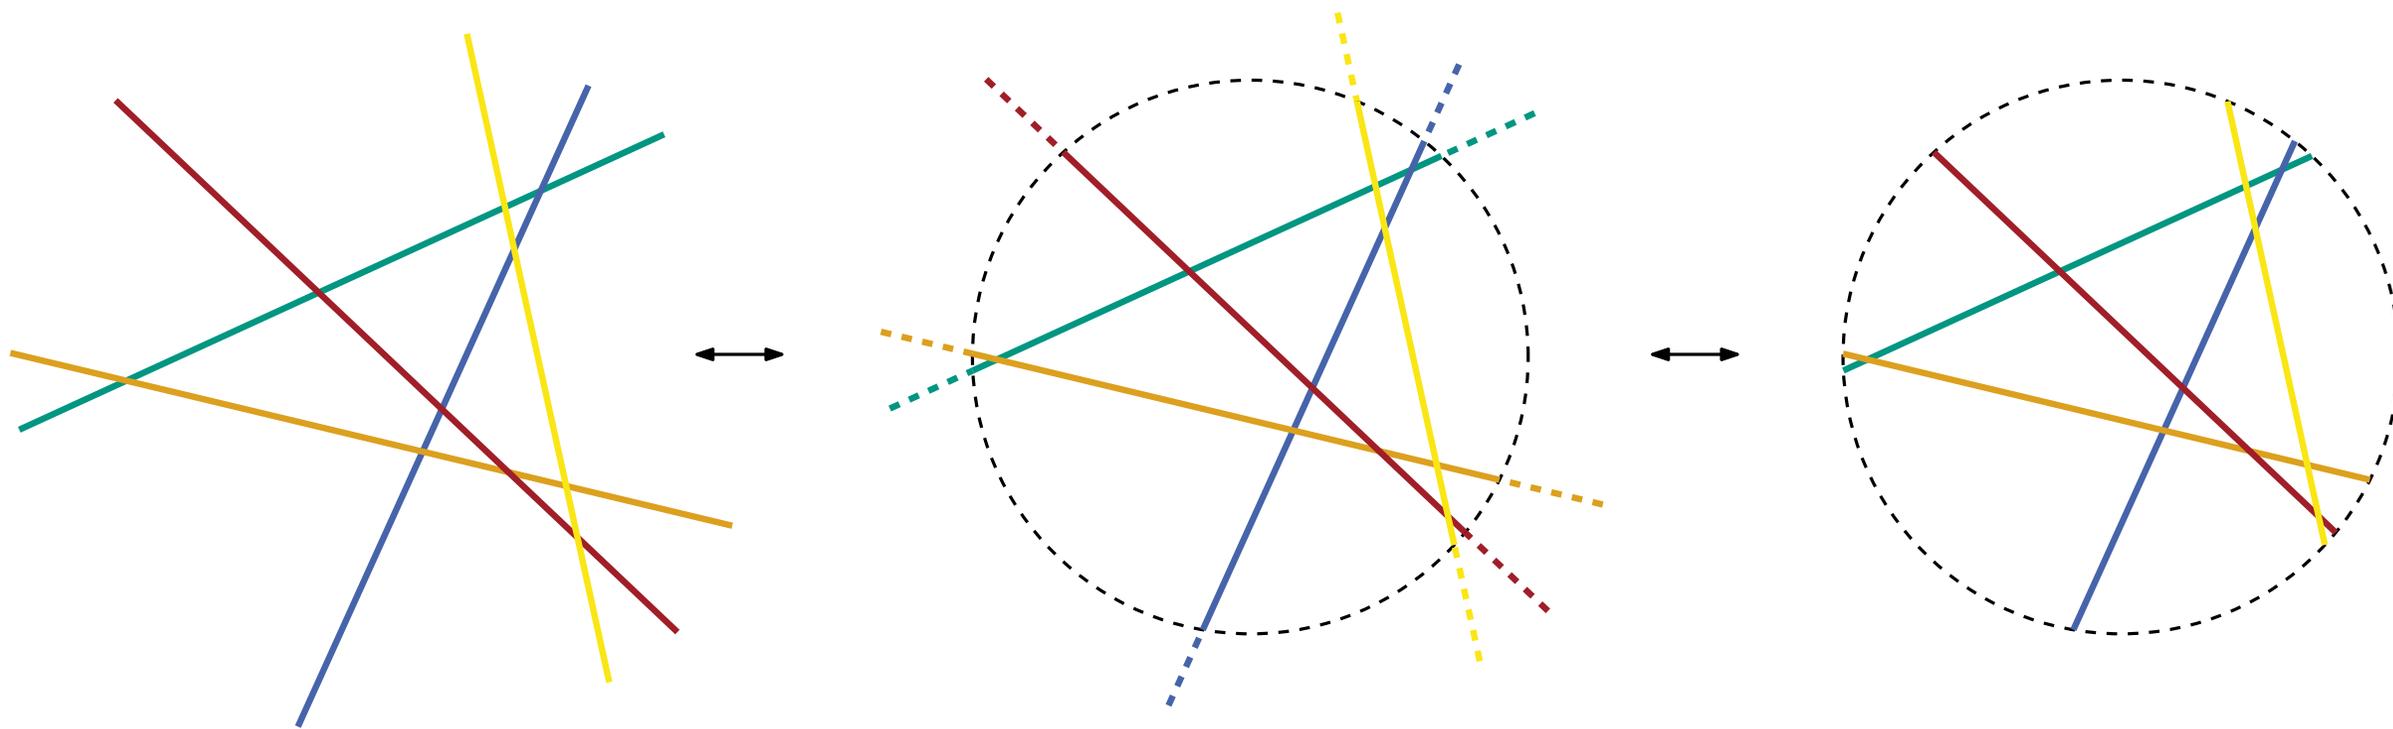
Menge von **Geraden**
mit gleicher Kombinatorik

