

*Motorprüfstand mit Lambda-Sensoren im Abgaskrümm.*



Neuronale Netze für

# Optim Luft-Kraftstoff-

Ein optimales Luft-Kraftstoff-Gemisch stellt eine große Herausforderung dar und ist somit immer wieder ein Thema im Bereich der Motorsteuerung. Seit den 80er Jahren motiviert der Übergang von Vergasern auf elektronisch gesteuerte Einspritzsysteme immer wieder zu neuen Forschungen auf diesem Gebiet. Das richtige Luft-Kraftstoff-Gemisch erhöht die Leistungsfähigkeit von Dreiwegekatalysatoren sowohl im Dauerbetrieb als auch bei Einschaltvorgängen und spielt daher eine entscheidende Rolle bei der Begrenzung des Schadstoffausstoßes von Ottomotoren, Magermotoren und Motoren mit Benzindirekteinspritzung.

Luft-Kraftstoff-Gemisch, geregelt mit der MicroAutoBox

# ales -Gemisch

## Anforderungen an die Steuerung des Luft-Kraftstoff-Gemisches

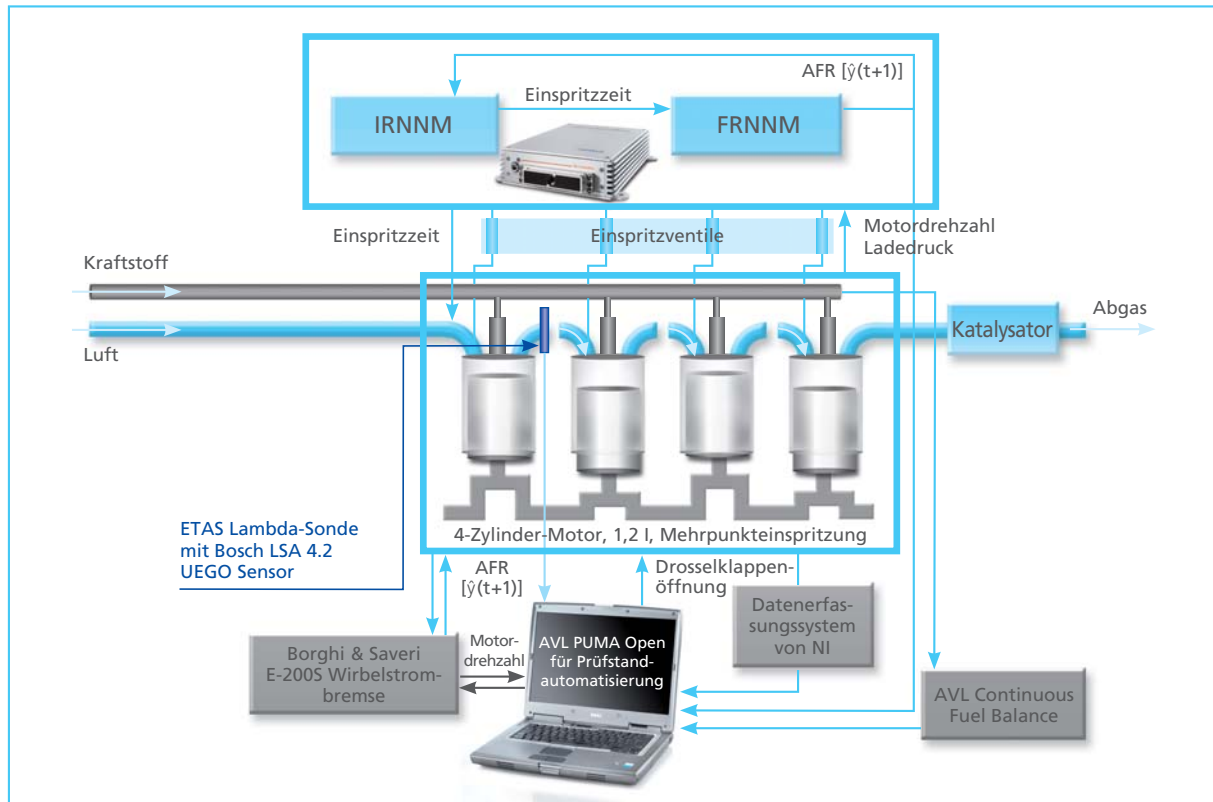
Trotz des stetig hohen Aufwands, die Abgasemissionen einzuschränken, stellt ein gutes Luft-Kraftstoff-Gemisch aufgrund der immer strenger werden den weltweiten Umweltgesetze immer noch eine große Herausforderung dar. Darüber hinaus müssen sich Entwicklungsingenieure mit den Anforderungen der Onboard-Diagnose auseinandersetzen, die 1996 in den USA und später auch in Europa eingeführt wurde. Diese bildet ein entscheidendes Ziel im Bereich der automotiven Regelungen, da sie eine stetige Überwachung aller Antriebsstrangkompo-

