

Online-Prädiktion der Prozessgüte komplexer Batchprozesse mittels informationstheoretischer Maße und Support Vector Machines

Christian Kühnert, Dr. Thomas Bernard, Fraunhofer IOSB, Karlsruhe

Kurzfassung

Aufgrund der ständig zunehmenden Komplexität verfahrenstechnischer Anlagen (z. B. der chemischen oder Glas-Industrie) wird es für den Anlagenfahrer immer schwieriger, frühzeitig zu erkennen, ob der Prozess hinreichend gut geführt wird. Dies gilt besonders für instationäre Prozessphasen, z. B. Anfahrphase oder Arbeitspunktwechsel. Da mit dem ebenfalls zunehmenden Automatisierungsgrad der Produktionsanlagen immer mehr Sensor- und Aktordaten des Prozesses zur Verfügung stehen, bietet es sich an, ergänzend zu modellbasierten Konzepten Data-Mining-Methoden zur Überwachung und Optimierung der Prozesse einzusetzen. Im vorliegenden Beitrag wird dazu ein neuartiges Konzept vorgestellt, welches im Rahmen des Fraunhofer-Verbundprojektes ProDaMi entwickelt wurde. Mittels Data-Mining-Methoden werden aus historischen Prozessdaten relevante Merkmale extrahiert und es wird ein datengetriebenes Modell zur Prädiktion eines definierten Gütemaßes (z. B. Ausschussmasse) generiert. Das Konzept bietet die Möglichkeit, ungünstige Prozessentwicklungen online frühzeitig zu erkennen um die Prozessführung anpassen zu können. Die Leistungsfähigkeit des Konzeptes wird anhand eines Benchmarkprozesses (Klatt-Engell-Reaktor) sowie eines industriellen Glasziehprozesses demonstriert.

1 Einleitung

Moderne verfahrenstechnische Prozesse zeichnen sich durch einen hohen Automatisierungsgrad und zunehmende Komplexität aus. Die Optimierung von instationären Prozessphasen wie z. B. dem Anfahren von Batchprozessen erfolgt bisher in der Regel basierend auf rigorosen Prozessmodellen und dem Expertenwissen der Anlagenfahrer. Die Erstellung dieser Modelle ist allerdings oft sehr zeit- und kostenaufwendig und bei vielen Prozessmodellen aufgrund stark nichtlinearer Teilprozesse bzw. Materialeigenschaften nur mit begrenzter Güte möglich.

Ein Ansatz zur datengetriebenen Optimierung mittels Data-Mining-Methoden [1] besteht darin, aus archivierten Zeitreihen der Prozessgrößen relevante, charakteristische Merkmale (z. B. Extrema, Trend-, Mittelwerte) zu extrahieren und diese in Relation zu einem Maß der Prozessgüte zu setzen (z. B. Ausschussmasse oder Energiekosten), siehe Bild 1. Dieses

Modell kann sowohl offline als auch online zur Analyse und Optimierung der Prozessführung eingesetzt werden. Im vorliegenden Beitrag wird dieser Ansatz zur Online-Überwachung und Prädiktion der Prozessführung verwendet. Das Konzept wird im folgenden Abschnitt 2 vorgestellt. In Abschnitt 3 werden Ergebnisse anhand eines Benchmarkprozesses und in Abschnitt 4 Ergebnisse anhand eines industriellen Glasziehprozesses vorgestellt.



Bild 1: Datengetriebenes Modell eines Prozess-Gütemaßes in Abhängigkeit von relevanten Merkmalen.

2 Konzept zur Merkmalsselektion, Modellbildung und Online-Prädiktion

Der erste wesentliche Schritt des Konzeptes besteht darin, aus den historischen Prozessdaten (Zeitreihen) eine möglichst geringe Anzahl relevanter Merkmale zu selektieren und ein Ranking der Merkmale zu erstellen [2]. Es müssen also redundante und informationslose Merkmale entfernt werden. Da in der Regel von jeder Prozessgröße mehrere Standard-Merkmale (z. B. Extrema, Trend-, Mittelwerte) in einem relativ umfangreichen Merkmalsdatensatz gesammelt werden, ist es zweckmäßig, eine Vorselektion der Merkmale durchzuführen. Unter Verwendung *Informationstheoretischer Maße* kann abgeschätzt werden, ob sich in einem extrahierten Merkmal hinreichend viel Information für eine Modellbildung trägt. Diese Größen stellen Maße zur Beurteilung von Wahrscheinlichkeitsverteilungen dar. Mittels dieser kann dann abgeschätzt werden, ob sich in den extrahierten Merkmalen genügend Informationen für eine sinnvolle Modellbildung befinden oder ob schon im Vorhinein eine Modellbildung ausgeschlossen werden kann [3]. Zusätzlich hat man mit diesen Maßen die Möglichkeit, ein erstes Ranking in Form einer Vorselektion der extrahierten Merkmale durchzuführen, indem redundante sowie informationslose Merkmale entfernt werden. Zur Analyse wird dazu als Maß die Transinformation zwischen zwei Werten verwendet, welche sich durch folgende Formel berechnet [5].

