

Farbbildbasierte Diagnose von Flammenfeldern in der Kohlenstaubfeuerung*

A. Heinze, K. Debes und H.-M. Groß

Technische Universität Ilmenau, Fachgebiet Neuroinformatik

D-98684 Ilmenau (Thüringen), Postfach 10 05 65

Andrea.Heinze@informatik.tu-ilmenau.de

Zusammenfassung

Gegenstand dieser Arbeit ist die Analyse der Farbwerte von Flammenbildern, um Rückschlüsse auf zugrundeliegende Prozeßsituationen zu treffen. Dazu erfolgt die Auswertung der Bildfarbwerte über einen neuronalen Clusterer in einem Histogramm, welches anschließend durch Verwendung eines Backpropagation Netzes bezüglich eingestellter Prozeßparameter klassifiziert wird.

1 Problemstellung

Ein wesentliches Ziel der Automatisierung der Prozeßführung von Feuerungsvorgängen in Kohlekraftwerken ist die *Wirkungsgradmaximierung* bei gleichzeitiger *Emissionsminimierung*. Dazu wurden bislang nur prozeßfern gewonnene und daher totzeitbehaftete Punktinformationen über die Randprozesse der Feuerung (z.B. Dampftemperatur, Emissionsmengen) genutzt. In Erweiterung dessen wäre aber vor allem die Analyse *primärseitiger* Prozeßinformationen (z.B. Farbbilder), die direkt aus dem Flammenfeld und der Feuerungszone abzuleiten sind, vorteilhaft. Nur mit diesen Informationen kann frühestmöglich verhindert werden, die Anlage in energetisch ungünstige Prozeßsituationen, verbunden mit hohen Emissionen, zu führen. Probleme bei der Nutzung primärseitiger Prozeßinformationen bestehen sowohl in deren sensorischer Erfassung als auch in der Auswertung der räumlich-zeitlich sehr komplexen Daten. Daher werden gegenwärtig im Rahmen eines BMBF-Verbundprojektes unter Federführung der Dipl.-Ing. Kurt-Henry-Mindermann GmbH Ratingen Methoden zur Gewinnung und Auswertung prozeßnaher „bildhafter“ *2D/3D-Feldinformationen* über die komplexen, dynamischen Vorgänge in der Feuerungszone untersucht.

2 Farbwertbasierte Klassifikation von Prozeßzuständen

Das Ziel bei der Untersuchung von Korrelationen zwischen Flammenbildern und Prozeßsituationen ist es, Rückschlüsse von Flammenbildern auf eingestellte Prozeßparameter zu treffen. Dies betrifft hierbei die Detektion des „Lastbereiches“ und somit indirekt auch des Anteils „nichtverbrannter Kohle“. Dabei können die Bilddaten aufgrund ihrer hohen Komplexität nicht unverarbeitet in die Prozeßsteuerung eingebunden werden. Daher ist eine Komplexitätsreduktion im Sinne einer Detektion relevanter Merkmale, die wesentliche globale Eigenschaften der Flamme, wie deren Farbverteilung, beschreiben, notwendig.

*gefördert durch das BMBF, Projekt-Nr.: 032 6843 B

2.1 Wahl eines Farbraumes

Zur Analyse der Farbinformationen eines Bildes ist die Nutzung eines spezifischen Farbraumes, wie des RGB- oder physiologischen Farbraumes [Pomierski 96], sinnvoll. Die Vorteile des physiologischen Farbraumes bestehen in einer dekorrelierten Repräsentation von Helligkeit und Farbinformation und der Möglichkeit einer separaten Ausprägung der vorrangig im Flammenbild auftretenden Farbwerte rot und gelb in zwei getrennten Merkmalskarten.

Da die mit beiden Farbräumen durchgeführten Untersuchungen zu qualitativ ähnlichen Ergebnissen führten, wird im folgenden der Nachweis der Klassifizierbarkeit von Prozeßzuständen nur anhand der auf dem physiologischen Farbraum basierenden Ergebnisse geführt.

2.2 Allgemeines Verarbeitungsschema

Durch die Transformation der RGB-Bilddaten in den physiologischen Farbraum werden bildspezifische Punktwolken gebildet. Die Repräsentation der Farbwertverteilungen innerhalb dieser Punktwolken erfolgt durch einen am Datenmaterial erlernten, neuronalen Clusterer, eine eindimensionale Kohonenkette [Kohonen 95] (Abbildung 5, Farbseite).