nenten erfordert, um Fehler im Abgassystem zu vermeiden. Die Regelung eines Luft-Kraftstoff-Gemisches (Air-fuel Ratio, AFR) basiert zurzeit auf einer Mittelwertdarstellung des Motormodells. Allerdings bringen die Mittelwertmodelle beträchtliche Einschränkungen mit sich, zum Beispiel den hohen experimentellen Aufwand für die Parameteridentifikation oder für die intrinsischen nicht anpassbaren Funktionen. Auf der anderen Seite ist die Verzögerung des AFR-Signals ein weiterer wichtiger Faktor für leistungsfähigere Regelstrategien im geschlossenen Regelkreis. Die neuronalen Netze stellen einen vielverspre-

chenden Lösungsansatz dieser Problematik dar. Sie verfügen über hohe Mapping-Fähigkeiten und sind auch mit wenigen Identifikationsdaten gut verständlich. Zudem können wir durch die Implementierung adaptiver Lernprozesse die äußeren Einflüsse auf die Leistung der Regelung einbeziehen.

## Entwickelte Regelstrategie

Die AFR-Regelstrategie basiert auf einem rekurrenten neuronalen Netz (RNN). Das neuronale Netz wird als Regler eingesetzt, dessen Ausgaben sich direkt auf die Regelvorgänge auswirken. Wir entwickelten ein Forward-RNN-Modell (FRNNM) der



Experimentaufbau mit dem Regler:

Die Regelstrategie besteht aus zwei RNNs zur Beschreibung der inversen (IRNNM) und Forward (FRNNM)-Dynamik.

AFR-Dynamik und berücksichtigten dabei, dass die dynamischen Prozesse, die die AFR-Reaktion beeinflussen, sowohl von der Dynamik der Luft als auch von der des Kraftstoffs abhängen. Die externen Eingangs-, Ausgangs- und Regelgrößen sind AFR, Einspritzzeitpunkt, Motordrehzahl und Ladedruck. Die Rückkopplungen werden vom Netz selbst simuliert, so dass das FRNNM keine AFR-Messung für die Online-Bewertung benötigt. Daher ist der Regler optimal für virtuelle AFR-Sensorik geeignet, da die Lambda-Sonde zum Beispiel bei einem Motorkaltstart nicht exakt messen kann. Zudem lässt sich durch den Regler der Verzug durch den Taktprozess des Motors, Übertragung und Sensorreaktion vermeiden.

### Neuronaler Regler

Die Regelvorgänge werden von einem inversen RNN-Modell (IRNNM) als Funktion aus den Sensormessun-

gen der Motorstatus und externen Eingängen berechnet. Die vom FRNNM vorausgerechneten Ausgangswerte gehen zurück an das IRNNM, das die Regelvorgänge im nächsten Schritt als eine Funktion des gewünschten Ausgangswerts evaluiert. Je genauer die FRNNM-Vorausberechnung ist, desto weniger weichen das FRNNM und die Ausgabe der Regelstrecke voneinander ab.

### Experimentaufbau


Zuerst prüften wir die entwickelte Regelstrategie gegen die flüchtigen Messdaten des Motorprüfstands. Der Lambda-Sensor wurde direkt hinter dem Auslassventil des ersten Zylinders platziert, um die Bildung des Luft-Kraftstoff-Gemisches in nur einem Zylinder zu untersuchen. Dadurch gab es keine dynamischen Auswirkungen von Gastransport und Gemischbildung im Abgaskrümmer. Auch

konnten wir nicht vorhersehbare Auswirkungen durch Zylinderungleichgewicht aufgrund ungleicher Prozesse wie Luftversorgung, thermodynamischer Zustand und Benzineinspritzung außen vor lassen. Daher berücksichtigt der Verzug zwischen Einspritzzeit und Lambda-Sensor-Messung hauptsächlich die Phasen zwischen Einlass- und Auslassventil. Wie bereits erwähnt, kann der Zeitverzug ein großes Problem für Regelanwendungen darstellen. Für die Echtzeitanwendung wurde der Regler mit MATLAB®/Simulink® modelliert und anschließend auf eine dSPACE MicroAutoBox hochgeladen. Mit diesem kompakten Prototyping-System lassen sich alle Motorfunktionen direkt regeln und Änderungen am Regler sofort umsetzen. Der direkte Regler berechnet die tatsächliche Einspritzzeit, indem er aktuelle und frühere Messwerte von Drehzahl und Ladedruck sowie eine vorherige



„Wir haben das Steuergerät durch eine dSPACE MicroAutoBox ersetzt. Mit ihr konnten wir alle Motorfunktionen steuern und die Regelalgorithmen leicht anpassen.“

Cesare Pianese, Universität Salerno



Die Regelstrategie ist sehr genau und verläuft schneller und präziser mit dem Ziel- $\lambda$  als das Steuergerät.