$$I(X;Y) = \int f(x,y) \log_2 \frac{f(x,y)}{f(x)f(y)} dx dy \quad (1)$$

Die zu berechnenden Verteilungsdichtefunktionen werden hierbei durch Parzen-Fenster angenähert. Zur Selektion der Merkmale werden ähnlich dem in [5] vorgestellten Verfahren die folgenden Werte berechnet:

$$D = I(x_i; y) \quad (2)$$

$$R = \max I(x_i; x_j) \text{ für } j = 1 \dots N, j \neq i \quad (3)$$

Hierbei beschreibt D die Relevanz des Merkmals bezüglich des Gütemaßes und R die maximale Redundanz eines Merkmals zu einem weiteren Merkmal. Mittels dieser beiden Werte hat man die Möglichkeit, eine Vorfilterung der Merkmale vorzunehmen, indem man eine Grenze für die minimale Relevanz sowie die maximale Redundanz definiert. Zusätzlich hat man die Möglichkeit, ein Merkmalsranking beispielsweise durch Division oder Subtraktion der Kriterien D und R durchzuführen. Die Modellbildung erfolgt durch den in [6] beschriebenen Ansatz. Hierbei wird ein eingebettetes Merkmalsranking und Modellbildungsverfahren basierend auf Support Vector Machines im Regressionskontext verwendet [4]. Bild 2 gibt hierzu einen Überblick. Die Initialisierung der SVR erfolgt mittels den vorselektierten Merkmale, der Wahl einer Kernelfunktion sowie den SVR-Hyperparametern. Daraufhin erfolgt die Modellbildung durch Trainieren der SVR für alle Merkmale, einem Merkmalsranking und der Berechnung eines ausgewählten Merkmalsraums. Daraufhin erfolgt das Trainieren der SVR basierend auf dem reduzierten Merkmalsdatensatz. Die Anzahl der Merkmale sowie die SVR-Parameter konvergieren schließlich, sodass man ein abgesichertes Merkmalsmodell einer Prozessphase erhält.

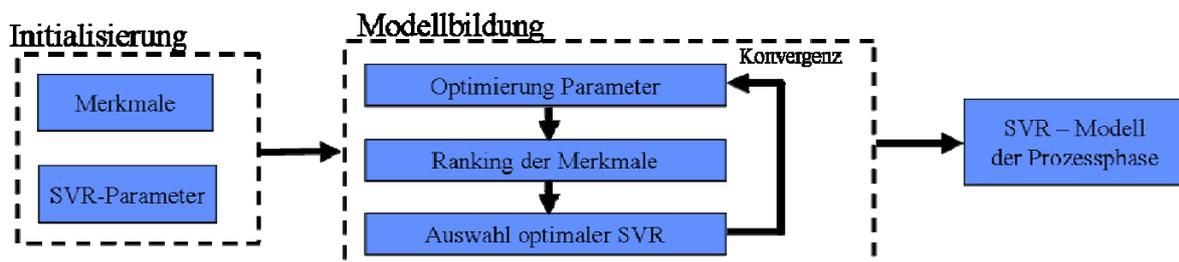


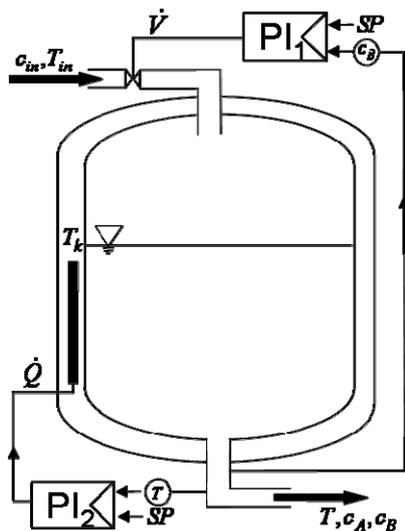
Bild 2: Berechnung eines Modells einer Prozessphase basierend auf Support Vector Machines

3 Evaluation des Konzeptes anhand eines Benchmark-Prozesses

Die prinzipiellen Eigenschaften des vorgeschlagenen Konzeptes wurden zunächst anhand eines Benchmark-Prozesses (Klatt-Engell Reaktor [9]) in Simulationen untersucht. Das Modell dieses Prozesses besteht aus vier gekoppelten, nichtlinearen Differentialgleichungen. Als Zielstellung wurde definiert, optimierte Merkmalswerte von zwei Eingangsgrößen zu finden, so dass die Anfahrphase des Prozesses möglichst schnell abgeschlossen ist. Es wurden unkorrelierte „Dummy-Prozessgrößen“ zu den simulierten Zeitreihen hinzugefügt, um die Robustheit des Konzeptes nachzuweisen.