Mittels der durch die Kohonenkette erlernten niedrigdimensionalen Repräsentation können statistische Aussagen zur Farbwertverteilung innerhalb der Punktwolke getroffen werden. Zur Umsetzung dessen werden die Aktivitäten der Neuronen des Kohonenvektors bei Präsentation aller in den Farbraum transformierter Farbwerte eines Flammenbildes aufgrund des euklidischen Abstandes bestimmt und über jedes Neuron summarisch in einem Histogramm¹ ausgewertet. Dieses Histogramm ist somit ein Maß für die in einem Bild vorkommenden Farbwerte bezüglich der gelernten Referenzdatenmenge (siehe Abschnitt *Repräsentativität des Datenmaterials*). Durch die Auswertung der Häufigkeiten des Auftretens bestimmter, durch die Neuronen repräsentierter Farbwerte wie schwarz, rot oder auch gelb können wiederum Rückschlüsse auf spezifische Prozeßsituationen getroffen werden. Entsprechend der auf visuellen Beobachtungen basierenden Hypothese, daß eine Erhöhung des „Anteils nichtverbrannter Kohle“ ebenso wie die Verschiebung des „Zündortes“ von der Brenneröffnung mit der Verringerung des „Lastbereiches“ korreliert, sollen diese Prozeßgrößen auch aus den Histogrammverteilungen abgeleitet werden. Dies erfolgt gegenwärtig durch einen neuronalen Funktionsapproximator, ein Backpropagation Netzwerk, das aufgrund gegebener Histogramme eine Abbildung auf die Prozeßgrößen „*Lastbereich*“ und somit indirekt auch auf die Größe „*nichtverbrannte Kohlemenge*“ lernt.

2.3 Neuronaler Clusterer zur Bestimmung von Histogrammen

Die wesentlichsten Aspekte zur Auswertung von Punktwolkenrepräsentationen in Histogrammen werden im folgenden diskutiert.

Repräsentativität des Datenmaterials Eine wesentliche Voraussetzung für die Bestimmung geeigneter Histogrammverteilungen ist ein am Datenmaterial belehrter und somit repräsentativer Clusterer. Daher muß bereits der Lernprozeß mit Datenmaterial erfolgen, das

¹Eine ebenfalls mögliche Histogrammbildung direkt über den Farbwerten würde unnötig viele Merkmale liefern, bzw. eine designerabhängige Reduktion bedeuten.

alle Situationen, hier im Sinne aller möglichen auftretenden Farbwerte, umfaßt. Da die Bilder aus dem Prozeßzustand „Vollast“ durch die vergleichsweise größte Vielfalt an Farbwerten gekennzeichnet sind, wurden diese auch zum Training der Kohonenkette genutzt. Dieser Aspekt ist bereits bei der visuellen Betrachtung der im physiologischen Farbraum gebildeten Punktwolken nachweisbar. So ist erkennbar, daß eine Punktwolke bei „Vollast“ sowohl entlang der Unbuntachse als auch bezüglich der Sättigung am stärksten aufgedehnt ist. Dagegen werden bei Bildern, die andere „Lastbereiche“ repräsentieren, nur kleinere Punktwolken, die im allgemeinen in der Nähe des Schwarzbereiches der Unbuntachse liegen, gebildet.

Ebenso ist es zur Gewährleistung der Repräsentativität des Datenmaterials sinnvoll, mehrere zeitlich aufeinanderfolgende Bilder zum Lernprozeß zu nutzen, um so mögliche Abweichungen vom zu erwartenden Datenmaterial auszugleichen.

Weiterhin ist zu beachten, daß die Farbwerte benachbarter Bildpunkte stark korrelieren und somit in ihrem Informationsgehalt redundant sind. Daher müssen nicht alle Bildpunkte in den Lernprozeß einbezogen werden und ein „Ausdünnen benachbarter Bildpunkte“ ist sinnvoll.