Berechnung des AFR, die vom FRNNM durchgeführt wurde, verarbeitet. Darüber hinaus wurde für die aktuelle Anwendung das Ziel- $\lambda$  auf den stöchiometrischen Wert von 14,67 eingestellt. Aufgrund der Platzierung der Lambda-Sonde wurde der Regler nur an einem Zylinder getestet. Für die restlichen drei Zylinder wurde eine herkömmliche kennfeldbasierte Einspritzstrategie eingesetzt.

### Ergebnisse für den direkten Regler

Das angepasste IRNNM simuliert die inverse AFR-Dynamik genauso exakt wie das FRNNM die Forward-Dynamik. Online-Tests der entwickelten RNNs wurden durch die Integration des FRNNM und IRNNM auf einer MicroAutoBox durchgeführt, wobei die Struktur des neuronalen Reglers beibehalten wurde.

### Fazit

Der virtuelle Sensor (FRNNM) konnte die AFR-Dynamik zufriedenstellend vorausberechnen und hatte bei den meisten Testdurchgängen selbst bei großen AFR-Spitzen im Vergleich zum Ist-Verlauf eine Fehlerquote kleiner 2%.

Damit ist das dynamische RNN-Verhalten sehr nah an der realen Systemdynamik. Der Regler, der ebenfalls die virtuelle Sensorvorausberechnung einsetzt, wurde auf dem Steuergerät implementiert und getestet. Der Vergleich mit dem AFR-Verlauf, der sich aus den Aktionen des Referenzsteuergeräts ergibt, verdeutlicht die gute Leistung des Reglers. Insbesondere führt die Integration der virtuellen Sensorvorausberechnung zu einer Reaktion höherer Ordnung, die nicht nur die AFR-Kompensation beschleunigt, sondern auch ein Überschwingen beim Steuergerät verhindert. In diesem Kontext war die MicroAutoBox eine große Hilfe, da ihre hohe Rechenleistung jederzeit die Ausführung der komplexen Algorithmen in Echtzeit gewährleistete. Die Ergebnisse zeigen das Potenzial der neuronalen Regler zur Verbesserung von Motorsteuerungsstrategien, da sie insbesondere den experimentellen und den Applikationsaufwand reduzieren. ■

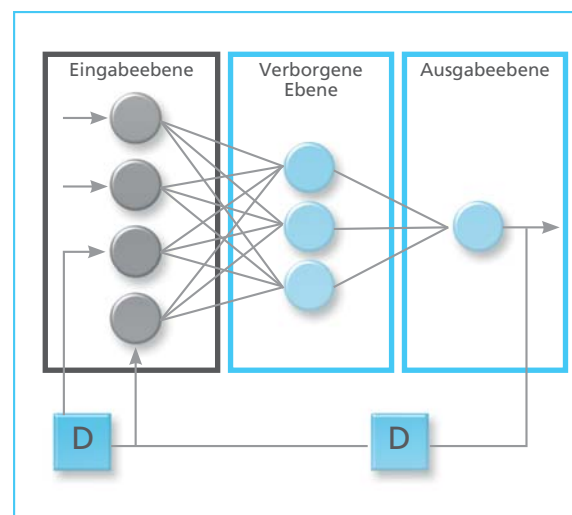
Ivan Arsie, Silvana Di Iorio, Giuseppe Noschese, Cesare Pianese, Marco Sorrentino  
pianese@unisa.it, Fachbereich Maschinenbau, Universität Salerno, Italien

## Glossar

**Luft-Kraftstoff-Gemisch (Air-fuel Ratio, AFR)** – Masseverhältnis von Luft und Kraftstoff während der Verbrennung. AFR ist eine wichtige Größe für mehr Leistung und weniger Luftverschmutzung. Lambda ( $\lambda$ ) ist eine Alternative zur Darstellung des AFR. Bei reinem Oktan ist das optimale Verhältnis  $\lambda = 1.00$  (stöchiometrisches Gemisch von Luft zu Kraftstoff von 14,67:1).

**Lambda-Sensor** – Auch Sauerstoffsensor genannt. Dieser misst den Sauerstoffgehalt im Abgas, damit das Steuergerät den Gehalt des Kraftstoffgemisches bestimmen kann, und passt es bei Bedarf an.

**Neuronale Netze** – Ein neuronales Netz besteht aus einzelnen Neuronen. Jedes Neuron hat ein Gewicht, das je nach Eingabe variiert. Als Ausgabe entsteht eine Funktion. Die Neuronen sind über eine Eingabeebene, eine Ausgabebene und eine oder mehrere verborgene Ebenen miteinander verbunden. Rekurrente neuronale Netze (RNN) werden über die Verbindungen zwischen den Neuronen aus den statischen Netzen abgeleitet. Ein lokaler Speicherprozess speist den dynamischen Effekt in das Rechnerystem ein. Vorteile der RNNs liegen darin, dass sie empfindlich sind und sich an vergangene Eingaben anpassen lassen.



Rekurrentes neuronales Netz (RNN).