



- (a) im Falle eines Braunkohleschwelbrandes
- (b) bei sonstigen Testbränden
- (c) bei Kalt- und Heißvulkanisation.



 Abb. 5.1: Schema der Signalverarbeitung zur Bestimmung von 2-Butanon und Benzol aus Gemischen beider Gase aus den Leitwerten zweier Halbleitergassensoren (Figaro TGS 812 und TGS 830) mit neuronalen Netzen. Die Balken auf den unteren Anzeigegeräten geben den maximalen Anzeigefehler an.



Abb. 5.2: Alternatives Verfahren zur Berechnung der Gaskonzentrationen bei Mehrsensorsystemen mit neuronalen Netzen. Die Netze approximieren das statische Sensorverhalten, die Konzentrationsbestimmung wird in einem Parameterschätzverfahren vorgenommen: nach jeder neuen Leitwertmessung wird eine iterative Konzentrationsschätzung vorgenommen. Die aus der Schätzung berechneten Leitwerte werden mit den gemessenen verglichen und aus dem Fehler die Schätzung verbessert. Die Prozedur wird wiederholt, bis eine vorgegebene Fehlerschranke unterschritten wird.



Abb. 5.3: Ergebnisse der Rekonstruktion von CO und H₂-Konzentrationen mit Halbleitergassensoren nach dem in Abb. 5.2 vorgestellten Verfahren. Ver-wendet wurden zwei Sensoren vom Typ UST 2015 bei unterschiedlichen Heitspannungen (3V bzw. 5V)



Abb. 5.4: Auftreten transienter Anzeigefehler bei Vernachlässigung der Sensordynamik in Mehrsensorsystemen: wahre Konzentration von Benzol in (a) und 2-Butanon in (b). In (c) ist die berechnete Benzolkonzentration nach dem System in Abb. 5.1 aufgetragen, in (d) der zugehörige Anzeigefehler. Deutlich zu erkennen sind temporäre Schwankungen in der Benzolanzeige auch bei Abwesenheit dieses Gases.



Abb. 5.5: Die obere Abb. zeigt in einer x-y-Auftragung die Signale des H₂- und CO-Sensors in der GSME während eines künstlichen Braunkohlen-Schwelbrandes. Nach Zündung des Brandes steigt zunächst die CO-Konzentration stärker an, im weiteren Verlauf nimmt dann die Konzentration von H₂ kräftiger zu - die Kurve flacht ab. Die meisten Geräte zeigen im Brandfall bei dieser Auftragung einen derart glatten Signalverlauf. Ein Gerät war währenddessen in der Nähe eines Lüftungsgitter angebracht, dort traten schnelle Außenluftströmungen auf. Diese führten zu schnellen Wechseln in den Gaskonzentrationen. Durch unterschiedliche Zeitkonstanten der Einzelsensoren im Brandmelder resultieren starke Signalstreuungen (transiente Anzeigefehler).



Abb. 5.6: Anordnung der Gassensormeldeeinheiten bei Versuchsbränden



Abb. 5.7: Verlauf des Stromanstiegs und des Stroms als Funktion der Ethanolkonzentration bei einer ZnO-Probe bei 400°C. Parameter ist dabei der Edelmetallzusatz in einer Konzentration von ca. 1%, aus [Hei 79].



Abb. 5.8: Meßgenauigkeit der Ethanolkonzentration anhand der Anfangssteigung des Stromsignals bei 10 aufeinanderfolgenden Messungen an einer ZnO-Probe bei 400°C. Die Dauer der Gasangebote und Pausen zwischen den Angeboten betrugen jeweils 5min. Der maximale Fehler bei einer Konzentration von 0.8 $^{\circ}/_{oo}$ beträgt weniger als 0.02 $^{\circ}/_{oo}$, aus [Hei 79].



Abb. 5.9: Anzeigebeschleunigung zur schnellen Messung von Gaskonzentrationen mt neuronalen Netzen



Abb. 5.10: Modellbasierte Bestimmung der Konzentration von n-Hexan. (a) Profil der n-Hexan-Konzentration, (b) Leitwert eines SnO₂-Dickschichtsensors bei Gasangeboten, (c) Rekonstruktion der Gaskonzentrationen mit Modellsensorrechnung, (d) Fehler in modellbasierter Rechnung



Abb. 5.11: Bestimmung der Konzentration von n-Hexan mit neuronalem Netz. (a) Profil der n-Hexan-Konzentration, (b) Leitwert eines SnO₂-Dickschichtsensors bei Gasangeboten, (c) Rekonstruktion der Gaskonzentrationen durch Einsatz eines neuronalen Netzes, (d) Fehler in Rekonstruktion



Abb. 5.12: Ausschnittsvergrößerung von Abb. 5.10.



