

Räumliche Positionsermittlung von Objekten mittels Neuroprozessor

Künstliche neuronale Netzwerke (KNN), die in analoger zeitkontinuierlicher Schaltungstechnik realisiert sind, bieten gegenüber sequenziell arbeitenden Schaltungen (wie CPUs) und Softwarelösungen bei vielen Anwendungsproblemen enorme Vorteile. Zum einen lassen sich hohe Verarbeitungsgeschwindigkeiten erreichen, die aufgrund der massiven Parallelität der Verarbeitungsstrukturen und der Analogtechnik entstehen. Zum anderen sind durch KNN bei vielen Problemen, für die z. B. keine Modelle oder Algorithmen bekannt sind, überhaupt erst Lösungen möglich.

Neuroprozessor

Ein solcher als IP4 bezeichneter analoger Neuroprozessor wird von der Fa. Neurosystems GmbH in Rostock entwickelt. Dieser IC besitzt für zeitkritische Assoziations-, Klassifikations- oder Erkennungsanwendungen hervorragende Eigenschaften. Das Netzwerk des IC's ist dreischichtig. Die Muster werden nach dem Backpropagation-Algorithmus erlernt. Der IC besitzt einen integrierten digitalen Controller, mit dessen Hilfe die gesamte Steuerung des Lernalgorithmus und der IC-Funktionalität erfolgt (Bild 1).




Bild 1: Neuroprozessor IP4 (Fa. Neurosystems GmbH)

Objekterkennung

Eine in Zusammenarbeit mit der Universität Rostock simulierte Anwendung für den IP4 ist die Positionsbestimmung von Objekten (Kopf) in Fahrzeugen zur gezielten Airbagsteuerung. Hierbei kommt es auf minimale Reaktionszeiten und Störsicherheit bei der Signalverarbeitung an. Der überwachte Raum wird hierfür in X-Y-Richtung durch ein 10x10-Raster diskreti-

siert. Die Einteilung der Z-Richtung (Tiefe) erfolgt in fünf Ebenen, wobei die nullte Ebene dem Hintergrund zugeordnet wird. Die Tiefeninformation lässt sich in der Amplitude der Eingangssignale kodieren. Auf diese Weise können die 10x10-Bildpunkt-signale direkt mit den 100 Eingängen des IC's verbunden werden. Der Bildsensor funktioniert dabei wie die Retina eines Auges. Die relativ geringe Rasterauflösung ist für diese Anwendung ausreichend (ca. 20 cm in der Tiefe und ca. 10 cm seitlich), da die Airbagsteuerung keine höhere Genauigkeit erreicht.

Lernen der Muster

Als Objekt wurde ein Quadrat (5 x 5) gewählt, welches in erster Näherung einem Kopf entsprechen soll (Bild 2). Durch die Rasterung und die gewählte Objektgröße ergeben sich 144 mögliche Positionen des Objektes im Raum (ohne Hintergrund), die dem Netzwerk als 144 verschiedene Muster an den Eingängen präsentiert werden.

Die Anzahl der Verarbeitungseinheiten (Knoten) in der so genannten verborgenen Schicht des KNN hat wesentlichen Einfluss auf die Eigenschaften der Signalverarbeitung (Generalisierungsvermögen, Lernfähigkeit). Daher wurde durch Simulationen versucht, eine günstige Anzahl an Knoten in der verborgenen Schicht für diese Anwendung zu ermitteln. Dazu wurden der mittlere quadratische Fehler (MSE) sowie der maximale Fehler eines einzelnen Ausganges (abs E) über eine sehr lange Lernphase von 100.000 Epochen aufgezeichnet und die minimal erreichten Werte als Funktion der Anzahl an verborgenen Knoten dargestellt (Bild 3).




Bild 2: Diskretisierung des Objekt-raumes

Es zeigte sich, dass ab ca. 40 Knoten bei beiden Fehlertypen keine wesentliche Verbesserung mehr eintrat. Da die Generalisierungsfähigkeit bei abnehmender Zahl von Knoten in der verborgenen Schicht steigt, ist es sinnvoll, ihre Anzahl gering zu halten. In den Simulationen wurden mit 50 Einheiten gute Ergebnisse erzielt.

Erkennung gestörter Bilder

Ein wesentliches Merkmal der Signalverarbeitung mit KNN ist die Fähigkeit, gelernte Musterzuordnungen zu generalisieren, so dass auch gestörte Bilder richtig zugeordnet werden können. Bei der Bewertung wurden maximale Positionsabweichungen von 2 Rastern in der X-Y-Richtung und einer Tiefenebene zugelassen. Die Ergebnisse der Simulationen ergaben geringe Fehlerraten bei Störung der Eingangsbilder mit bis zu 10 Prozent Rauschen (siehe Tabelle).

Bildstörung in %	mittlere Fehlerraten in %		
	X	Y	Z
2,5	0	0	0
5	0	0	0,3
7,5	0,1	0	3
10	0,3	0,4	8
12,5	1	1,6	17,3

Künstliche neuronale Netzwerke bieten bei der Bildverarbeitung gegenüber herkömmlichen Systemen prinzipbedingte Vorteile. Durch den Einsatz von Hardwarelösungen ergeben sich Echtzeitfähigkeiten bei komplexen Verarbeitungsfunktionen. Die Fähigkeit von KNN erlernte Muster zu generalisieren, wirkt sich besonders günstig auf eine robuste und störsichere Signalverarbeitung aus.

Bild 3: Fehler in Abhängigkeit der Knoten in der verborgenen Schicht des KNN

Universität Rostock

Dr.-Ing. Ansgar Wego
 Fachbereich ETIT
 Albert-Einstein-Straße 2, 18059 Rostock
 Tel.: 0381/4 98 35 02
 wego@warnow.e-technik1.uni-rostock.de