Theorem: [Mnev 1988]
STRETCHABILITY ist
 $\exists\mathbb{R}$ -vollständig.

SimpleStretchability

- je zwei Geraden haben genau einen Schnittpunkt
- keine Dreifach Schnittpunkte

STRETCHABILITY in der hyperbolischen Ebene \mathbb{H}^2



Geraden in \mathbb{R}^2

Kreis um alle Schnittpunkte

Geraden in \mathbb{H}^2
(Beltrami-Klein Modell von \mathbb{H}^2)

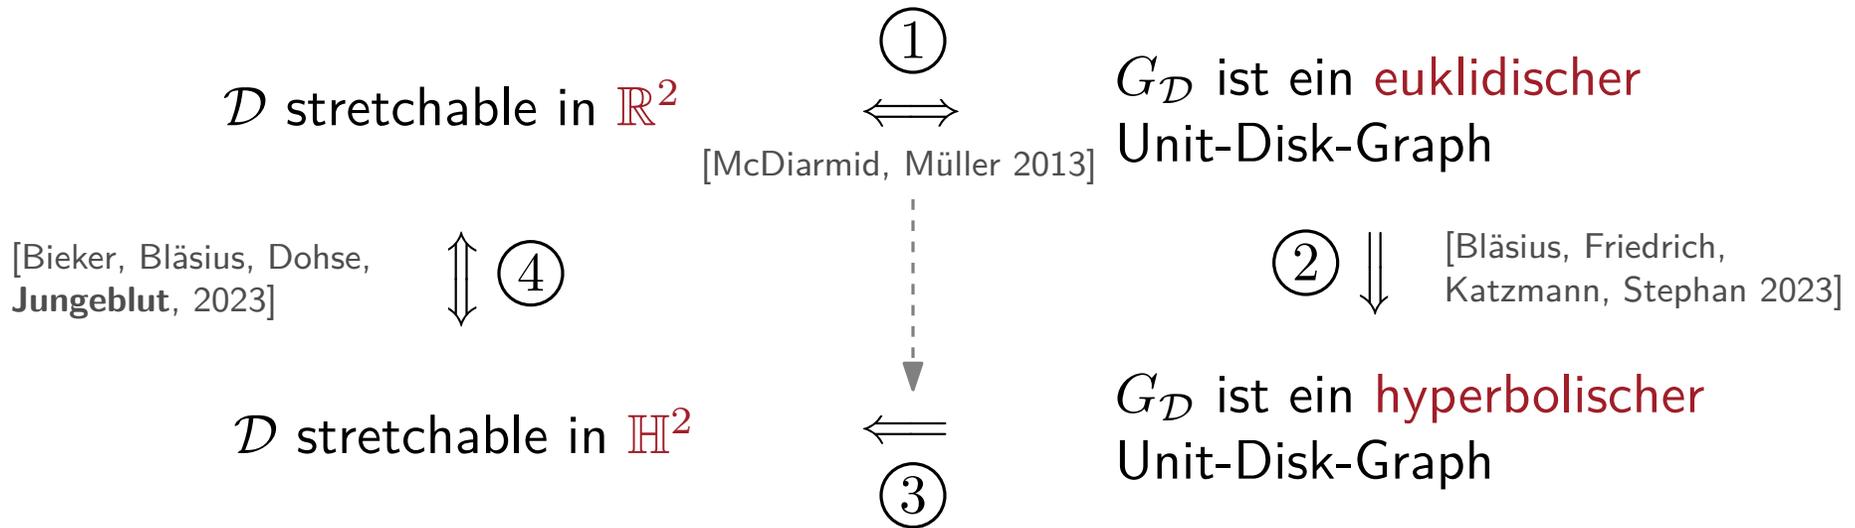
Framework für hyperbolische Unit-Disk-Graphen

