

Quantitative Analyse neuronaler Netzwerke als universelle Funktionsapproximatoren

Stephan Trenn

Diplomarbeit - Zwischenverteidigung

Ilmenau, 4. Juli 2006

Gliederung



- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Grundstruktur des Multi-Layer-Perceptrons (MLP)




Ausgangsschicht

h -te Hidden-Schicht

⋮

1. Hidden-Schicht

Eingangsschicht



MLP als mathematisches Objekt



Definition MLP

Ein MLP ist ein Quadrupel $(h, \mathbf{n}, \sigma, \mathbf{P})$.

- h : Anzahl Hidden-Schichten
- $\mathbf{n} = (n_0, n_1, \dots, n_h)$: Anzahl Neuronen pro Schicht
 - n_0 : Anzahl Eingänge
 - n_1, \dots, n_h : Anzahl Neuronen in der jeweiligen Hidden-Schicht
- $\sigma : \mathbb{R} \rightarrow \mathbb{R}$: Aktivierungsfunktion innerhalb der Hidden-Neuronen
- $\mathbf{P} = (\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^h, \mathbf{w}^y)$: variable Netzwerkparameter
 - Kantengewichte
 - Schwellenwerte

MLP als mathematisches Objekt



Definition MLP

Ein MLP ist ein Quadrupel $(h, \mathbf{n}, \sigma, \mathbf{P})$.

- h : Anzahl Hidden-Schichten
- $\mathbf{n} = (n_0, n_1, \dots, n_h)$: Anzahl Neuronen pro Schicht
 - n_0 : Anzahl Eingänge
 - n_1, \dots, n_h : Anzahl Neuronen in der jeweiligen Hidden-Schicht
- $\sigma : \mathbb{R} \rightarrow \mathbb{R}$: Aktivierungsfunktion innerhalb der Hidden-Neuronen
- $\mathbf{P} = (\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^h, \mathbf{w}^y)$: variable Netzwerkparameter
 - Kantengewichte
 - Schwellenwerte

MLP als mathematisches Objekt



Definition MLP

Ein MLP ist ein Quadrupel $(h, \mathbf{n}, \sigma, \mathbf{P})$.

- h : Anzahl Hidden-Schichten
- $\mathbf{n} = (n_0, n_1, \dots, n_h)$: Anzahl Neuronen pro Schicht
 - n_0 : Anzahl Eingänge
 - n_1, \dots, n_h : Anzahl Neuronen in der jeweiligen Hidden-Schicht
- $\sigma : \mathbb{R} \rightarrow \mathbb{R}$: Aktivierungsfunktion innerhalb der Hidden-Neuronen
- $\mathbf{P} = (\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^h, \mathbf{w}^y)$: variable Netzwerkparameter
 - Kantengewichte
 - Schwellenwerte

MLP als mathematisches Objekt



Definition MLP

Ein MLP ist ein Quadrupel $(h, \mathbf{n}, \sigma, \mathbf{P})$.

- h : Anzahl Hidden-Schichten
- $\mathbf{n} = (n_0, n_1, \dots, n_h)$: Anzahl Neuronen pro Schicht
 - n_0 : Anzahl Eingänge
 - n_1, \dots, n_h : Anzahl Neuronen in der jeweiligen Hidden-Schicht
- $\sigma : \mathbb{R} \rightarrow \mathbb{R}$: Aktivierungsfunktion innerhalb der Hidden-Neuronen
- $\mathbf{P} = (\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^h, \mathbf{w}^y)$: variable Netzwerkparameter
 - Kantengewichte
 - Schwellenwerte

MLP als mathematisches Objekt




Definition MLP

Ein MLP ist ein Quadrupel $(h, \mathbf{n}, \sigma, \mathbf{P})$.