Parametrisierung der Kohonenkette In den bisherigen Untersuchungen wurden Kohonenketten mit einer fest vorgegebenen Größe von 20 Neuronen genutzt. Diese bildeten die Punktwolke sehr genau und ohne topologische Defekte ab. Dabei wurden die zwei die Kette begrenzenden Neuronen jeweils im Schwarz- bzw. Weißpunkt des Farbraumes „befestigt“ und im Lernprozeß nicht adaptiert. Dies ermöglicht ein Aufspannen der Kohonenkette über den gesamten Farbraum, wodurch auch deren Glattheit unterstützt wird. Sind dagegen die zwei die Kette begrenzenden Neuronen adaptierbar, wird die Kette nach dem Lernprozeß gefaltet in der Punktwolke liegen.

Die Initialisierung der Neuronen erfolgte entlang der Unbuntachse, so daß im nachfolgenden Lernprozeß sowohl topologische Defekte weitestgehend verhindert als auch der Lernprozeß beschleunigt werden konnte.

Bildung von Histogrammen Da prozeßspezifische Flammenbilder jeweils typische Farbwerte besitzen, sind auch deren Histogramme durch charakteristische Merkmale gekennzeichnet, die wiederum Rückschlüsse auf den gegenwärtigen Prozeßzustand liefern.

Bei der Farbwertauswertung von Bildern wird jeder einzelne Bildpunkt der Kohonenkette² präsentiert, das Best-Matching Neuron ermittelt und seine Aktivität in einem Histogramm (Abbildung 1 links) ausgewertet. Alternativ dazu können auch die Aktivitäten aller Neuronen ($y_{rr'}$) berücksichtigt werden. Dies bewirkt, daß die Histogramme geglättet und „Ausreißer“ verschliffen werden. Abbildung 1 Mitte, Gleichung 1, zeigt ein Histogramm, bei dem die Aktivität eines Neurons linear (bzw. gaußförmig fallend, Abbildung 1 rechts, Gleichung 2), abhängig von seinem Abstand zum Best-Matching Neuron bestimmt wird.

$$y_{rr'} = \max\left(0, \left(1 - \frac{1}{\sigma^2} \cdot \|r - r'\|\right)\right) \quad \text{mit } \sigma^2 = 3 \quad (1)$$

$$y_{rr'} = \exp\left(-\frac{\|r - r'\|}{2 \cdot \sigma^2}\right) \quad \text{mit } \sigma^2 = 3 \quad (2)$$

²Für eine Vergleichbarkeit von Histogrammen unterschiedlicher Bilder dürfen die Gewichte der Kohonenkette nach dem Lernprozeß nicht mehr geändert werden.




Abbildung 1: *Histogramme mit relativen Häufigkeiten zur Repräsentation von Farbwerten durch einzelne Neuronen, bezogen auf das gleiche Bild. Zur Histogrammbildung erfolgte die Auswertung der Aktivität des Best-Matching Neurons (**links**), eine Aktivitätsberechnung der Neuronen nach Gleichung 1 (**Mitte**) und die nach Gleichung 2 (**rechts**).*

2.4 Prozeßidentifikation über neuronale Funktionsapproximatoren

Prinzipielles Ziel der Verwendung eines neuronalen Funktionsapproximators ist die Ermittlung einer Abbildungsvorschrift von den aus einem Verbrennungsprozeß gewonnenen Farbbildern auf spezifische Prozeßgrößen, wie den „Lastbereich“. Als Funktionsapproximator wurde ein zweischichtiges Backpropagation Netzwerk genutzt.




Abbildung 2: *Basierend auf einem gelernten Kohonenvektor können Histogramme für Bilder aus unterschiedlichen Prozeßzuständen ermittelt werden. Bereits die visuelle Betrachtung der Histogramme zeigte wesentliche und typische Unterschiede. Da der Kohonenvektor ausschließlich mit „Vollast“ Bilddaten trainiert wurde, sind die Histogramme von Bildern aus diesem Zustand durch eine fast gleichmäßig starke Aktivierung gekennzeichnet (**links**). Dagegen weisen die Histogramme von Bildern aus dem Prozeßzustand „Teillast“ (**Mitte**) eine typische bimodale Verteilung auf. Die Histogramme für Bilder aus dem Prozeßzustand „Schwachlast“ (**rechts**) wiederum besitzen eine oder nur wenige starke Aktivierungen der Neuronen, die den Bereich in der Nähe des Schwarzpunktes des Farbraumes abdecken. Diese sehr ungleichmäßige Verteilung kann dabei durch die wesentlich schwächere Verbrennung als im Prozeßzustand „Vollast“ erklärt werden.*

Spezifikationen des Backpropagation Algorithmus Die hier genutzten Netzwerke bestanden aus zwei verarbeitenden Schichten mit 20 Input-, 3 bzw. 9 Output- und abhängig von der durchgeführten Untersuchung aus 2 bis 15 Hiddenneuronen. Die Adaptation der Gewichte der Netze erfolgte mittels des direct learnings.