Theorem: [McDiarmid, Müller 2013]

STRETCHABILITY kann in polynomieller Zeit auf das Erkennen von Unit-Disk-Graphen reduziert werden. $\rightsquigarrow \exists \mathbb{R}$ -schwer

\mathcal{D} - Instanz von SIMPLESTRETCHABILITY

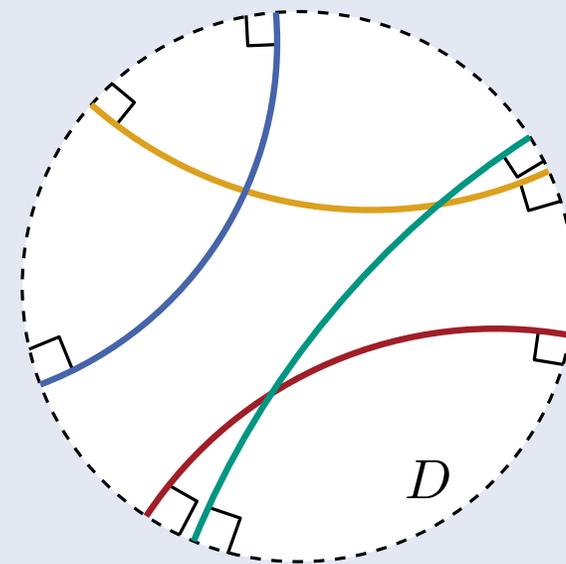
$G_{\mathcal{D}}$ - Graph, konstruiert aus \mathcal{D} nach McDiarmid + Müller (2013)



Lombardi und hyperbolische Geometrie

Poincaré Disk Modell:

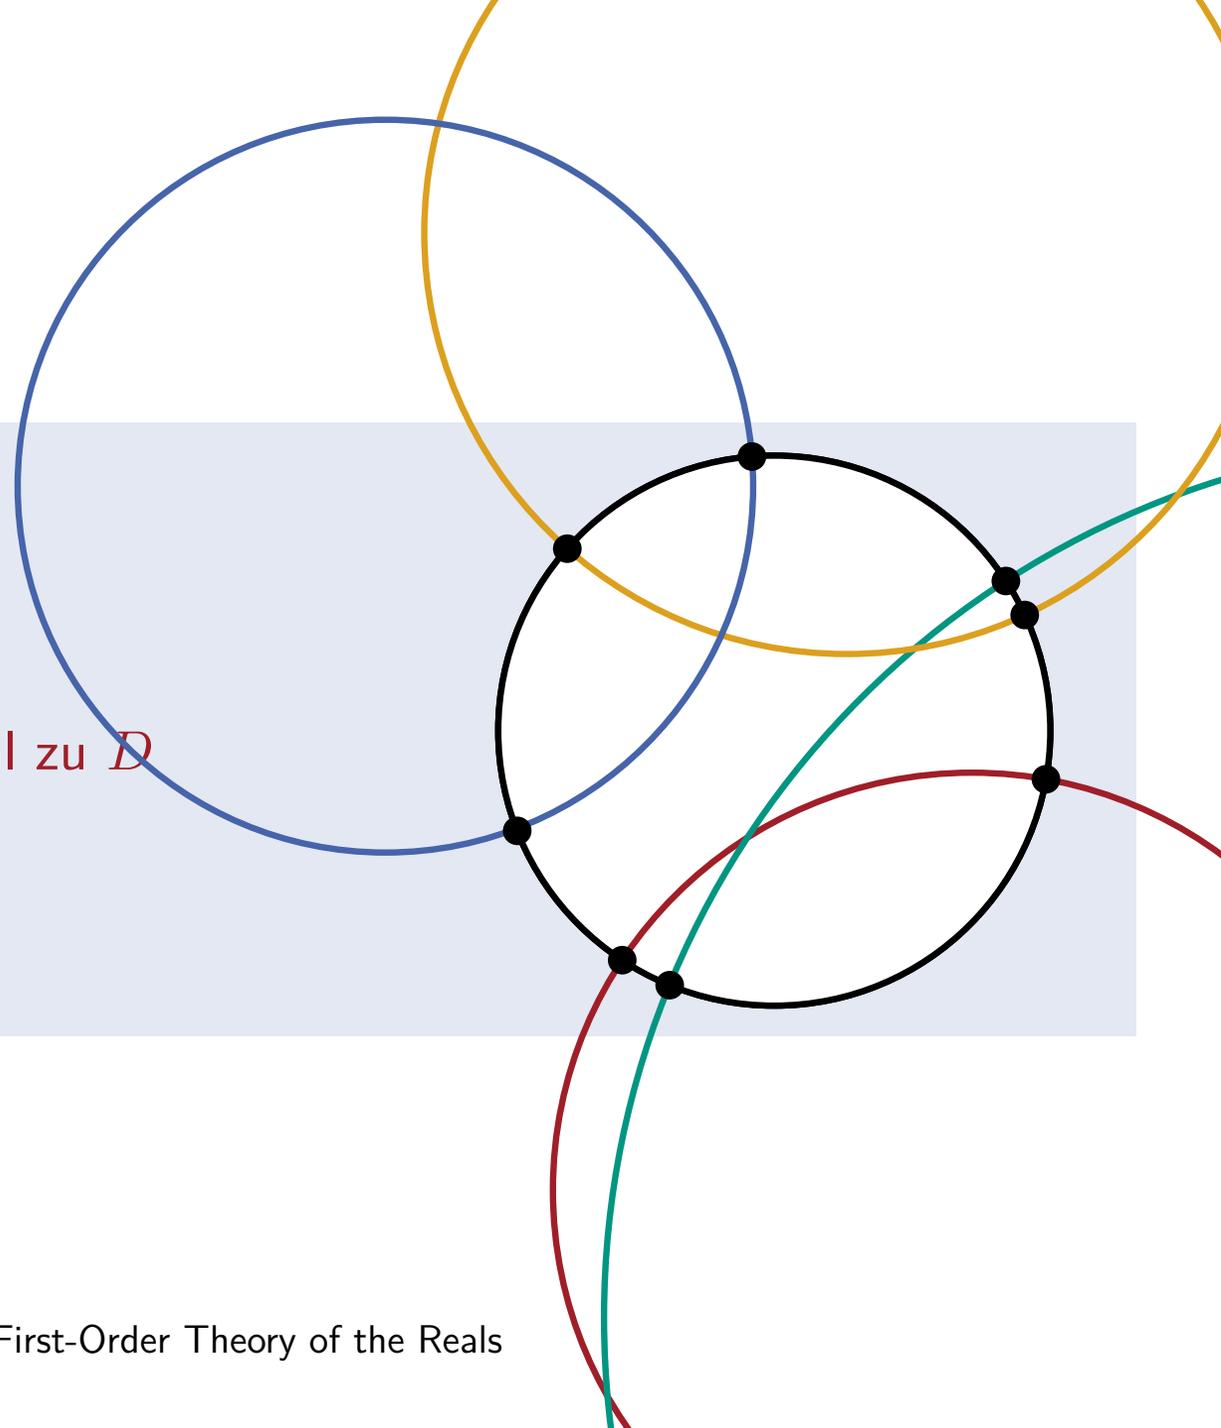
- bettet \mathbb{H}^2 in \mathbb{R}^2 ein
- \mathbb{H}^2 ist Inneres eines Einheitskreises D
- hyperbolische Geraden \rightsquigarrow **Kreisbögen orthogonal zu D**
- **Konform**: winkelerhaltend



Lombardi und hyperbolische Geometrie

Poincaré Disk Modell:

- bettet \mathbb{H}^2 in \mathbb{R}^2 ein
- \mathbb{H}^2 ist Inneres eines Einheitskreises D
- hyperbolische Geraden \leadsto Kreisbögen orthogonal zu D
- **Konform**: winkelerhaltend