Abb. 5.13: Ausschnittsvergrößerung von Abb. 5.11.



Abb. 5.14: Simulation: Test des neuronalem Netzes zur Bestimmung der Konzentrationen von Gassorte 1 bei Anwesenheit eines Störgases (Gas 2) aus den Leitwerten zweier künstlicher SnO₂-Modellsensoren: (a) wahre Konzentration von Gas 1 und des Störgases 2, (b) Rekonstruktion der Konzentration von Gas 1 nach statischem Verfahren oder dynamischen Verfahren mit neuronlem Netz, (c) Fehler bei statischem Verfahren, (d) Fehler bei dynamischen Verfahren



Abb. 5.15: wie zuvor, anderer Ausschnitt aus dem Testdatensatz



Abb. 5.16: Linearer Tiefpaß: Trainingsergebnis eines neuronalen Netzes im Zeitbereich. (a) wahres Eingangssignal, in (b) das korrespondierende Ausgangssignal, (d) Berechnung des neuronalen Netzes, in (d) der Anzeigefehler.



Abb. 5.17: Statische Kennlinie des linearen Tiefpasses und der Approximation des neuronalen Netzes in (a), in (b) der Fehler der Approximation.



Abb. 5.18: Bode-Diagramm des linearen Tiefpasses und der Approximation des neuronalen Netzes. Die Verstärkung und Phasenverschiebung sind gegen die Kreisfrequenz aufgetragen.



Abb. 5.19: Gassensor-Simulation: Trainingsergebnis des neuronalen Netzes im Zeitbereich. In (a) simuliertes Eingangssignal (Gaskonzentration), in (b) Sensorausgangssignal (Leitwert). In (c) ist die Rekonstruktion des Eingangssignal durch ein neuronales Netz aufgetragen, in (d) der zugehörige Fehler.



Abb. 5.20: Gassensor-Simulation: statische Kennlinie des Langmuir-Sensors und der Approximation durch das neuronale Netz in (a), in (b) der Fehler des Netzes.



Abb. 5.21: Gassensor-Simulation: Verlauf der Verstärkung in Abhängigkeit der Kreisfrequenz des inversen Sensormodells und der Approximation durch das neuronale Netz in (a), in (b) das Verhältnis zwischen den Verstärkungen.



Abb. 5.22: "Random"-Gasmischprogramm zur Ermittlung der dynamischen Sensoreigenschaften und Erzeugung der Trainingsdaten für neuronale Netze zur Rekonstruktion der Gaskonzentrationen aus den Sensorleitwerten



Abb. 5.23: Rekonstruktion der Benzolkonzentration aus den zeitabhängigen Signalen eines Halbleitergassensors mit neuronalen Netzen. In (a) ist ein dem Leitwert proportionales Sensorsignal zu sehen, (b) zeigt mit der durchgezogenen Linie die wahre, mit der gestrichelten Linie die berechnete Benzolkonzentration. In (c) ist der Anzeigefehler des neuronalen Netzes aufgetragen.



Abb. 5.24: statisches Gassensorsignal in Abhängigkeit der Benzolkonzentration. (a) die Quadrate korrespondieren mit den Meßwerten, die durchgezogene Linie mit einem sublinearen Fit der Form $a \cdot C^n$ mit *C* als Benzolkonzetration. Die gepunktete Linie repräsentiert die Approxiamtiondurch ein neuronales Netz. Der Approximationsfehler ist in (b) aufgetragen.



Abb. 5.25: Die Verstärkung des neuronalen Netzes bei sinusförmigen Eingangssignalen (Bode-Diagramm).



Abb. 5.26: Anwendung von Modellvalidierungstests auf das neuronale Netz zur Rekonstruktion der Benzolkonzentrationen aus den Sensorleitwerten. Man erkennt sehr starke Abweichungen vom Idealverlauf der Kurven, welche auf Verzerrungen in der Approximation hindeuten.