3.1 Klatt-Engell-Reaktor

Der Klatt-Engell-Reaktor beschreibt den so genannten van de Vusse [7] Reaktionsmechanismus, bei dem aus einem Edukt A in einer Reaktion ein Produkt B mit zwei Nebenreaktionen gebildet wird. Der zugrundeliegende Prozess dazu ist in Bild 2



skizziert. Der Volumenstrom für die durchzuführende Reaktion enthält hierbei das Edukt A mit einer Konzentration c_{in} und der Temperatur T_{in} . Am Ausgang liegt das Produkt mit der Konzentration c_B und das nicht reagierte Edukt mit der Konzentration c_A an. Zur Regelung stehen zwei PI-Regler zur Verfügung. Die erste Regelung verwendet als Stellgröße den Volumenstrom \dot{V} und als Regelgröße die sich ergebende Konzentration c_B . Der zweite Regler wird dazu verwendet, die Ausgangstemperatur T mittels der Kühlleistung \dot{Q} konstant zu halten.

Bild 3: Schema des Klatt-Engell Reaktors

Aus den Massebilanzen ergeben sich die folgenden Konzentration c_A und c_B :

$$\begin{aligned} \dot{c}_A &= -k_1(T)c_A - k_2(T)c_A^2 + [c_{in} - c_A]u_1 \\ \dot{c}_B &= k_1(T)[c_A - c_B] - c_B u_1 \end{aligned} \quad (4)$$

Zusätzlich lässt sich mittels der Enthalpiebilanzen die Temperatur des Kühlmantels T_k und die Reaktortemperatur T mittels der folgenden Differentialgleichungen berechnen:

$$\begin{aligned} \dot{T} &= h(c_A, c_B, T) + \alpha[T_k - T] + [T_{in} - T]u_1 \\ \dot{T}_k &= \beta[T - T_k] + \gamma u_2 \end{aligned} \quad (5)$$

Für die Reaktion der Reaktortemperatur wird zur Berechnung der Enthalpie folgende Gleichung angenommen:

$$h(c_A, c_B, T) = -\delta[k_1(T)[c_A \Delta H_{AB} + c_B \Delta H_{BC}] + k_2(T)c_A^2 \Delta H_{AD}] \quad (6)$$

Die beiden Konstanten k_1 und k_2 werden dazu durch die folgende Arrhenius-Funktion beschrieben:

$$k_i(T) = k_{i0} \exp\left(\frac{-E_i}{T + 273.15}\right) \quad (7)$$

Die Gleichungen (4) - (7) stellen ein System von vier gekoppelten, nichtlinearen Differentialgleichungen dar. Die gewählten Parameterwerte sind aus [8] entnommen und in Tabelle 1 dargestellt. Zur Regelung werden zwei PI-Regler mit Stellgrößenbeschränkung

verwendet, um reale Bedingungen zu simulieren. Der erste PI-Regler PI_1 wird dazu verwendet, die Konzentration c_B durch den Volumenstrom \dot{V} zu regeln ($u_1 = \dot{V} / V_{Reaktor}$). Der zweite PI-Regler PI_2 regelt die Ausgangstemperatur T des Volumenstroms mittels der Kühlleistung $u_2 = \dot{Q}$. Die PI-Regler wurden folgendermaßen parametrisiert:

$$u_1(s) = \left(10^{-4} + \frac{2 \cdot 10^{-3}}{s}\right) e(s) \quad \text{mit } 0 < u_1 < 2/h \quad \text{PI-Regler } PI_1 \quad (8)$$

$$u_2(s) = \left(90 + \frac{80}{s}\right) e(s) \quad \text{mit } 0 < u_2 < 12500 \text{ kJ/h} \quad \text{PI-Regler } PI_2 \quad (9)$$

