

Embedded KI für Gassensoren - eine industrielle Perspektive

Anna Schröter¹, Ravi Kanth Reddy Chilumula², Ronald Schreiber¹, Clayton Kosteletzky², Christian Meyer¹

¹Renesas Electronics Germany GmbH, Dresden, Deutschland

²Renesas Electronics America, Longmont, USA

Kontakt: anna.schroeter.uw@renesas.com

Einleitung

Die Erkennung der Luftqualität hat in den letzten Jahren viel Aufmerksamkeit erlangt, um eine bessere und gesündere Luftqualität in Innenräumen und öffentlichen Bereichen zu gewährleisten. Typische Anwendungsbeispiele der Luftgüteüberwachung reichen von Luftreinigern, Klimaanlage- und Lüftungssteuerungen, Konferenzraumausrüstungen, Wearables, Mobiltelefonen bis hin zu Überwachungssystemen für Smart Home und Smart City. Metalloxid-Sensoren (MOx-Sensoren) sind in der Lage, das Vorhandensein vieler gesundheitsschädlicher Gase in Innenräumen und in der Außenluft zu erkennen. Die ersten digitalen MOx-Sensoren zur Erfassung der Luftqualität kamen im letzten Jahrzehnt auf den Markt [1]. Im Vergleich zu früheren analogen Lösungen haben diese wesentliche Vorteile, wie beispielsweise eine höhere Miniaturisierung, einfachere Implementation, bessere Skalierbarkeit für die Massenproduktion, einen geringeren Stromverbrauch und einen niedrigeren Preis. Die meisten MOx-Sensoren, sowohl analog als auch digital, nutzen einen traditionellen Algorithmus basierend auf empirischen Gleichungen zur Berechnung der Gaskonzentration. Ein nächster Schritt in der Entwicklung digitaler Metalloxidsensoren ist die Verwendung von Algorithmen des maschinellen Lernens für die Berechnung der Gaskonzentration. Durch den Einsatz von eingebetteter Künstlicher Intelligenz (KI) können MOx-basierte Gassensoren eine höhere Genauigkeit und eine bessere Präzision von Bauteil zu Bauteil erreichen. Renesas ist das erste Unternehmen, das MOx-basierte Gassensoren mit dieser Technologie auf den Markt brachte [2].

Methoden und Materialien

Aufbau und Funktion des MOx-Sensors

Die Gassensormodule von Renesas wie dargestellt in Abbildung 1 bestehen aus einer MEMS Mikro-Heizplatte mit dem abgeschiedenen MOx-Material und einem dedizierten ASIC für die Heizungssteuerung, elektrische Messungen und die Kommunikation über einen I²C-Bus mit einem Host-Controller, z. B. einem Mikrocontroller.




Abb. 1: Schematische Darstellung des Querschnitts der Renesas ZMOD Gassensoren (wasserdichte Variante).

Die Kalibrierungsparameter aus dem chemischen Produktionstest werden im nichtflüchtigen Speicher des ASICs gespeichert. Außerdem enthält dieser Speicher Register zur Sicherung der Sensorkonfiguration und kann die unkalibrierten Widerstandsrohwerter und Statusinformationen ausgeben. Der Host-Controller hat die Aufgabe, die Sensorkonfiguration an den ASIC zu übergeben, die Rohwiderstände auszulesen und die Kalibrierung anzuwenden. Zum Produkt gehört eine Firmware, welche die Sensorkommunikation und die Berechnung der Ausgabe, z. B. einer Gaskonzentration, enthält. Beim traditionellen Ansatz (1. Generation) wird die Gaskonzentration c aus dem Wert des kalibrierten Leitwerts des Metalloxidmaterials G_{MOx} aus folgendem empirischen ermittelten Zusammenhang gemäß Gleichung (1) berechnet [3]:

$$G_{MOx} = G_{CDA} + \frac{c^\alpha}{A} \quad (1)$$

A und α sind Konstanten, welche den Schnittpunkt mit der Widerstands-Achse bzw. den Anstieg im logarithmischen Bereich angeben; beide Parameter werden für jeden Sensor während dessen Kalibrierung gewonnen. G_{CDA} ist der Referenz-Leitwert für saubere trockene Luft (*clean dry air*, CDA).

