


KI in Embedded Systems

Wie neuronale Netze bei der Motorregelung unterstützen

01.07.2026 · Ein Gastbeitrag von Jörg Klenke * · 6 min Lesedauer · 

Moderne Embedded Controller sind zunehmend leistungsfähig und eröffnen damit erstmals realistische Möglichkeiten für den Einsatz von Künstlicher Intelligenz in der Motorregelung. Gleichzeitig sind klassische Regelungsverfahren wie PID etabliert und industriell bewährt. Wo liegt also der Mehrwert vom KI-Einsatz?




Kann KI die klassische Motorregelung ersetzen? Burger Engineering und die TH Nürnberg haben das untersucht. (Bild: Burger Engineering / istockphoto.com)

Künstliche Intelligenz (KI) direkt auf Embedded Systemen einsetzen? Diese Frage rückt für viele Entwickler zunehmend in den Fokus, da heutige Mikrocontroller eine deutlich höhere Rechenleistung bieten als noch vor wenigen Jahren. Zusätzlich stehen spezialisierte Neural Processing Units (NPUs) zur Verfügung, die die Ausführung neuronaler Netze auch unter strengen Ressourcenbedingungen ermöglichen. Besonders in der Regelungstechnik

versprechen Verfahren wie Reinforcement Learning (RL) und Tiny Machine Learning (TinyML) eine höhere Robustheit, eine bessere Anpassungsfähigkeit an Nichtlinearitäten sowie Potenziale zur Energieeinsparung.

Vor diesem Hintergrund stellt sich die Frage: In welchen Anwendungsfällen bietet der Einsatz von Künstlicher Intelligenz einen konkreten Mehrwert? Dieser zeigt sich insbesondere dort, wo in der Entwicklung eine hohe Variantenvielfalt, wechselnde Lastprofile oder nichtlineare Systemeigenschaften zu berücksichtigen sind. In der Motorregelung kommen zusätzlich steigende Anforderungen an Robustheit, Energieeffizienz und kurze Inbetriebnahmezeiten hinzu, was den Aufwand für Parametrierung, Anpassung und Pflege klassischer Regelungsverfahren weiter erhöht.

BILDERGALERIE



KI-Unterstützung für mechatronische Stellantriebe

Die industrielle Motorregelung steht seit Jahrzehnten auf einem soliden Fundament klassischer Regelungsverfahren. PID-Regler, feldorientierte Regelung und modellbasierte Ansätze sind etabliert, gut verstanden und in zahllosen Anwendungen zuverlässig im Einsatz. Gleichzeitig haben sich die Randbedingungen in der industriellen Automatisierung deutlich verändert. Variantenvielfalt, kürzere Produktlebenszyklen, steigende Anforderungen an Energieeffizienz sowie hochdynamische Lastprofile erhöhen den Entwicklungs- und Inbetriebnahmeaufwand kontinuierlich.

Insbesondere die Parametrierung klassischer Regler wird bei komplexen mechatronischen Systemen zunehmend zu einem zeit- und kostenintensiven Faktor. Parallel dazu hat sich die Leistungsfähigkeit moderner Embedded Controller erheblich gesteigert. Mikrocontroller verfügen heute über höhere Taktfrequenzen, größere Speicher, DSP-Einheiten und teilweise über integrierte Neural Processing Units. Damit rückt der KI-Einsatz direkt auf Embedded

Systemen erstmals in einen realistischen industriellen Kontext. Verfahren wie neuronale Netze, TinyML und Reinforcement Learning versprechen eine bessere Anpassungsfähigkeit an Nichtlinearitäten, höhere Robustheit gegenüber Störungen sowie Potenziale zur Reduktion manueller Engineering-Aufwände.

Klassische Regelkreise mit KI kombinieren

In der Industrie ist die Skepsis dennoch groß, denn lernbasierte Verfahren gelten als schwer erklärbar, ressourcenintensiv und nur eingeschränkt echtzeitfähig. Die zentrale Frage lautet daher nicht, ob KI klassische Regelung ersetzen kann, sondern ob und wie sie diese sinnvoll ergänzt, ohne bewährte Prinzipien wie Determinismus, Stabilität und funktionale Sicherheit zu gefährden. Genau hier setzt der betrachtete Ansatz an.