Hausdorff-Distanz: $\forall\exists\mathbb{R}$ -Schwere (Skizze)

Eingabe: $\Phi := \forall X \in \mathbb{R}^n . \exists Y \in \mathbb{R}^m : \varphi(X, Y)$

Reduktion: $A := \{x \in \mathbb{R}^n \mid \exists Y \in \mathbb{R}^m : \varphi(x, Y)\} \subseteq \mathbb{R}^n$  alle x , für die
es ein Y gibt

$B := \mathbb{R}^n$

Hausdorff-Distanz: $\forall\exists\mathbb{R}$ -Schwere (Skizze)

Eingabe: $\Phi := \forall X \in \mathbb{R}^n . \exists Y \in \mathbb{R}^m : \varphi(X, Y)$

Reduktion: $A := \{x \in \mathbb{R}^n \mid \exists Y \in \mathbb{R}^m : \varphi(x, Y)\} \subseteq \mathbb{R}^n$  alle x , für die es ein Y gibt
 $B := \mathbb{R}^n$

Idee: Φ wahr $\rightsquigarrow A = \mathbb{R}^n \rightsquigarrow d_H(A, B) = 0$

Φ falsch $\rightsquigarrow A \subsetneq \mathbb{R}^n \rightsquigarrow d_H(A, B) > 0$

Hausdorff-Distanz: $\forall\exists\mathbb{R}$ -Schwere (Skizze)

Eingabe: $\Phi := \forall X \in \mathbb{R}^n . \exists Y \in \mathbb{R}^m : \varphi(X, Y)$

Reduktion: $A := \{x \in \mathbb{R}^n \mid \exists Y \in \mathbb{R}^m : \varphi(x, Y)\} \subseteq \mathbb{R}^n$

$B := \mathbb{R}^n$

←----- alle x , für die
es ein Y gibt

Idee: Φ wahr $\rightsquigarrow A = \mathbb{R}^n \rightsquigarrow d_H(A, B) = 0$

Φ falsch $\rightsquigarrow A \subsetneq \mathbb{R}^n \rightsquigarrow d_H(A, B) > 0$

$d_H(A, B) = 0$
 \iff
A und B haben
gleichen Abschluss

Problem 1:

nur ein einziges „ x ohne passendes Y “

$\not\Rightarrow d_H(A, B) > 0$

Hausdorff-Distanz: $\forall\exists\mathbb{R}$ -Schwere (Skizze)

Eingabe: $\Phi := \forall X \in \mathbb{R}^n . \exists Y \in \mathbb{R}^m : \varphi(X, Y)$

Reduktion: $A := \{x \in \mathbb{R}^n \mid \exists Y \in \mathbb{R}^m : \varphi(x, Y)\} \subseteq \mathbb{R}^n$
 $B := \mathbb{R}^n$

← alle x , für die
es ein Y gibt

Idee: Φ wahr $\rightsquigarrow A = \mathbb{R}^n \rightsquigarrow d_H(A, B) = 0$

Φ falsch $\rightsquigarrow A \subsetneq \mathbb{R}^n \rightsquigarrow d_H(A, B) > 0$

$d_H(A, B) = 0$
 \iff
 A und B haben
gleichen Abschluss

Problem 1:

nur ein einziges „ x ohne passendes Y “
 $\not\Rightarrow d_H(A, B) > 0$

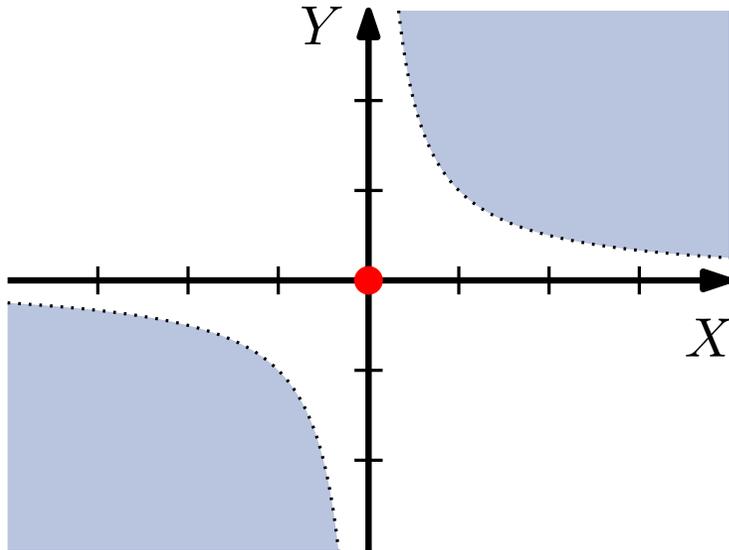
Problem 2:

Definition von A enthält
Existenzquantor \exists

Lösung 1: falsch und falscher

Idee: Falsche Formeln „noch falscher“ machen.