Für verschiedene Anwendungen sind je nach den zu erwartenden Gasen unterschiedliche MOx Sensormaterialien relevant. Für Innenraumluftanwendungen ist die Messung der gesamten flüchtigen organischen Verbindungen (*Total Volatile Organic Compounds*, TVOC) von Bedeutung. Für den Innen-

raumluftqualitätssensor ZMOD4410 wird ein Material verwendet, das einen positiven Anstiegskoeffizienten α aufweist. Bei Außenanwendungen spielen Verschmutzungen durch Ozon eine Rolle. Diese Gase können mit katalytischen Materialien bestimmt werden, die eine negative Steilheit α haben, wie am Beispiel des ZMOD4510.

Neuronale Netze für verbesserte Sensorausgaben

Da die Berechnung der Gaskonzentration auf dem Host-Controller erfolgt, kann die Berechnungsmethode verändert werden, ohne dass die Sensorhardware selbst geändert werden muss. Außerdem ist es möglich, das Betriebssystem zu ändern. Beispielsweise wird der Innenraumluftheizungssensor beim traditionellen Ansatz (erste Generation) das Sensorelement auf eine konstante Temperatur zwischen 200°C bis 400°C geheizt. Um einen Sensor mit eingebetteter KI zu verwenden, wurde das Betriebssystem auf eine Heizsequenz mit unterschiedlichen Temperaturen geändert. Das Ergebnis ist eine Reihe von Widerständen bei jeweils unterschiedlicher Sensortemperatur. Der Außenluftqualitätssensor wird mit einer Reihe von Impulsen bei einer konstanten Temperatur erhitzt. Die Reihe von Widerständen spiegelt das transiente Verhalten des Sensors wider. Mit dem resultierenden zusätzlichen Informationsgehalt können einige unerwünschte Sensoreigenschaften abstrakt bestimmt werden, wie z. B. das Alter, produktionsbedingte Abweichungen des Sensormaterials und die Sensordrift.

Viele tausende Messungen mit verschiedenen Gas-Stimulationen unter kontrollierten Laborbedingungen und Untersuchungen in realen Umgebungen wurden mit hunderten von Sensoren durchgeführt. Beide Sensorgruppen erhielten Stimuli in verschiedenen Temperatur- und Feuchtebereichen (0 bis 60°C, 0 bis 80%RH) um eine Kompensation umzusetzen.

Referenzgeräte bestimmen die vorhandene TVOC-Konzentration oder Ozon-Konzentration in den realen Umgebungen bzw. im Labor (FTIR). Als Beispielumgebungen wurden im Innenraum Wohnungen und Büros sowie im Außenraum städtische und ländliche Orte auf verschiedenen Kontinenten gewählt.

Sensorwiderstände bei verschiedenen Betriebstemperaturen werden als Array erfasst, vorverarbeitet und zusammen mit den entsprechenden Zielgaskonzentrationen verwendet, um ein überwacht Training eines künstlichen neuronalen Feed-Forward-Netzes mit einer mehrlagigen Perzeptren-Architektur (*Multi Layer Perceptron*, MLP) [4, 5] durchzuführen. Die Koeffizienten des neuronalen Netzes und die Architektur werden vereinfacht und in die Programmiersprache C übersetzt. Ein eingebetteter Host-Controller verwendet den C-Code, um

die Gaskonzentration in Echtzeit auf der Grundlage der Sensorwiderstandseingaben zu ermitteln.

Ergebnisse

Embedded KI erhöht die Genauigkeit

Ein Beispiel einer Messung mit dem Innenraumluftheizungssensor ZMOD4410 ist in Abbildung 2 veranschaulicht. Je vier Sensoren wurden mit dem Betriebssystem der 1. Generation mit konstanter Temperatur gemessen und vier weitere mit einem mehrstufigen Temperaturprofil. Dargestellt sind die entsprechenden Ausgabewerte der Algorithmen mit traditionellem Ansatz (1. Generation) und dem künstlichen neuronalen Netz (2. Generation) für die TVOC Konzentration. Die Messung erfolgte unter Stimulation mit verschiedenen VOC-Gaskonzentrationen gemischt mit gereinigter Luft und 30% Luftfeuchte.