Eine mögliche Lösung basiert auf einer hybriden Regelungsarchitektur, bei der klassische Regelkreise und KI-basierte Komponenten gezielt miteinander kombiniert werden. So zum Beispiel bei Stellantriebsaktuatoren, bei denen Lastsprünge, nichtlineare Effekte und unterschiedliche Einsatzszenarien zu einem erhöhten Abstimmungs- und Inbetriebnahmeaufwand führen.

Um diesen Aufwand systematisch zu reduzieren, wurden in einem praxisnahen Testszenario von Burger Engineering und dem Spices Lab der Technischen Hochschule Nürnberg lernbasierte Verfahren auf Embedded Controllern an einem mechatronischen Stellantriebaktor untersucht. Im Fokus der Untersuchung standen Verfahren der Künstlichen Intelligenz, insbesondere neuronale Netze sowie Reinforcement Learning, und deren Einsatz zur Unterstützung der Motorregelung auf Embedded Controllern. Die gewonnenen Erkenntnisse zeigen, in welchen Bereichen der Einsatz von KI in der Motorregelung heute sinnvoll ist – und wo weiterhin klassische Verfahren im Vorteil bleiben.

Hybride Regelungsansätze für Embedded-Antriebe

Im Zentrum der Untersuchung stand dabei ein mechatronischer Stellantriebaktor mit DC-beziehungsweise BLDC-Motor, wie er typischerweise in industriellen Automatisierungs- und Handhabungssystemen eingesetzt wird. Die Grundstruktur der Regelung – Strom-, Drehzahl- und Positionsregelung – bleibt unverändert und wird weiterhin durch klassische Regler abgebildet.

Ergänzend dazu wird ein neuronales Netz oder eine durch Reinforcement Learning trainierte Policy eingesetzt. Diese KI-Komponente übernimmt nicht die vollständige Regelung, sondern unterstützt gezielt Teilaufgaben, etwa die adaptive Anpassung von Reglerparametern, die Kompensation nichtlinearer Effekte oder die Generierung zusätzlicher Stellgrößen bei Laständerungen. Dadurch bleibt das Gesamtsystem erklärbar und kontrollierbar, während gleichzeitig datengetriebene Anpassungsfähigkeit gewonnen wird.

Die Inferenz der neuronalen Netze erfolgt direkt auf dem Mikrocontroller. Typische Zielplattformen sind 32-Bit-MCUs mit begrenztem RAM und harten Echtzeitanforderungen. Um diese Randbedingungen einzuhalten, werden die Modelle konsequent optimiert: geringe Layer-Tiefen, kleine Netze, INT8-Quantisierung, Festpunktarithmetik sowie die Nutzung hardwareoptimierter Inferenzbibliotheken. Die resultierenden Inferenzzeiten liegen im Millisekundenbereich und sind damit kompatibel mit den Zykluszeiten industrieller Motorregelungen.

Das Besondere an diesem Ansatz ist nicht der Einsatz neuronaler Netze an sich, sondern die konsequente industrielle Einbettung. Anstatt KI als Black-Box-Regler zu verwenden, wird sie als unterstützendes Werkzeug innerhalb einer bekannten Regelungsarchitektur eingesetzt. Klassische Regler bleiben für stabile, deterministische Basisfunktionen verantwortlich, während KI dort wirkt, wo Modelle unvollständig oder Randbedingungen variabel sind.

Vom Training bis zum Embedded-Deployment

Ein weiterer zentraler Aspekt ist die Betrachtung des gesamten Entwicklungsprozesses. Die Lösung umfasst nicht nur das trainierte Modell, sondern einen vollständigen Workflow von der Datenerfassung über Training, Validierung und Sim-to-Real-Übertragung bis hin zum Embedded-Deployment. Dieser ganzheitliche Ansatz ist entscheidend, um KI nicht als experimentelles Element, sondern als reproduzierbares Ingenieurwerkzeug nutzbar zu machen.