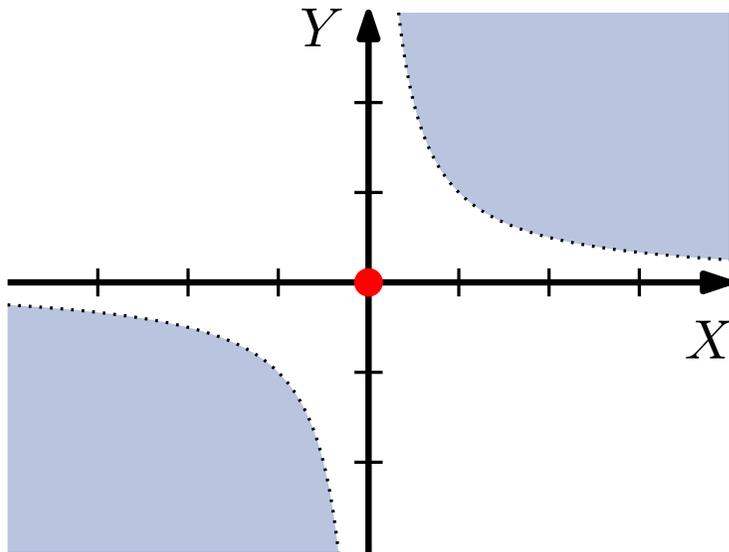
$$\forall X \in \mathbb{R} . \exists Y \in \mathbb{R} : XY > 1$$



Lösung 1: falsch und falscher

Idee: Falsche Formeln „noch falscher“ machen.

$$\forall X \in \mathbb{R} . \exists Y \in \mathbb{R} : XY > 1$$



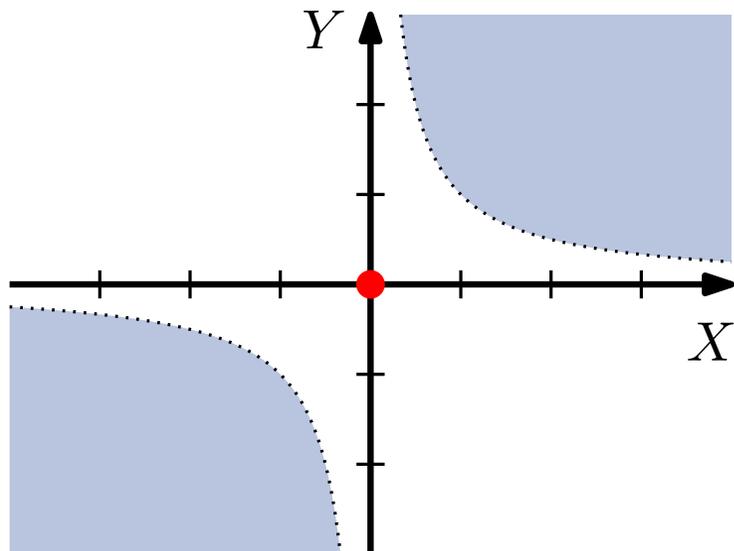
$$A = \mathbb{R} \setminus \{0\} \quad B = \mathbb{R}$$

$$\rightsquigarrow d_H(A, B) = 0$$

Lösung 1: falsch und falscher

Idee: Falsche Formeln „noch falscher“ machen.