Die beiden Gruppen von Sensoren unterscheiden sich nicht nur in ihren Ausschlägen, sondern haben auch eine deutlich geringere Streuung zwischen den vier Sensoren. Insgesamt konnte ermittelt werden, dass die Messwerte der 2. Generation eine vierfach höhere Präzision erreichen als mit dem traditionellen Ansatz. Gleichzeitig halbiert sich die Messabweichung.




Abb. 2: Zeitverlauf der Ausgabe der TVOC Konzentration für Innenraum-Sensoren mit traditionellen Algorithmen (1. Generation) und mit eingebetteter KI (2. Generation) stimuliert mit einem VOC Gas in verschiedenen Konzentrationsstufen.

Höhere Signalgüte für geringere Leistungsaufnahme

Die Technologie der eingebetteten neuronalen Netze erhöht die Güte der Ausgabewerte. Dieser Umstand kann genutzt werden, einen Algorithmus zu entwickeln, welcher in einem Betriebssystem mit sehr kurzer Anschaltdauer weiterhin gute Ausgaben berechnet. Diese Strategie wurde für den Außenluftsensor ZMOD4510 angewandt. In dem Betriebssystem wechselt sich ein sehr kurzer Heizimpuls von wenigen Millisekunden mit einer Pause von

knapp zwei Sekunden ab. Auch in diesem Fall wurde ein neuronales Netz mit diesem Betriebsschema trainiert und gleichzeitig eine Temperatur- und Feuchtekompensation umgesetzt. Abbildung 3 zeigt die Zuordnung aller Validierungsdaten zwischen einem hochgenauem Referenzgerät zur Ozonmessung und dem digitalen MOx-Sensor mit dem neuronalen Netz im Inferenz-Zustand. Die Abbildung stellt den gesamten Trainingssatz der Messungen in drei unterschiedlichen geografischen Lagen in Nordamerika, Europa und Asien dar. Die Messungen enthalten 41,4 Millionen Datensätze für 39 Sensoren, 242 Tage Betriebszeit. Diese hohe Menge an Daten ist notwendig, um möglichst viele Zustände der Außenluft zu berücksichtigen und zu verifizieren, dass die Embedded KI korrekt trainiert und in variierenden realen Außenluft-Umgebungen funktioniert. Im Ergebnis zeigt sich ein linearer Zusammenhang zwischen den Werten des Referenzgeräts und der KI-Lösung, was für eine gute Übereinstimmung der Messungen spricht. Gleichzeitig konnte die Leistungsaufnahme des Sensors im Vergleich zur Betriebsweise in der ersten Generation um etwa das Hundertfache verringert werden (von 21 mW auf 0,2 mW).




Abb. 3: Gegenüberstellung von der Ausgabe der Ozonkonzentration der Außenluft-Sensoren mit eingebetteter KI und den Werten eines Referenzgeräts

Diskussion

Der Einsatz der Embedded KI erzielte für die Renesas Gassensoren einen großen Gewinn hinsichtlich der Signalgüte. Bei der Entwicklung und Anwendung dieser Algorithmen ergeben sich einige

Herausforderungen und Besonderheiten. Dazu zählen:

- Auswahl des korrekten Betriebsschemas,
- Erfassung der Trainings- und Validierungsdaten für Hunderte von Sensoren,
- das richtige Maß des Trainings des neuronalen Netzes,
- Algorithmenkomplexität der neuronalen Netze,
- Performanz in der realen Anwendung.

Für den ersten Punkt, der Auswahl des Betriebsschemas, sind zunächst eine hinreichend große Anzahl an Messungen mit verschiedenen Modi notwendig. Dabei können Anzahl und Höhe der Temperaturschritte und zur Reduktion des Stromverbrauchs eingefügte Pausenzeiten variieren. Ausgehend aus der Vorerfahrung, die bei der Entwicklung von Gassensor-Algorithmen herrscht, konnte bereits eine Vorselektion der Betriebsschemata erfolgen. Die Varianten müssen gründlich bezüglich ihrer resultierenden Sensitivität, Selektivität und des Stromverbrauchs gegeneinander abgewogen werden. Für eine gute Performanz der KI-Algorithmen ist diese Vorauswahl entscheidend.