Die erfolgreiche Implementierung einer KI-gestützten Motorregelung erfordert klare Voraussetzungen:

- Trainingsdaten in hoher Qualität: Diese müssen relevante Betriebszustände, Störgrößen und Grenzfälle abdecken. Unvollständige Datensätze führen unweigerlich zu instabilem oder nicht reproduzierbarem Verhalten.
- Realistische Simulationsumgebung: Real-to-Sim-Ansätze, bei denen Simulationsmodelle aus Messdaten abgeleitet werden, bilden die Grundlage für effizientes Reinforcement Learning. Das eigentliche Training erfolgt offline auf leistungsfähiger Hardware. Auf dem Embedded System wird ausschließlich die Inferenz ausgeführt, um Echtzeitfähigkeit und Determinismus sicherzustellen.
- Sicherheitskonzepte: Auf Systemebene müssen KI-Komponenten in bestehende Sicherheitskonzepte eingebettet werden. In der Praxis bedeutet dies häufig, dass klassische Regler als Fallback dienen und KI-basierte Funktionen nur innerhalb definierter Betriebsbereiche aktiv sind.
- Übertragung der trainierten Modelle auf den Mikrocontroller: Hierfür kommen typischerweise TinyML-Workflows zum Einsatz. Dabei werden neuronale Netze hinsichtlich Speicherbedarf und Laufzeit optimiert, quantisiert und anschließend in MCU-kompatible Laufzeitmodelle beziehungsweise C-Code überführt. Dadurch lassen sich die Modelle direkt in bestehende Firmware-Architekturen integrieren.
- Hardware-Ressourcen berücksichtigen: Gerade in Embedded-Systemen spielen RAM-Verbrauch, Flash-Speicher und deterministische Inferenzzeiten eine zentrale Rolle. KI-Modelle müssen daher bereits während der Entwicklung konsequent auf die verfügbaren Hardware-Ressourcen abgestimmt werden.

Grenzen und Potenziale KI-gestützter Motorregelung

Im Vergleich zu rein klassischen Regelungsverfahren verschiebt sich der Schwerpunkt von manueller Parametrierung hin zu datengetriebener Adaption. Während PID-Regler bei stabilen Systemen weiterhin unschlagbar effizient sind, stoßen sie bei hoher Nichtlinearität und Variantenvielfalt an wirtschaftliche Grenzen. Hier liefert KI ihren größten Nutzen – nicht

primär durch bessere Regelgüte, sondern durch reduzierte Engineering-Aufwände und höhere Robustheit. Gegenüber früheren KI-Ansätzen, die oft leistungsfähige Industrie-PCs erforderten, zeichnet sich der hier betrachtete Ansatz durch seine Embedded-Tauglichkeit aus. TinyML, Quantisierung und optimierte Inferenzbibliotheken ermöglichen erstmals den direkten Einsatz lernbasierter Verfahren auf dem Motorcontroller selbst, ohne zusätzliche Hardwareebenen oder Kommunikationslatenzen.

Die erzielten Verbesserungen zeigen sich vor allem auf Systemebene:



- KI-gestützte Regelungen reagieren stabiler auf Lastsprünge und Modellabweichungen;
- sie reduzieren den manuellen Abstimmungsaufwand insbesondere bei Varianten oder Serienanpassungen;
- die Robustheit gegenüber Alterung, Verschleiß und thermischen Effekten steigt, da diese implizit in den Trainingsdaten enthalten sind;
- langfristig ergeben sich daraus Potenziale, um Inbetriebnahmezeiten, Stillständen und Energieverbrauch zu reduzieren.


Genau diese Effekte sind für industrielle Anwender häufig entscheidender als eine marginale Verbesserung einzelner Regelkennzahlen.


Die Untersuchung zeigt klar: KI ersetzt klassische Motorregelung nicht pauschal, sondern ergänzt sie dort, wo Komplexität, Dynamik und Variantenvielfalt klassische Ansätze wirtschaftlich unter Druck setzen. Mit TinyML und Reinforcement Learning entsteht ein praxisnahes Werkzeug, das klassische Regelungstechnik sinnvoll erweitert und eine belastbare Brücke zwischen Forschung und industrieller Anwendung schlägt – ein realistischer Fahrplan für KI in der Embedded-Motorregelung.

* Jörg Klenke ist Mitglied der Geschäftsführung bei der Burger Engineering GmbH

(ID:50857641)







WORKFLOW

TRAINING → DEPLOYMENT