Abb. 5.27: Testsystem zur Untersuchung der Optimierung neuronaler Netze nach einer anwendungsspezifischen Zielfunktion. Ein Grundsignal in (a) bestehe aus einer Folge gleichverteilter Zufallswerte im Bereich [1.0; 2.0]. Jeder Wert wird für 10 Zeitschritte konstant gehalten und anschließend ein neuer Wert aus dem Bereich gewählt. Auf das Grundsignal wird ein normalverteiltes (weißes) Rauschen mit einer Varianz von 0.1 addiert, siehe (b). Die Summe aus Grund- und Rauschsignal liegt als Eingang eines nichtlinearen Übertragungssystems an. Dieses nimmt zunächst eine Tiefpaßfilterung und anschließend eine sublineare Transformation vor. Man erhält das transformierte Ausgangssignal in (d).



Abb. 5.28: Rekonstruktion des Grundsignals aus Abb. 5.27 anhand der Anwendung des exakten Modells (Kreise), eines neuronalen Netz welches nach der Backpropagation-Regel trainiert wurde (graue Dreiecke) und eines neuronalen Netzes welches nach den Modelltestgleichungen optimiert wurde (schwarze Dreiecke). Näheres im Text unter 5.3.3.4.



Abb. 5.29: Anwendung der Modellvalidierungsgleichungen 2.26-2.40 auf die drei Rekonstruktionsverfahren in Abb. 5.28. Man erkennt, daß das exakte Modell diese genau erfüllt (oben). Auch das nach diesen Testgleichungen optimierte neuronale Netz zeigt nur sehr geringe Differenzen vom idealen Verlauf (unten). Das neuronale Netz, welches nach der Backpropagation-Lernregel trainiert wurde, zeigt sehr starke Abweichungen, welche auf Verzerrungen in der Approximation hinweisen (mitte).



Abb. 5.30: Die Anwendung der drei Rekonstruktionsverfahren auf einen neuen Testdatensatz. Bei diesem wurde der Wertebereich auf [0.25; 2.0] erweitert und für jeden Zeitpunkt ein neuer Zufallswert berechnet. Man erkennt, daß das "Backpropagation"-Netz der schnelleren Dynamik des Signals nicht nachfolgt, zusätzlich unterschreitet es den trainierten Wertebereich nicht. Die übrigen beiden Verfahren weisen dagegen nur geringe Abweichungen vom tatsächlichen Grundsignal auf. Näheres im Text unter 5.3.3.4.



Abb. 5.31: Erweiterung des Verfahrens aus Abb. 5.9 durch Einführung zusätzlicher Netzeingänge für gemessene Sensorparameter.



Abb. 5.32: (a) Leitwert von Sensor 4 bei zweiter Messung, (b) wahre (true) und berechnete (ANN) Benzolkonzentration



Abb. 5.33: Sensortypische Parameter des Sensortyps UST 2000/15 bei den Betriebsspannungen von 3 V und 5 V. Die Sensoren 2 und 6 weichen bei der Betriebsspannung von 5 V deutlich vom linearen Zusammenhang der übrigen Sensoren ab.



Abb. 5.34: Ergebnisse der Rückrechnungen mit den Signalen des Sensors 5 bei 3 V Heizspannung und den Signalen des Sensors 4 bei 5 V Heizspannung (oben). Ergebnisse der Rückrechnungen mit den Signalen des Sensors 6 bei 3 V Heizspannung und den Signalen des Sensors 4 bei 5 V Heizspannung (unten). Die Sensoren sind vom Typ UST 2000/15



Abb. 5.35: oben: H₂-Sensor: Empfindlichkeiten auf Prüfgas H₂ (10 ppm) über mehr als ein Jahr hinweg. Die Signale der verschiedenen Sensoren sind unkalibriert unten: CO-Sensor: Empfindlichkeiten auf Prüfgase CO (30 ppm) und H₂ (10 ppm) über ein Jahr hinweg; Die Sensoren wurden kalibriert, offene Kreise: Querempfindlichkeit auf H₂ (Abb. aus [Kel 96]).



Abb. 5.36: Schema der Vorgehensweise zur Auswertung der relativen Schwankungsbeiträge.
(a) Originalmeßreihe, (b) Fensterung des Sensorsignals, (c) Einteilung der Schwankungsbeitäge zur Bestimmung der Häufigkeitsverteilung

Abb. 5.37: Gemittelte Häufigkeit der Schwankungsbeiträge in den 12 Klassen beim NO-Sensor aus der GSME 61: (a) beim Brand aus 726, level 1.0, (b) beim Brand aus 730, level 1.0, (c) bei Bandlauf, (d) bei Naßreinigung der Anlage. Die gepunkteten Kurven geben die Standardabweichung der Häufigkeit an.