$\alpha = 30.82 \text{ h}^{-1}$	$E_1 = 9758 \text{ K}$	$\Delta H_{AB} = 4.2 \frac{\text{kJ}}{\text{mol}}$
$\beta = 0.4 \text{ h}^{-1}$	$E_2 = 8560 \text{ K}$	$\Delta H_{AD} = -41.85 \frac{\text{kJ}}{\text{mol}}$
$\gamma = 0.1 \frac{\text{K}}{\text{kJ}}$	$c_{in} = 5100 \frac{\text{mol}}{\text{m}^3}$	$\Delta H_{BC} = -11.00 \frac{\text{kJ}}{\text{mol}}$
$\delta = 3.5 \cdot 10^{-4} \frac{\text{m}^3 \text{ K}}{\text{kJ}}$	$T_{in} = 105 \text{ K}$	$k_1 = 1.287 \cdot 10^{12} \text{ h}^{-1}$
$c_A = 3517 \frac{\text{mol}}{\text{m}^3}$	$T = 87 \text{ K}$	$k_2 = 9.043 \cdot 10^6 \frac{\text{m}^3}{\text{mol} \cdot \text{h}}$
$c_B = 740 \frac{\text{mol}}{\text{m}^3}$	$T_k = 740 \text{ K}$	

Tabelle 1: Modellparameter des Klatt-Engell-Reaktors

3.2 Anwendungsbeispiel: Optimierung der Eingangsgrößen

Zur Erzeugung des Testdatensatzes wird angenommen, dass die beiden Prozessparameter c_{in} und T_{in} von einer zuvor stattgefundenen Reaktion stammen und somit Schwankungen unterliegen, die zwar gemessen werden können, aber auf die bei Eintritt in den Reaktor kein Einfluss genommen wird. Diese Schwankungen werden in Form von unterschiedlichen Mittelwerten ausgedrückt. Das Ziel des Verfahrens ist es, automatisiert die relevanten Merkmale (also Mittelwerte c_{in} und T_{in}) zu finden sowie deren optimale Werte bezüglich eines definierten Gütemaßes zu berechnen.

Als instationäre Prozessphase wird hierbei der Anfahrvorgang des Chemiereaktors betrachtet, mit dem Ziel ein möglichst schnelles Einschwingen der Konzentration c_B zu erreichen. Hierzu wird als Gütemaß der Abtastzeitpunkt definiert, bei dem die Konzentration c_B weniger als 0,5 % vom gewünschten Sollwert abweicht. Der Reaktor selbst wird hierbei als Black-Box-Modell betrachtet. Das heißt, als Anlagedaten werden die Eingangsgrößen c_{in} und T_{in} verwendet sowie als Ausgangsdaten die sich ergebenden Konzentrationen c_A , c_B sowie die Temperatur T_{out} des austretenden Volumenstroms. Zusätzlich werden zwei fiktive Messgrößen M_1 und M_2 hinzugefügt, welche keinen Einfluss auf die resultierende Konzentration c_B haben und deren Merkmalswerte während der Selektion automatisiert

entfernt werden sollen. Als Merkmale werden von allen Werten Minima, Maxima, Schwankung und Mittelwert der Originalmessreihe sowie der ersten Ableitung extrahiert.

Um Schwankungen in den einzelnen Messreihen zu simulieren, werden die Messwerte jeweils mit mittelwertfreiem Rauschen überlagert, welches jeweils eine Varianz von 10 % des Stationärwertes besitzt. Die Verläufe 400 simulierten Anfahrvorgängen sind in Bild 4 dargestellt. Während des Anfahrvorgangs lassen sich zwei optimierte Anfahrphasen beschreiben, mit welchen ein schnelles Einschwingen des Prozesses bezüglich der Konzentration c_B erreicht wird. Diese sind in Bild 4 grau dargestellt. Sie beinhalten eine hohe Eingangskonzentration c_{in} sowie eine Eingangstemperatur T_{in} um 100 oder 80 Grad.

3.3 Ergebnisse

Insgesamt wurden 64 Merkmale aus den Messreihen extrahiert. Mittels der informationstheoretischen Maße konnte der Datensatz zunächst auf 8 Merkmale reduziert werden. Diese 8 Merkmalen bestanden nur noch aus Merkmalen der Messgrößen c_{in} und T_{in} . Mittels der in Abschnitt 2 beschriebenen eingebetteten Merkmalsselektion und dem Modellbildungsansatz wird der in Tabelle 1 dargestellte Merkmalsdatensatz identifiziert und ergibt die jeweilige erklärte Varianz des berechneten Modells. Es zeigt sich also, dass mittels des Verfahrens die entscheidenden Merkmale gefunden werden können. Das an Stelle 3 ausgewählte Merkmal, Minimum T_{in} , wird zwar durch das Rankingverfahren nicht entfernt, allerdings zeigt sich bei der berechneten erklärten Varianz des Modells, dass dieses Merkmal keinen Einfluss auf die sich ergebende Modellgüte mehr hat.