- h : Anzahl Hidden-Schichten
- $\mathbf{n} = (n_0, n_1, \dots, n_h)$: Anzahl Neuronen pro Schicht
 - n_0 : Anzahl Eingänge
 - n_1, \dots, n_h : Anzahl Neuronen in der jeweiligen Hidden-Schicht
- $\sigma : \mathbb{R} \rightarrow \mathbb{R}$: Aktivierungsfunktion innerhalb der Hidden-Neuronen
- $\mathbf{P} = (\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^h, \mathbf{w}^y)$: variable Netzwerkparameter
 - Kantengewichte
 - Schwellenwerte

MLP-Funktion


Hidden-Schicht-Neuron:




MLP-Funktion



Hidden-Schicht-Neuron:




Ausgangsneuron:

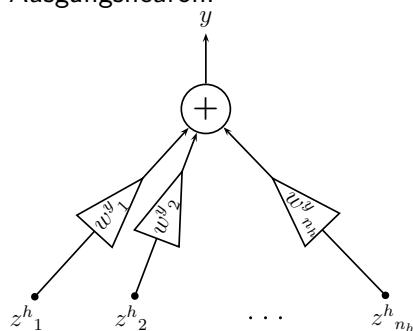


MLP-Funktion

Hidden-Schicht-Neuron:



Ausgangsneuron:



MLP-Funktion für fest gewählte Parameter

$$f_{\text{MLP}} : \mathbb{R}^{n_0} \rightarrow \mathbb{R}, \quad \mathbf{x} = (x_1, x_2, \dots, x_{n_0}) \mapsto y$$

Allgemeine Fragestellung



Problemstellung

Gegeben: Zielfunktion $f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$.

Gesucht: Ein MLP mit $f_{\text{MLP}} \approx f$.

Allgemeine Fragestellung



Problemstellung

Gegeben: Zielfunktion $f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$.

Gesucht: Ein MLP mit $f_{\text{MLP}} \approx f$.

In diesem Zusammenhang muss geklärt werden:

- Was bedeutet $f_{\text{MLP}} \approx f$ formal?
- Welche Art von Funktionen soll approximiert werden?
- Kann man mit fester Anzahl von Neuronen beliebig gut approximieren?
- Wie viele Neuronen braucht man mindestens, um mit einer vorgegeben Güte zu approximieren?

Allgemeine Fragestellung



Problemstellung

Gegeben: Zielfunktion $f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$.

Gesucht: Ein MLP mit $f_{\text{MLP}} \approx f$.

In diesem Zusammenhang muss geklärt werden:

- Was bedeutet $f_{\text{MLP}} \approx f$ formal?
- Welche Art von Funktionen soll approximiert werden?
- Kann man mit fester Anzahl von Neuronen beliebig gut approximieren?
- Wie viele Neuronen braucht man mindestens, um mit einer vorgegeben Güte zu approximieren?

Allgemeine Fragestellung



Problemstellung

Gegeben: Zielfunktion $f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$.

Gesucht: Ein MLP mit $f_{\text{MLP}} \approx f$.

In diesem Zusammenhang muss geklärt werden:

- Was bedeutet $f_{\text{MLP}} \approx f$ formal?
- Welche Art von Funktionen soll approximiert werden?
- Kann man mit fester Anzahl von Neuronen beliebig gut approximieren?
- Wie viele Neuronen braucht man mindestens, um mit einer vorgegeben Güte zu approximieren?

Allgemeine Fragestellung



Problemstellung

Gegeben: Zielfunktion $f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$.

Gesucht: Ein MLP mit $f_{\text{MLP}} \approx f$.

In diesem Zusammenhang muss geklärt werden:

- Was bedeutet $f_{\text{MLP}} \approx f$ formal?
- Welche Art von Funktionen soll approximiert werden?
- Kann man mit fester Anzahl von Neuronen beliebig gut approximieren?
- Wie viele Neuronen braucht man mindestens, um mit einer vorgegeben Güte zu approximieren?

Allgemeine Fragestellung



Problemstellung

Gegeben: Zielfunktion $f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$.

Gesucht: Ein MLP mit $f_{\text{MLP}} \approx f$.

In diesem Zusammenhang muss geklärt werden:

- Was bedeutet $f_{\text{MLP}} \approx f$ formal?
- Welche Art von Funktionen soll approximiert werden?
- Kann man mit fester Anzahl von Neuronen beliebig gut approximieren?
- Wie viele Neuronen braucht man mindestens, um mit einer vorgegeben Güte zu approximieren?

- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Relevanter Funktionenraum



Einschränkungen

- Zielfunktion: mindestens stetig
- Definitionsbereich: Einschränkung auf kompakte Menge $K \subseteq \mathbb{R}^{n_0}$, z.B. $K = [-1, 1]^{n_0}$, d.h. $x_1, x_2, \dots, x_{n_0} \in [-1, 1]$

Dieser Funktionenraum sei mit $C(K; \mathbb{R})$ bezeichnet.

Relevanter Funktionenraum



Einschränkungen

- Zielfunktion: mindestens stetig
- Definitionsbereich: Einschränkung auf kompakte Menge $K \subseteq \mathbb{R}^{n_0}$, z.B. $K = [-1, 1]^{n_0}$, d.h. $x_1, x_2, \dots, x_{n_0} \in [-1, 1]$

Dieser Funktionenraum sei mit $C(K; \mathbb{R})$ bezeichnet.

Im $C(K; \mathbb{R})$ kann man folgenden **Abstand** zwischen zwei Funktionen f_1 und f_2 definieren:

$$\|f_1 - f_2\| = \max_{\mathbf{x} \in K} |f_1(\mathbf{x}) - f_2(\mathbf{x})|$$

Definition

- $M \subseteq C(K; \mathbb{R})$ heißt **dicht** in $C(K; \mathbb{R})$
 $:\Leftrightarrow \forall \varepsilon > 0 \forall f \in C(K; \mathbb{R}) \exists f_M \in M:$

$$\|f - f_M\| < \varepsilon.$$

- $M \subseteq C(K; \mathbb{R})$ heißt **ε -dicht** in $C(K; \mathbb{R})$
 $:\Leftrightarrow \forall f \in C(K; \mathbb{R}) \exists f_M \in M:$

$$\|f - f_M\| < \varepsilon.$$

- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Generelle Approximationsfähigkeit von MLPs



Positives Resultat:

Theorem

Falls σ stetig und kein Polynom ist, dann ist die Menge aller MLP-Funktionen von MLPs mit einer Hidden-Schicht dicht in $C(K; \mathbb{R})$.

Generelle Approximationsfähigkeit von MLPs



Positives Resultat:

Theorem

Falls σ stetig und kein Polynom ist, dann ist die Menge aller MLP-Funktionen von MLPs mit einer Hidden-Schicht dicht in $C(K; \mathbb{R})$.

Problem dieses Resultats:

Struktur des approximierenden MLPs hängt von der Zielfunktion ab, d.h. keine allgemeingültige Schranke für die Anzahl der benötigten Hidden-Neuronen!

Approximationsfähigkeit bei fester MLP-Struktur



Negatives Resultat:

Vermutung

Die MLP-Funktionen von MLPs mit *einer Hidden-Schicht* und *fester Neuronen-Anzahl* liegen **nicht** ε -dicht in $C(K; \mathbb{R})$.

Approximationsfähigkeit bei fester MLP-Struktur



Negatives Resultat:

Vermutung

Die MLP-Funktionen von MLPs mit *einer Hidden-Schicht* und *fester Neuronen-Anzahl* liegen **nicht** ε -dicht in $C(K; \mathbb{R})$.

Aber:

Theorem

*Es gibt ein MLP mit **zwei** Hidden-Schichten, einer speziell gewählten Aktivierungsfunktion und einer festen Anzahl von Hidden-Neuronen, welches jede stetige Funktion beliebig gut approximieren kann.*

Approximationsfähigkeit bei fester MLP-Struktur



Negatives Resultat:

Vermutung

Die MLP-Funktionen von MLPs mit *einer Hidden-Schicht* und *fester Neuronen-Anzahl* liegen **nicht** ε -dicht in $C(K; \mathbb{R})$.

Aber:

Theorem

*Es gibt ein MLP mit **zwei** Hidden-Schichten, einer speziell gewählten Aktivierungsfunktion und einer festen Anzahl von Hidden-Neuronen, welches jede stetige Funktion beliebig gut approximieren kann.*

Problem: Die Aktivierungsfunktion ist **nicht realisierbar**.

Zu hohe Zielstellung?



Problem

Stetige Funktionen als Zielfunktionen noch zu allgemein!

Zu hohe Zielstellung?



Problem

Stetige Funktionen als Zielfunktionen noch zu allgemein!

