

## 5 Zusammenfassung

Die Approximation ein-dimensionaler Funktionen durch neuronale Netze kann durch unterschiedliche Methoden erreicht werden. Breite neuronale Netze benötigen bei der selber Parameteranzahl einen höheren Rechenaufwand als tiefe neuronale Netze und sind empfindlich bezüglich der Initialisierung der Parameter. Tiefe neuronale Netze können durch die Aneinanderreihung von versteckten Schichten komplexe Muster erstellen, mit denen eine Funktion dargestellt werden kann. Insbesondere tiefe Neuronale Netze sind empfindlich bezüglich der Wahl von Aktivierungsfunktionen. Es wurde beobachtet, dass Probleme bei der Verwendung der Sigmoid-Aktivierungsfunktion auftreten können, jedoch können diese durch den Austausch durch die Leaky ReLU Aktivierungsfunktion gelöst werden.

Es wurde gezeigt, dass tiefe neuronale Netze gute Approximationen liefern können. Sie sind in ihrer Vorhersagegenauigkeit bei Daten mit Rauschen vergleichbar mit der kubischen Smoothing Spline. Leider ist der Rechenaufwand von tiefen neuronalen Netzen im Vergleich zur kubischen Smoothing Spline hoch. Ein tiefes neuronales Netz mit Skip Connections stellt eine gute Möglichkeit dar, bei hohen Rauschwerten deutlich bessere Ergebnisse zu erzielen als es mit einer kubischen Smoothing Spline der Fall ist. Besonders bei geringen Datenmenge scheint ein ResNet eine gute Approximation zu erzielen.

Neuronale Netze mit mehreren Ein- und Ausgängen sind für die Approximation ein-dimensionaler Funktionen weniger geeignet. Zum Schluss wurden die Approximationseigenschaften von stetigen und unstetigen Aktivierungsfunktionen bezüglich diskontinuierlicher Funktionen untersucht. Aktivierungsfunktionen sind ein wichtiger Bestandteil von Architekturen, da nur mit ihnen ein Netzwerk genutzt werden kann. Es wurde gezeigt, dass die Kombination verschiedener Aktivierungsfunktionen bei kleinen neuronalen Netzen Vorteile haben kann.