Zur Bestimmung der Outputaktivitäten der Neuronen wurden Fermi-Funktionen genutzt, durch deren Anstieg das Konvergenzverhalten der Neuronen in den Sättigungsbereich steuerbar ist. Dabei sind die in der Hiddenschicht genutzten Fermi-Funktionen durch einen wesentlich flacheren Verlauf als die für die Outputschicht festgelegten gekennzeichnet. Somit befinden sich die Aktivitäten der Hiddenneuronen auch bei hohen Zustandswerten, verursacht durch viele Eingangselemente mit hohen Inputwerten, im Arbeitsbereich und daher außerhalb ihrer Sättigung.

Zur Beschleunigung des Lernvorganges wurde weiterhin eine modifizierte Form der Berechnung der durch das Netz zurück zu propagierenden Fehler [Fahlman 88] verwendet.

Abgeleitet aus der in Abbildung 2 dargelegten Möglichkeit zur visuellen Differenzierung der Histogramme wurden nachfolgend zwei prinzipielle Versuchsstrategien zur neuronalen Klassifikation der Bilder anhand ihres zugehörigen „Lastbereiches“ durchgeführt.

Grobklassifikation von Histogrammen Zunächst wurde eine Klassifizierbarkeit der Histogramme in die 3 „Lastbereiche“ untersucht. Dazu wurde jedem Input (Histogramm), basierend auf der Angabe des „Lastbereiches“ für das zugrundeliegende Bild, ein Teachersignal zugewiesen (Gleichung 3).

$$\underline{t} = \begin{cases} 1.0 & 0.0 & 0.0 & : & \text{Histogramm für eine „Vollast“} \\ 0.0 & 1.0 & 0.0 & : & \text{Histogramm für eine „Teillast“} \\ 0.0 & 0.0 & 1.0 & : & \text{Histogramm für eine „Schwachlast“} \end{cases} \quad (3)$$

Das Ziel dieser Untersuchungen bestand im prinzipiellen Nachweis der Möglichkeit der farbbildbasierten Klassifikation unterschiedlicher Prozeßzustände. Aufgrund der erreichten Ergebnisse konnte nachgewiesen werden, daß eine Klassifikation von den aus Farbbildern ermittelten Histogrammen in die 3 Prozeßzustände „Lastbereich“ bereits durch ein Netzwerk mit 2 Hiddenneuronen auch bei unterschiedlichen Parameterkonfigurationen nach wenigen (etwa 600) Epochen möglich ist (Abbildung 3). Eine Epoche umfaßte wie auch bei der nachfolgenden Feinklassifikation die jeweils ersten 75% aller 519 Muster des Datensatzes. Die weiteren 25% der Muster dienten der nachfolgenden Validierung des Netzes.




Abbildung 3: *Typischer zeitlicher Verlauf des Epochenfehlers für ein Experiment mit drei Versuchswiederholungen. Der prozentuale Validierungsfehler, bezogen auf ein 100% falsch gelerntes Muster (maximaler absoluter Musterfehler von 3) betrug in diesen Versuchen nach 2000 Epochen durchschnittlich 0.16% pro Muster. Die diesem Versuch zugrundeliegenden Parameter sind 2 Hiddenneuronen, eine zeitlich fallende Lernrate*

mit $\eta_{init} = 0.8$, ein Momentum von $\alpha = 0.2$ und eine zufällige Gewichtsinitialisierung im Intervall $[-1, 1]$.