Für die Entwicklung der Algorithmen ist eine große Anzahl von Trainingsdatensätzen nötig. Dazu muss eine gute Balance zwischen Labormessungen und Messungen in realen Umgebungen berücksichtigt werden. Die Auswahl der Trainingsdatensätze entscheidet ebenfalls über die Güte des anschließenden Trainings. Die Messumgebung sollte sinnvoll gestaltet sein, beispielsweise durch die Auswahl hochwertiger Referenzgeräte.

Das Training selbst sollte so gestaltet sein, dass eine gute Verallgemeinerung möglich ist. Demzufolge darf es nicht zu einem Übertrainieren kommen, was zu lokalen Häufungen der Ausgaben führt und auch ein Untertraining ist zu vermeiden, um die Präzision der Ausgabe zu erhalten.

Neuronale Netze haben meist eine größere Komplexität als die empirisch ermittelten Fitting-Funktionen. Dies kann zu einem größeren Speicherbedarf für den Algorithmus führen und damit zu Einschränkungen bei der Auswahl eines Host-Controllers. Dafür wurden speziell Architekturen von neuronalen Netzen gewählt, die einen geringen Speicherbedarf erfordern. Auch der Schritt der Vereinfachung des trainierten neuronalen Netzes ist dabei wichtig. Der Bedarf an Programmspeicher ist durch die Anwendung des neuronalen Netzes beispielsweise für den Innenraumsensor nur um 21% gestiegen.

Der reale Einsatz beim Anwender kann eigene Besonderheiten mit sich bringen, die beispielsweise durch die Produktion, das Gehäuse und besondere Einsatzbedingungen beeinflusst werden. Daher ist eine entscheidende Phase der Entwicklung eine

Testphase beim Anwender. Dort kann die Akzeptanz der Algorithmen und ihrer Performanz überprüft und gegebenenfalls angepasst werden.

Ausblick

Die Sensoren für Innenraumluft- und Außenluft-Qualität konnten mit Hilfe von Embedded KI-Technologie eine signifikante Verbesserung der Sensorperformanz zeigen. Das Erreichen dieser Eigenschaften war unter anderem durch die Nutzung einer Vielzahl ausgewählter Trainingssätze in verschiedenen realen und Laborumgebungen erreicht werden. Das Werkzeug der neuronalen Netze kann genutzt werden, um weitere Funktionalitäten und Anwendungen für digitale Metalloxid-Sensoren zu erschließen. Analog zum Außenluftsensor ZMOD4510 kann auch der Innenraumluftsensor ZMOD4410 durch ein angepasstes Betriebssystem und ein dafür trainiertes neuronales Netz in mobilen Endgeräten (Smartphones und -watches) betrieben werden. Die Veröffentlichung dieses Upgrades ist für Anfang 2022 geplant.

Literatur

- [1] INTEGRATED DEVICE TECHNOLOGY, INC.: *IDT Expands its Flagship Integrated VOC Gas Sensor Line With Solutions for Indoor Air Quality Applications*. Pressemitteilung, San Jose, 2018: <https://www.renesas.com/us/en/about/press-room/idt-expands-its-flagship-integrated-voc-gas-sensor-line-solutions-indoor-air-quality-applications>
- [2] RENESAS ELECTRONICS CORPORATION: *Renesas enhances ZMOD4410 Indoor Air Quality Platform with AI for smart odor sensing*. Pressemitteilung, Tokyo, 2020: <https://www.renesas.com/eu/en/about/press-room/renesas-enhances-zmod4410-indoor-air-quality-platform-artificial-intelligence-smart-odor-sensing>
- [3] FRADEN, J.: *Handbook of Modern Sensors: Physics, Designs, and Applications*. Springer, 2015
- [4] ZELL, A.: *Simulation Neuronaler Netze*. Addison Wesley Longman, 1994
- [5] RUMELHART, D. E.; HINTON, G. E.; AND WILLIAMS, R. J.: *Learning internal representations by error propagation*. California Univ San Diego Inst for Cognitive Science, Technical Report, 1985