Mittels eines Grid-Search-Verfahrens, welches auf die berechnete SVR angewendet wird, werden im nächsten Schritt die optimalen Merkmalswerte für c_{in} und T_{in} berechnet. In Bild 5 ist hierfür der Dichteplot des berechneten Modells dargestellt, wobei über der z-Achse der Modellwert aufgetragen ist. Deutlich lassen sich die beiden Minima bei der Temperatur und der Konzentration erkennen, in welchen sich der Prozess in einer optimierten Prozessführung befindet. Das heißt, in dem hier vorliegenden Fall sollte das Ziel sein, Temperatur und Konzentration beispielsweise durch eine Vorsteuerung in einem der beiden Bereiche zu halten, um ein schnelles Einschwingen zu garantieren. Dieser Ansatz wird im Folgenden leicht modifiziert dazu verwendet, um die Anfahrphase eines rheologischen Glasziehprozesses online zu überwachen.

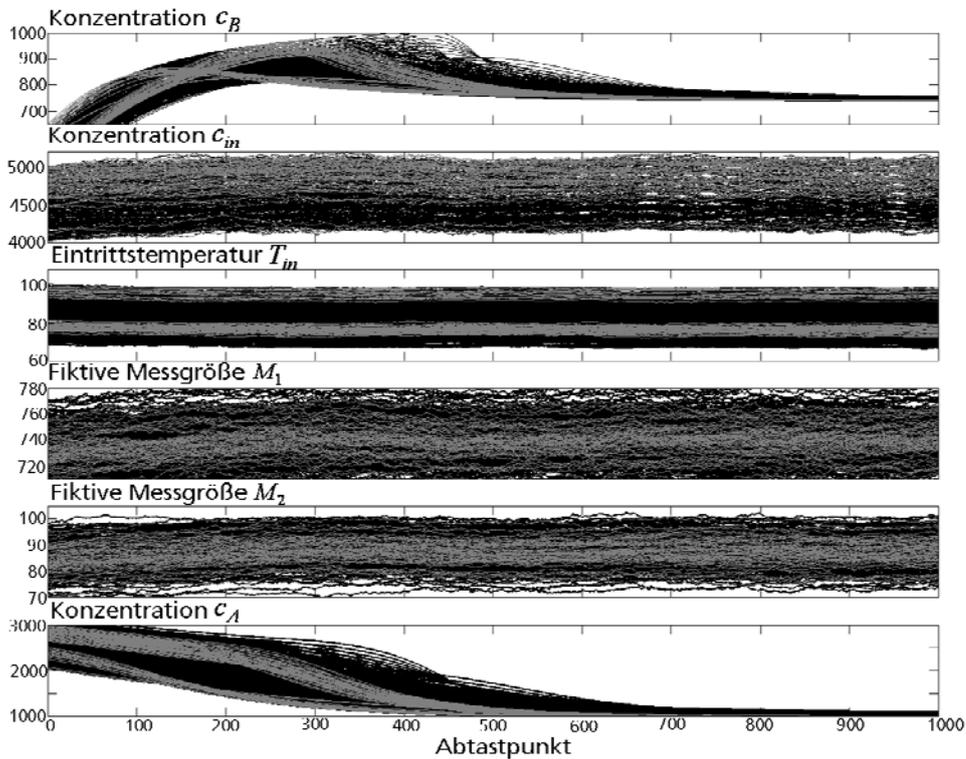


Bild 4: Verlauf der Anfahrphase des simulierten Chemiereaktors. In grau dargestellt Prozessphase mit optimalem Verlauf

Rang	Ausgewählte Merkmale	erklärte Varianz
1	Mittelwert T_{in}	62,30%
2	Mittelwert c_{in}	89,70%
3	Minimum T_{in}	89,70%

Tabelle 2: Ausgewählte Merkmale nach Selektion und erklärte Varianz des berechneten Modells