Abb. 5.38: Schema der Vorgehensweise zur Auswertung der Signalspektren. (a)Originalmeßreihe, (b) Hochpaßfilterung des Signals, (c) Fensterung des Sensorsignals, (d) FFT des Datenausschnitts

 Abb. 5.39: (a) Signal des NO-Sensors der GSME 61 während des Schwelbrands zur Meßreihe 726. Der Brandbeginn ist durch den Pfeil "on", sein Ende durch "off" markiert. Der Pfeil "transition" zeigt den Übergang von Brandlevel 0.5 nach 1.0, welcher in (b) beim gefilterten Signal deutlicher wird. In (c) sind die mittleren Fourierspektren der verschiedenen Zustände aufgetragen.

Abb. 5.40: (a) Signal des NO-Sensors der GSME 61 in Meßreihe 828 (Laufen der Förderbänder). In (b) ist das gefilterte Signal sowie in (c) das mittlere Fourierspektrum des gefilterten Signals und dessen Standardabweichung zu sehen.

Abb. 5.41: (a) Signal des NO-Sensors der GSME 61 während einer Naßreinigung der Anlage. In (b) ist das gefilterte Signal sowie in (c) das mittlere Fourierspektrum des gefilterten Signals und dessen Standardabweichung zu sehen.

Abb. 5.42: Gemittelte Fourierspektren der gefilterten Signale des NO-Sensors aus GSME 61 bei zwei Testbränden (a) und (b), bei Bandlauf (c) und bei Naßreinigung der Anlage (d). Die gepunkteten Kurven geben die Standardabweichungen der Amplituden an.

Abb. 5.43: Schwelbranderkennung mit neuronalen Netzen durch klassische Minimierung eines quadratischen Klassifikationsfehlers (Backpropagation-Lernregel). Auf (a) sind die Signale des NO-Sensors der GSME 61 zum Schwelbrand in Meßreihe 726 aufgetragen. (b) zeigt den Netzausgang bei der Klassifizierung der relativen Signaländerungen, (c) den bei der Klassifizierung der Signalspektren. Die ca. 2000s betragende Signalverschiebung in (b) und (c) hängt mit der Fensterung des Signals zusammen

Abb. 5.44: Schwelbranderkennung mit neuronalen Netzen durch klassische Minimierung eines quadratischen Klassifikationsfehlers (Backpropagation-Lernregel). Auf (a) sind die Signale des NO-Sensors der GSME 61 zum Schwelbrand in Meßreihe 826 aufgetragen. (b) zeigt den Netzausgang bei der Klassifizierung der relativen Signaländerungen, (c) den bei der Klassifizierung der Signalspektren. Die ca. 2000s betragende Signalverschiebung in (b) und (c) hängt mit der Fensterung des Signals zusammen

Abb. 5.45: Fitness des besten Individuums während der Optimierung bei der Klassifikation von Signalschwankungen mit neuronalen Netzen. Details zur anwendungsspezifischen Zielfunktion finden sich im Text unter 5.5.3.2.

Abb. 5.46: Schwelbranderkennung durch Klassifikation der Signalspektren mit neuronalen Netzen. In (a) sind die Ereignisse (Brand=1, kein Brand=0) aufgetragen, (b) zeigt die Ergebnisse eines Neuroklassifikators, welcher mit Evolutionsstrategien trainiert wurde, anhand der Signalschwankungen eine Zuordnung nach den Ereignissen vorzunehmen. Details zur anwendungsspezifischen Zielfunktion finden sich im Text unter 5.5.3.2.

Abb. 5.47: Schwelbranderkennung durch Klassifikation von Signalschwankungen mit neuronalen Netzen. In (a) sind die Ereignisse (Brand=1, kein Brand=0) aufgetragen, (b) zeigt die Ergebnisse eines Neuroklassifikators, welcher mit Evolutionsstrategien trainiert wurde, anhand der Signalschwankungen eine Zuordnung nach den Ereignissen vorzunehmen. Details zur anwendungsspezifischen Zielfunktion finden sich im Text unter 5.5.3.2.

Abb. 5.48: Signalhäufigkeiten im Nicht-Brandfall bei Optimierung des Neuroklassifikators nach dem quadratischen Fehler. Bei der Optimierung nach der anwendungsspezifischen Funktion (siehe Text 5.5.3.2) traten im Nicht-Brandfall keine Ausgaben ungleich Null auf.