Mögliche Verschärfungen:

- Differenzierbarkeit der Zielfunktionen
- Beschränktheit der Zielfunktion und deren Ableitungen

Gliederung



- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Taylorpolynome



Theorem (Satz von Taylor)


Für eine genügend oft differenzierbare Funktion $f : K \rightarrow \mathbb{R}$ gilt:

$$f(x) = \underbrace{\sum_{k=0}^N \frac{f^{(k)}(0)}{k!} x^k}_{\mathcal{I}_N\{f\}(x)} + \frac{f^{(N+1)}(\xi)}{(N+1)!}$$

für $N \in \mathbb{N}$ und ein $\xi \in K$.

Bemerkung: $n_0 > 1 \Rightarrow f^{(k)}(0)$ ist Tensor k -ter Ordnung.

Beispiel Taylorpolynome



Idee

- 1 $\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Rightarrow f \approx f_{\text{MLP}}$
- 2 Ordnung des Taylorpolynoms \leftrightarrow Maß für Approximationsgüte

Gliederung



- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Analytische Funktionen



Definition

$f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$ heißt *analytisch* in 0

$:\Leftrightarrow$

$\exists \delta > 0 : \mathcal{T}_N\{f\}(x) \xrightarrow{N \rightarrow \infty} f(x)$ für alle $\|x\| < \delta$.

Das größte δ heißt *Konvergenzradius*.

Analytische Funktionen



Definition

$f : \mathbb{R}^{n_0} \rightarrow \mathbb{R}$ heißt *analytisch* in 0

$:\Leftrightarrow$

$\exists \delta > 0 : \mathcal{T}_N\{f\}(x) \xrightarrow{N \rightarrow \infty} f(x)$ für alle $\|x\| < \delta$.

Das größte δ heißt *Konvergenzradius*.

Beispiele:

- Sinus ist analytisch in 0 mit $\delta = \infty$.
- Die Funktion $x \mapsto \frac{1}{x-1}$ ist analytisch in 0 mit $\delta = 1$.
- Die Funktion $x \mapsto \begin{cases} 0, & x \leq 0, \\ e^{-1/x}, & x > 0, \end{cases}$ ist **nicht** analytisch in 0.

Approximationsordnung



Theorem

Sei $f : [-1, 1]^{n_0} \rightarrow \mathbb{R}$ analytisch in 0 mit Konvergenzradius $\delta > 1$.
Dann gilt:

$$\forall \varepsilon > 0 \exists N \in \mathbb{N} : \|\mathcal{T}_N\{f\} - f\| < \varepsilon$$

Approximationsordnung



Theorem

Sei $f : [-1, 1]^{n_0} \rightarrow \mathbb{R}$ analytisch in 0 mit Konvergenzradius $\delta > 1$.
Dann gilt:

$$\forall \varepsilon > 0 \exists N \in \mathbb{N} : \|\mathcal{I}_N\{f\} - f\| < \varepsilon$$

Folgerung

Seien f und f_{MLP} beide analytisch in 0 mit Konvergenzradius $\delta > 1$, dann gibt es für alle $\varepsilon > 0$ ein $N \in \mathbb{N}$ so dass

$$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Rightarrow \|f - f_{\text{MLP}}\| < \varepsilon$$

Gliederung



- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Vorgabe

Ordnung N und Forderung dass $\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\}$.

Ansatz



Vorgabe

Ordnung N und Forderung dass $\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\}$.

Frage:

Welche Voraussetzung muss MLP erfüllen, damit Vorgabe erfüllt werden kann?

Ansatz



Vorgabe

Ordnung N und Forderung dass $\mathcal{T}_N\{f\} = \mathcal{T}_N\{f_{\text{MLP}}\}$.

Frage:

Welche Voraussetzung muss MLP erfüllen, damit Vorgabe erfüllt werden kann?

Beispiel für $n_0 = 1$ und $N = 3$:

$$\mathcal{T}_3\{f\}(x) = a_0 + a_1x + a_2x^2 + a_3x^3$$

und

$$\mathcal{T}_3\{f_{\text{MLP}}\}(x) = b_0 + b_1x + b_2x^2 + b_3x^3.$$

Nichtlineares Gleichungssystem



Eigenschaft von Polynomen

$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Leftrightarrow$ alle Koeffizienten stimmen überein.