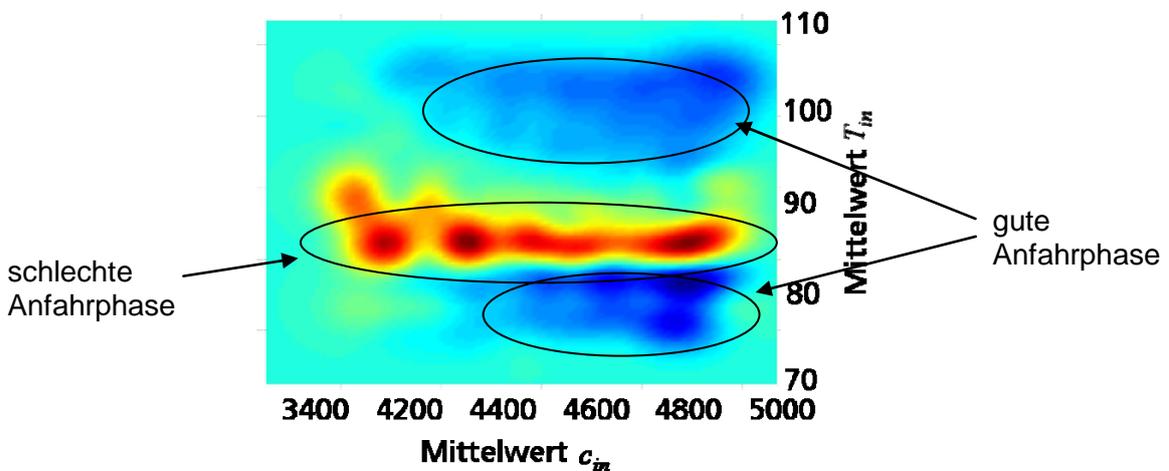


Bild 5: Dichteplot des Modells über die Mittelwerte c_{in} und T_{in} . Markiert sind Parameterkombination guter bzw. schlechter Anfahrphase

4 Online-Überwachung der Prozessgüte eines industriellen Glasziehprozesses

4.1 Zielstellung und Vorgehensweise

Das in den Abschnitten zuvor dargestellte Verfahren zur Merkmalsselektion und Modellbildung sowie die Berechnung optimaler Merkmalswerte wird im Folgenden dazu angewendet, die Anfahrphase eines industriellen Glasziehprozesses online zu überwachen. Hierzu wird je nach vorliegender erreichter Prozessphase ein Modell erzeugt, welches mit einer geringen Anzahl an Merkmalen das zuvor definierte Qualitätsmaß genau beschreibt. Hierdurch ist es möglich, frühzeitig zu erkennen, ob ein Prozess ein hohes Qualitätsmaß erzielen wird oder ob gegengesteuert werden soll, falls sich eine schlechte Produktion andeutet. Es werden also mehrere Modelle generiert, welche dann bei laufender Produktion zur Prädiktion der Prozessgüte herangezogen werden. Hierzu wird je nach laufender Produktion das jeweilige Modell ausgewählt, sodass frühzeitig gegengesteuert werden kann, falls das Modell anzeigt, dass der Prozess sich nicht in seinem optimalen Zustand befindet. Da mit fortschreitender Produktion eine immer größere Anzahl an Messdaten zur Verfügung steht, ergibt sich auch ein immer genaueres Prognosemodell. Bild 6 zeigt hierfür den Verlauf zur Überwachung der Anfahrphase. Zur Prognose der Prozessgüte werden die jeweils vorliegenden aktuellen Messverläufe vorverarbeitet (Resampling und Ausreißerdetektion), die benötigten Merkmale extrahiert und das jeweilige diskrete Modell zur Prognose der Prozessgüte ausgewählt.

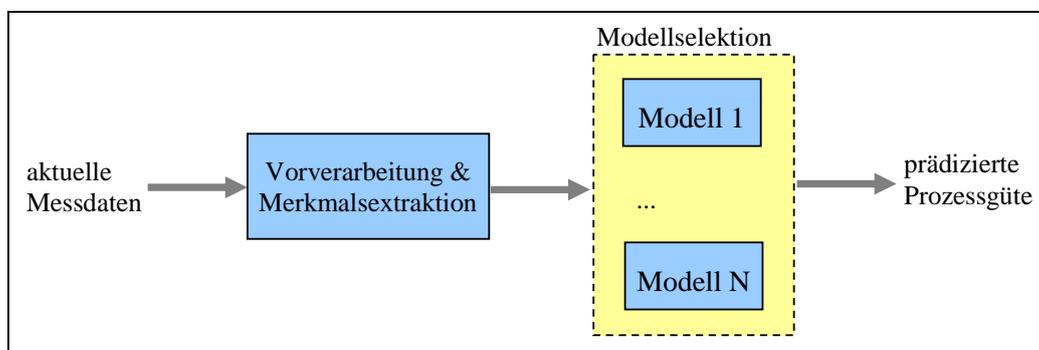


Bild 6: Online-Überwachung und Prädiktion der Prozessgüte von Batchprozessen

4.2 Optimierung der Anfahrphase eines industriellen Glasziehprozesses

Bei dem in Bild 7 schematisch dargestellten komplexen rheologischen Batchprozess wird ein vertikal hängender Glaszylinder langsam durch einen Ofen gefahren und unterhalb des Ofens mit höherer Geschwindigkeit v abgezogen, so dass ein definierter Durchmesser des Stabes eingehalten wird [10]. In der Anfahrphase soll der Durchmesser möglichst schnell und überschwingfrei erreicht werden. Der Prozess zeigt stark nichtlineares Verhalten aufgrund von dominierenden Strahlungseffekten, von Produktion zu Produktion

schwankende Materialeigenschaften sowie schleichend zeitvariantes Verhalten aufgrund von Abnutzungserscheinungen des Ofens. Daher wäre eine rigorose Modellbildung extrem aufwendig.