Feinklassifikation von Histogrammen Basierend auf diesem Ergebnis wurde eine Feinklassifikation der Histogramme bezüglich des „Lastbereiches“ untersucht. Das Ziel war es, die Bilder nicht nur anhand der definierten „Lastbereiche“, sondern auch bezüglich der Übergänge zwischen den vorgegebenen Zuständen zu klassifizieren, um so einen Trend im Verbrennungsprozeß erkennen oder auch Vergleiche zwischen mehreren Brennern realisieren zu können.

Da die vorliegenden Bilddaten bezüglich des durch sie repräsentierten Prozeßzustandes nur grob in 3 Klassen unterteilbar waren, mußten die für eine Feinklassifikation notwendigen Histogramme aus den real ermittelten künstlich erzeugt werden. Diese Datengenerierung erfolgte, indem ein „künstliches“ Histogramm aus einer prozentualen Überlagerung zweier realer Histogramme gebildet wurde. Verbunden mit der verfeinerten Auflösung der Prozeßzustände in 9 Klassen wurde auch die Netzwerkstruktur auf 9 Outputneuronen angepaßt.

Im Ergebnis dieser Untersuchungen wurde festgestellt, daß eine Klassifikation von den aus den realen Farbbildern ermittelten und den künstlich generierten Histogrammen in 9 Prozeßzustände möglich ist und Netzwerke mit einer Mindestanzahl von 8 Hiddenneuronen erfordert (Abbildung 4). Unter Nutzung des direct-learning konvergierte der summierte Musterfehler je Epoche nach etwa 3000 Epochen (1410 Muster je Epoche) gegen einen Fehlerwert von etwa 120 (durchschnittlicher prozentualer Musterfehler von 0.94%). Im Gegensatz zur Klassifikation von 3 Prozeßzuständen ist dieser Lernprozeß stärker parameterabhängig.




Abbildung 4: Typischer zeitlicher Verlauf des Epochenfehlers für ein Experiment mit drei Versuchswiederholungen. Hierbei betrug der durchschnittliche Epochenfehler nach 6000 Epochen 140, d.h. 0.099 je Muster. Bezogen auf ein 100% falsch gelerntes Muster entspricht dieser absolute Lernfehler einem prozentualen von 1.1% je Muster. Der prozentuale Validierungsfehler betrug dabei durchschnittlich 4.9%. Die bei diesem Experiment genutzten Parameter sind 15 Hiddenneuronen, eine zeitlich feste Lernrate von $\eta = 0.8$, ein Momentum von $\alpha = 0.2$ und eine zufällige Gewichtsinitialisierung $[-1, 1]$.

3 Zusammenfassung der Ergebnisse und Ausblick

Das wesentliche Ergebnis dieser Untersuchungen ist der Nachweis, daß für die Bilder aus unterschiedlichen Prozeßzuständen „Lastbereich“ jeweils typische und klassifizierbare Histogramme existieren. Dies sollte in nachfolgenden Untersuchungen auch anhand realer Bild- und Prozeßdaten, die das gesamte Spektrum möglicher „Lastbereiche“ kennzeichnen, validiert werden. Abgeleitet aus diesen Ergebnissen sollten sich darauf aufbauende Untersuchungen mit folgenden Aspekten befassen.

- Klassifikation der Prozeßzustände „Lastbereich“ durch ein einzelnes Neuron der Outputschicht, welches eine Klassenzugehörigkeit direkt über den analogen Wert (100% - 0% „Lastbereich“) seines Outputs kodiert.
- Extraktion der zur Unterscheidung von Prozeßsituationen signifikanten Bildbereiche. Dazu erfolgt die Ermittlung derjenigen Neuronen der Kohonenkette, die eine Unterscheidung der „Lastbereiche“ ermöglichen. Für diese Neuronen werden die durch sie kodierten Farbwerte und deren Position im Bild (z.B. in der Flamme oder auf der Brennerwand) bestimmt.
- Auswertung der Histogramme bezüglich weiterer korrelierter Prozeßgrößen, wie z.B. die „Luftmenge“.

Literatur

- [Fahlman 88] **S.E. Fahlman** (1988). An empirical study of learning speed in back-propagation networks. In D.Touretzky, G.Hinton, T.Sejnowski (Eds.): Proc. of the 1988 Connectionist Models Summer School, June 17-26 1988, Carnegie Mellon University. Morgan Kaufmann.
- [Kohonen 95] **T. Kohonen** (1995). Self-Organizing Maps. Springer-Verlag Berlin Heidelberg.
- [Pomierski 96] **T. Pomierski and H.-M. Gross** (1996). Neural architecture for Chromatic Adaptation of Single Images and Picture Sequences. In 2. Nationaler Workshop „Farbbildverarbeitung“, TU-Ilmenau. pp. 29-34.