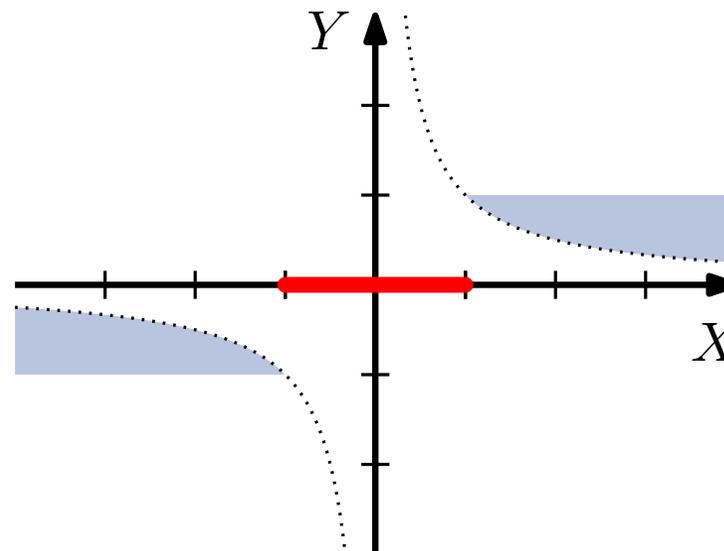
$$\forall X \in \mathbb{R} . \exists Y \in \mathbb{R} : XY > 1$$



$$A = \mathbb{R} \setminus \{0\} \quad B = \mathbb{R}$$

$$\rightsquigarrow d_H(A, B) = 0$$

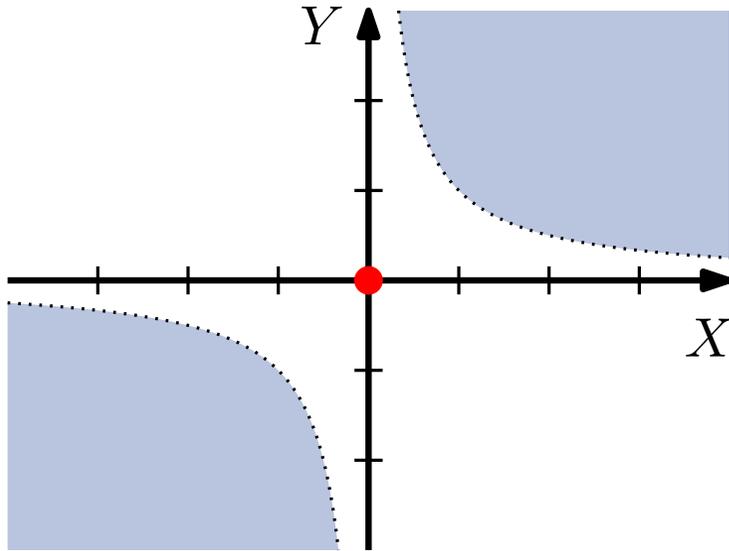
$$\forall X \in \mathbb{R} . \exists Y \in [-1, 1] : XY > 1$$



Lösung 1: falsch und falscher

Idee: Falsche Formeln „noch falscher“ machen.

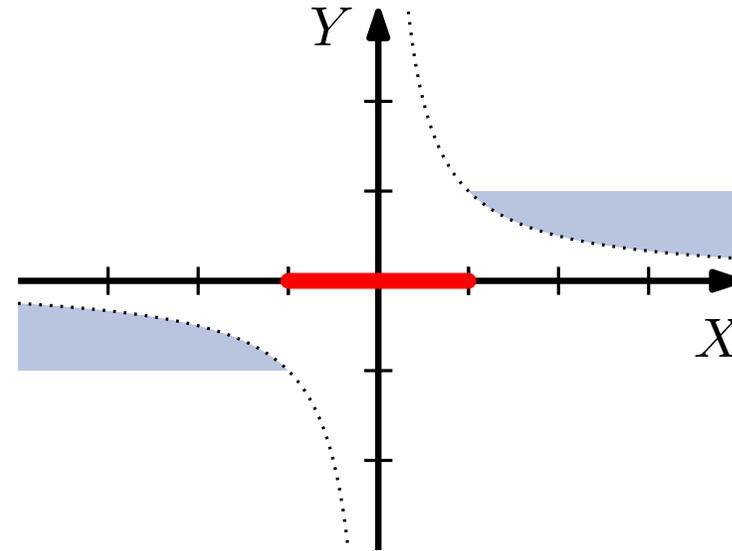
$$\forall X \in \mathbb{R} . \exists Y \in \mathbb{R} : XY > 1$$



$$A = \mathbb{R} \setminus \{0\} \quad B = \mathbb{R}$$

$$\rightsquigarrow d_H(A, B) = 0$$

$$\forall X \in \mathbb{R} . \exists Y \in [-1, 1] : XY > 1$$



$$A = \mathbb{R} \setminus [-1, 1] \quad B = \mathbb{R}$$

$$\rightsquigarrow d_H(A, B) = 1$$