Ziel der Prozessführung in der Anfahrphase des Batchprozesses ist es, mit möglichst geringen Verlusten den nominalen Durchmesser D_{soll} des Glasrohres zu erreichen. Zu Beginn befindet sich der Prozess in einer gesteuerten Phase und bei Erreichen des nominalen Durchmessers wird eine Regelung aktiviert. Bild 7 zeigt einen beispielhaften Verlauf der Anfahrphase des Prozesses. Gleichzeitig sind in der Abbildung die Zeitpunkte markiert, an denen ein Merkmalsmodell erzeugt wird, welches die zu erreichende Prozessgüte online prognostiziert. Als Qualitätsmaß für die optimale Prozessführung wird der Ausschuss während der Anfahrphase des Batchprozesses herangezogen. Das Ziel besteht darin, möglichst frühzeitig während des Prozessverlaufs die relevanten Merkmale aus den gemessenen Zeitverläufen zu ermitteln.

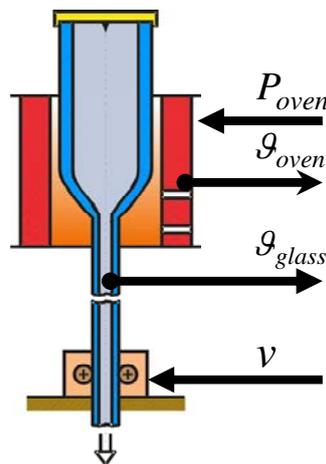


Bild 7: Industrieller Glasziehprozess mit ausgewerteten Prozessgrößen

4.3 Ergebnisse

Zur Prädiktion der Prozessgüte werden insgesamt sechs Modelle generiert. Diese prädizieren die Prozessgüte (Ausschussmasse) bei Erreichen von 30 %, 50 %, 70 %, 80 %, 90 % und 100 % des Nominaldurchmessers. Zur Analyse wurden 500 Produktionen herangezogen. Die Messdaten wurden numerisch differenziert und in zwei Segmente unterteilt. Als Merkmale wurden von jedem Segment Maximum, Minimum, Mittelwert, (Maximum - Minimum) und die Koeffizienten einer Steigungsgeraden ausgewertet. Tabelle 3 stellt hierzu die erklärte Varianz sowie die Anzahl der selektierten Merkmale für das jeweils erzeugte Modell dar. Die Ergebnisse zeigen, dass schon bei circa 50 % des Nominaldurchmessers eine erklärte Varianz von über 70 % erreicht wird und somit schon in diesem Bereich eine aussagekräftige Prognose möglich ist. Das heißt, man kann frühzeitig

erkennen, ob der Prozess zufriedenstellend geführt wird, sodass bei schlechter Güte die Prozessführung rechtzeitig angepasst werden kann.

Prozessphase	30%	50%	70%	80%	90%	100%
Anzahl Merkmale	5	5	4	6	4	6
Erklärte Varianz	52.8%	71.5%	78.3%	82.2%	85%	85.9%

Tabelle 3: Anzahl der ausgewählten Merkmale sowie erklärte Varianz der Modelle für die verschiedenen Prozessphasen