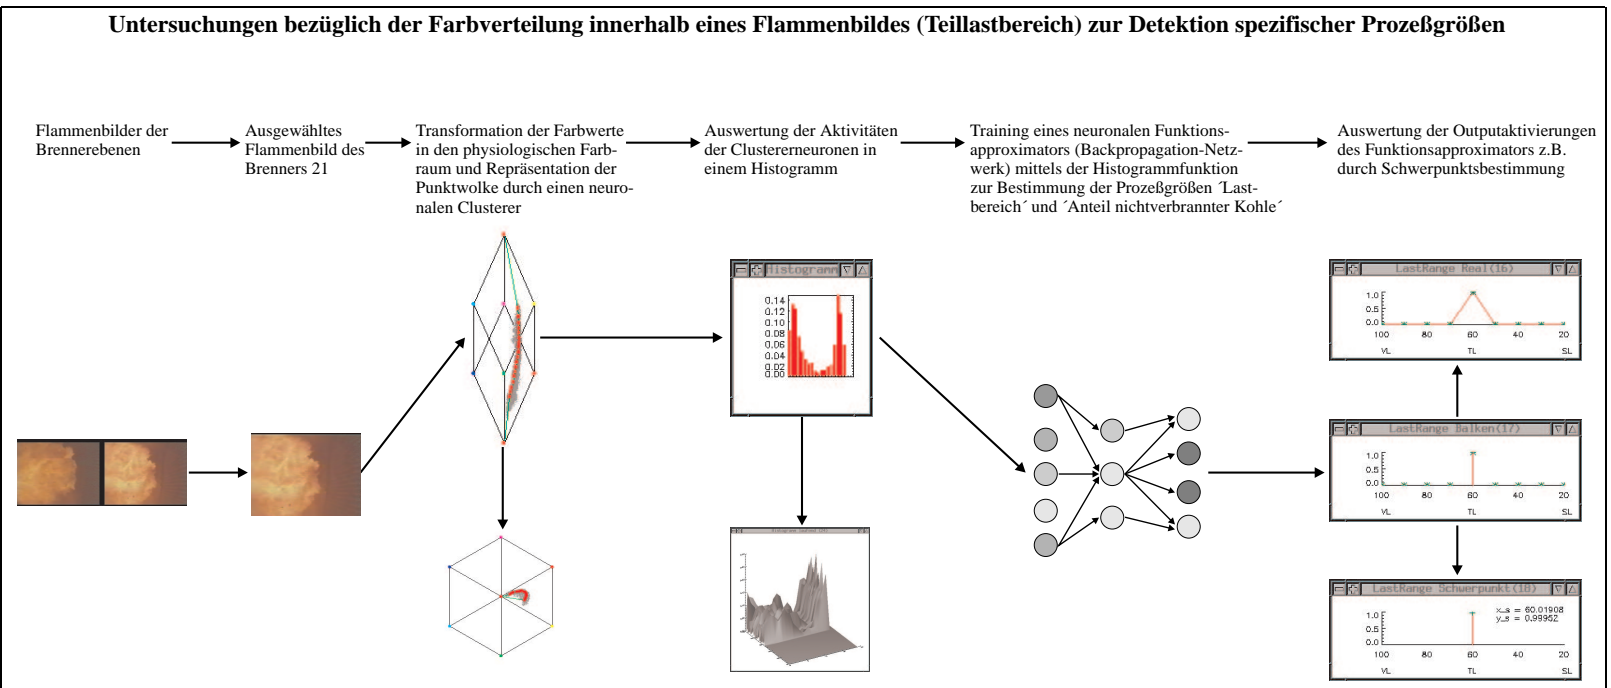


Abbildung 5: Schematische Darstellung der Klassifikation von Prozesszuständen über eine niedrigdimensionale Repräsentation von Farb Bildern und einer sich anschließenden Klassifikation mittels eines Backpropagation Netzes.