Nichtlineares Gleichungssystem



Eigenschaft von Polynomen

$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Leftrightarrow$ alle Koeffizienten stimmen überein.

Im Beispiel - Gleichungssystem mit 4 Gleichungen:

$$a_0 = b_0$$

$$a_1 = b_1$$

$$a_2 = b_2$$

$$a_3 = b_3$$

Nichtlineares Gleichungssystem



Eigenschaft von Polynomen

$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Leftrightarrow$ alle Koeffizienten stimmen überein.

Im Beispiel - Gleichungssystem mit 4 Gleichungen:

$$a_0 = b_0(\mathbf{P})$$

$$a_1 = b_1(\mathbf{P})$$

$$a_2 = b_2(\mathbf{P})$$

$$a_3 = b_3(\mathbf{P})$$

Nichtlineares Gleichungssystem



Eigenschaft von Polynomen

$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Leftrightarrow$ alle Koeffizienten stimmen überein.

Im Beispiel - Gleichungssystem mit 4 Gleichungen:

$$a_0 = b_0(\mathbf{P})$$

$$a_1 = b_1(\mathbf{P})$$

$$a_2 = b_2(\mathbf{P})$$

$$a_3 = b_3(\mathbf{P})$$

Erinnerung: $\mathbf{P} = (w^1, w^2, \dots, w^h, w^y)$
(Kantengewichte und Schwellenwerte)

Abstraktere Sichtweise



Nichtlineares Gleichungssystem

$$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Leftrightarrow \mathbf{a} = \mathfrak{K}(\mathbf{P})$$

- $\mathfrak{K} : \mathbb{R}^{|\mathbf{P}|} \rightarrow \mathbb{R}^G$
- $|\mathbf{P}|$: Anzahl der variablen Netzwerkparameter, abhängig von h und \mathbf{n} .
- G : Anzahl Gleichungen = Anzahl Koeffizienten im Taylorpolynom

Abstraktere Sichtweise



Nichtlineares Gleichungssystem

$$\mathcal{I}_N\{f\} = \mathcal{I}_N\{f_{\text{MLP}}\} \Leftrightarrow \mathbf{a} = \mathfrak{K}(\mathbf{P})$$

- $\mathfrak{K} : \mathbb{R}^{|\mathbf{P}|} \rightarrow \mathbb{R}^G$
- $|\mathbf{P}|$: Anzahl der variablen Netzwerkparameter, abhängig von h und \mathbf{n} .
- G : Anzahl Gleichungen = Anzahl Koeffizienten im Taylorpolynom

Notwendige Forderung

\mathfrak{K} muss surjektiv sein.

Gliederung



- 1 Qualitative Approximation
 - Das Multi-Layer-Perceptron (MLP)
 - Abstandsmessung zwischen Funktionen und Dichtheit
 - Dichtheitsaussagen für MLPs
- 2 Taylorpolynome
 - Taylerreihenentwicklung
 - Analytische Funktionen
- 3 Notwendige Anzahl von Hidden-Neuronen
 - Lösbarkeit von mehrdimensionalen Gleichungen
 - (Geplante) Ergebnisse der Diplomarbeit

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Weitere geplante Ergebnisse:

- Konkrete Beispiele zum Aufzeigen der Möglichkeiten und Grenzen des Ansatzes.
- Experimentelle Untersuchung anderer Aktivierungsfunktionen.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Weitere geplante Ergebnisse:

- Konkrete Beispiele zum Aufzeigen der Möglichkeiten und Grenzen des Ansatzes.
- Experimentelle Untersuchung anderer Aktivierungsfunktionen.

Ergebnisse



Bisher erhaltene Ergebnisse:

- Notwendige Mindestzahl von Hidden-Neuronen kann berechnet werden!
- Auch die Anzahl der Hiddenschichten und die Verteilung der Neuronen darin kann bestimmt werden.
- Nebenergebnis: Mehr als zwei Hidden-Schichten sind nicht sinnvoll.
- Die klassische Aktivierungsfunktion ist nicht gut geeignet.

Weitere geplante Ergebnisse:

- Konkrete Beispiele zum Aufzeigen der Möglichkeiten und Grenzen des Ansatzes.
- Experimentelle Untersuchung anderer Aktivierungsfunktionen.