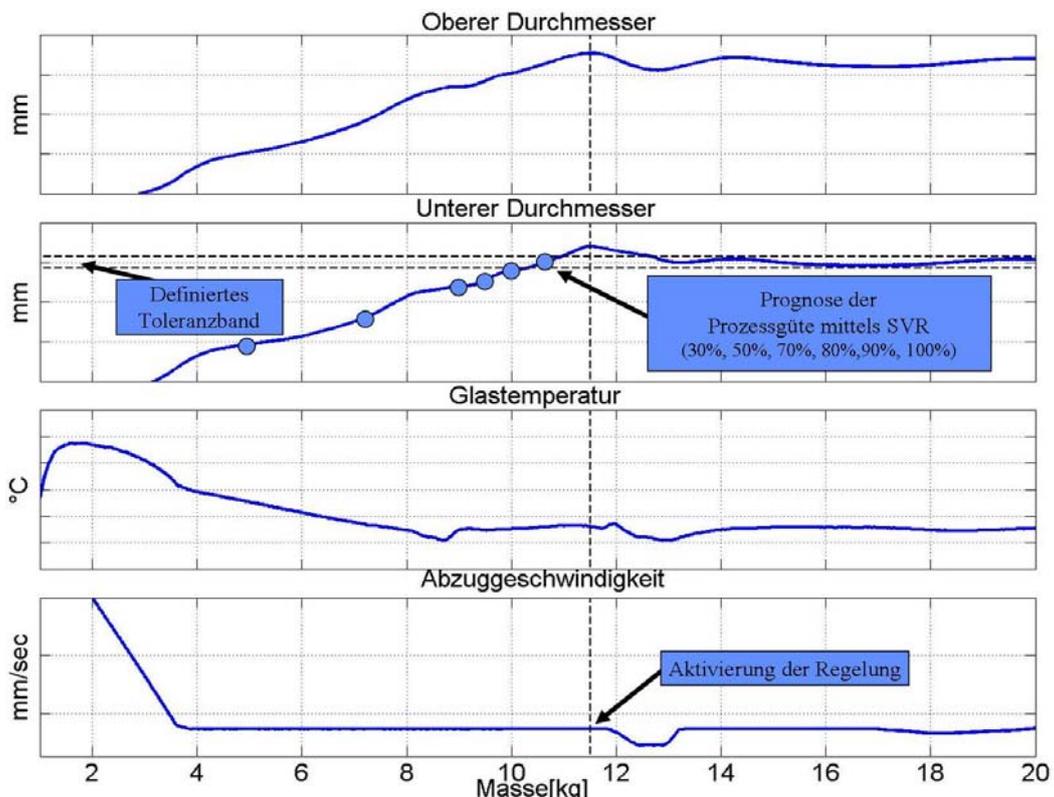


Bild 2: Überwachung und Prädiktion der Güte der Anfahrphase eines Batchprozesses durch Berechnung mehrerer datengetriebener Modelle

5. Zusammenfassung

Im vorliegenden Beitrag wurde ein auf Data-Mining-Methoden basierendes Konzept vorgestellt, mittels dem online ein definiertes Prozess-Gütemaß prädiziert werden kann. Die prinzipiellen Eigenschaften des vorgeschlagenen Konzeptes wurden zunächst anhand eines Benchmark-Prozesses (Klatt-Engell-Reaktor) in Simulationen untersucht. Weiter wurde das Konzept zur Online-Überwachung und Prädiktion der Güte der Anfahrphase eines industriellen Glasziehprozesses eingesetzt. Hierbei hat sich gezeigt, dass es schon bei circa

50 % Nominaldurchmesser möglich ist, die Prozessgüte hinreichend genau zu präzisieren, so dass bei ungünstiger Prognose frühzeitig Gegenmaßnahmen ergriffen werden können. Aktuelle Arbeiten befassen sich mit der automatisierten Anpassung der Prozessführung in Abhängigkeit der prognostizierten Prozessgüte.

Literatur

- [1] I. Witten, E. Frank, Data Mining Practical Machine Learning tools and techniques, Elsevier, 2005
- [2] C. Kühnert, T. Bernard, Online-Monitoring und Prädiktion der Prozessgüte komplexer Batchprozesse. Proc. VDI/VDE-GMA-Expertenforum Verteilte Messsysteme 2010, S. 13-24, Braunschweig, 24.-25.03.2010
- [3] D. Pyle, Data Preparation for Data-Mining, Morgan Kaufmann, 1999
- [4] N. Christianini, J. Shawe-Taylor, An introduction to Support Vector Machines, Cambridge
- [5] H. Peng, F. Long, Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, Min-Redundancy, Transaction on Pattern Analysis, 2005
- [6] C. Kühnert, T. Bernard, Extraction of optimal control patterns in industrial batch processes based on support Vector machines, IEEE Multi-Conference on systems and control, St. Petersburg, 2009
- [7] J.G. van de Vusse, Pug-flow type reactor versus tank reactor, Chem. eng. Sci., 1964
- [8] Utz. Tilman, V. Hagenmeyer, Nonlinear Model Predictive and Flatness-Based Two-Degree-of-Freedom Control Design: A comparative Evaluation in View of Industrial Application, Conference on Control Applications, 2006
- [9] K.-U. Klatt, S. Engell: Rührkesselreaktor mit Parallel- und Folgereaktion. In: VDI-Bericht Nr 1026: Nichtlineare Regelung, VDI Verlag, 1993
- [10] T. Bernard, E. Moghaddam, Nonlinear Model Predictive Control of a Glass forming Process based on a Finite Element Model, IEEE International Conference on Control Applications, Munich, 2006