

Neuronentyp	Netzeingabefunktion	Aktivierungsfunktion	Ausgabefunktion	Bemerkung
Schwellenwertelement	$f_{\text{net}}(\vec{x}, \vec{w}) = \sum_i w_i \cdot x_i$	$f_{\text{act}}(\text{net}, \theta) = \begin{cases} 1 & \text{falls } \text{net} \geq \theta, \\ 0 & \text{sonst} \end{cases}$	$f_{\text{out}}(\text{act}) = \text{act}$	
versteckte Neuronen im MLP	$f_{\text{net}}(\vec{x}, \vec{w}) = \sum_i w_i \cdot x_i$	<p>sigmoide Funktionen z.B.</p> <p>Sprungfunktion:</p> $f_{\text{act}}(\text{net}, \theta) = \begin{cases} 1, & \text{falls } \text{net} \geq \theta, \\ 0, & \text{sonst} \end{cases}$ <p>semi-lineare Funktion:</p> $f_{\text{act}}(\text{net}, \theta) = \begin{cases} 1, & \text{falls } \text{net} \geq \theta + \frac{1}{2}, \\ 0, & \text{falls } \text{net} \geq \theta - \frac{1}{2}, \\ (\text{net} - \theta + \frac{1}{2}), & \text{sonst} \end{cases}$ <p>Sinus bis Sättigung:</p> $f_{\text{act}}(\text{net}, \theta) = \begin{cases} 1, & \text{falls } \text{net} \geq \theta + \frac{\pi}{2}, \\ 0, & \text{falls } \text{net} \geq \theta - \frac{\pi}{2}, \\ \frac{\sin(\text{net}-\theta)+1}{2}, & \text{sonst} \end{cases}$ <p>logistische Funktion (gewöhnlich verwendet):</p> $f_{\text{act}}(\text{net}, \theta) = \frac{1}{1+e^{-(\text{net}-\theta)}}$ <p>tangens hyperbolicus:</p> $f_{\text{act}}(\text{net}, \theta) = \tanh(\text{net} - \theta)$	$f_{\text{out}}(\text{act}) = \text{act}$	logistische Aktivierungsfunktion erlaubt Training mittels Backpropagation
Ausgabeneuron im MLP	$f_{\text{net}}(\vec{x}, \vec{w}) = \sum_i w_i \cdot x_i$	<p>sigmoide Funktion oder linear, d.h.</p> $f_{\text{act}}(\text{net}, \theta) = a \cdot \text{net} - \theta.$	$f_{\text{out}}(\text{act}) = \text{act}$	
versteckte Neuronen in RBF-Netzen	<p>Distanzfunktion, z.B.</p> $f_{\text{net}}(\vec{x}, \vec{w}) = \left(\sum_i (x_i - w_i)^k \right)^{\frac{1}{k}};$ <p>$k \in \mathbb{N}$</p>	<p>radiale Funktionen z.B.</p> <p>Rechteckfunktion:</p> $f_{\text{act}}(\text{net}, \sigma) = \begin{cases} 1, & \text{falls } \text{net} \leq \sigma, \\ 0, & \text{sonst} \end{cases}$ <p>Dreieckfunktion:</p> $f_{\text{act}}(\text{net}, \sigma) = \begin{cases} 1 - \frac{\text{net}}{\sigma}, & \text{falls } \text{net} \leq \sigma, \\ 0, & \text{sonst} \end{cases}$ <p>Kosinus bis Null:</p> $f_{\text{act}}(\text{net}, \sigma) = \begin{cases} \frac{\cos(\frac{\pi}{2\sigma}\text{net})+1}{2}, & \text{falls } \text{net} \leq 2\sigma, \\ 0, & \text{sonst} \end{cases}$ <p>Gaußsche Funktion:</p> $f_{\text{act}}(\text{net}, \sigma) = e^{-\frac{\text{net}^2}{2\sigma^2}}$	$f_{\text{out}}(\text{act}) = \text{act}$	

Neuronentyp	Netzeingabefunktion	Aktivierungsfunktion	Ausgabefunktion	Bemerkung
Ausgabeneuronen in RBF-Netzen	$f_{\text{net}}(\vec{x}, \vec{w}) = \sum_i w_i \cdot x_i$	$f_{\text{act}}(\text{net}, \theta) = \text{net} - \theta$	$f_{\text{out}}(\text{act}) = \text{act}$	
Neuronen in SOMs (Ausgabeschicht)	Abstandsfkt. (wie verst. Neuronen in RBF-Netzen)	monoton fallende Fkt. (wie verst. Neuronen in RBF-Netzen)	$f_{\text{out}}(\text{act}) = \text{act}$	Verwendung von "winner takes it all"-Diskretisierung bei Berechnung von Aktualisierungen; Nachbarschaftsbeziehung über Ausgabeneuronen definiert und Aktualisierungen berücksichtigt
Neuronen in Hopfield Netzen	$f_{\text{net}}(\vec{x}, \vec{w}) = \sum_i w_i \cdot x_i$	$f_{\text{act}}(\text{net}, \theta) = \begin{cases} 1, & \text{falls } \text{net} \geq \theta, \\ -1, & \text{sonst} \end{cases}$	$f_{\text{out}}(\text{act}) = \text{act}$	