

**Entwurf neuronaler Netze zur Prädiktion von Prozessgrößen
in einer Schmelzwanne für Floatglas**

Dipl.-Ing. Martin Handreg
Brandenburgische Technische Universität Cottbus-Senftenberg
Lehrstuhl Regelungssysteme und Leittechnik

1. Einleitung

Glas ist ein faszinierender und moderner Werkstoff, der durch seine Vielfältigkeit aus dem heutigen Alltag nicht mehr wegzudenken ist. Bei der industriellen Glasherstellung wird Rohmaterial (sog. Gemenge) über eine automatische Vorrichtung der Schmelzwanne zugeführt, in der es durch Wärmezufuhr schmilzt. Aufgrund der entstehenden Temperaturgradienten entwickeln sich Konvektionsströmungen, die zur Homogenisierung der Glasschmelze führen. Am Ofenausgang wird das geschmolzene Glas entnommen und zum jeweiligen Endprodukt weiterverarbeitet. Je nach Glasart (z.B. Behälter- oder Flachglas) und Produktanforderungen haben sich verschiedene Herstellungsverfahren entwickelt. In Deutschland werden 95% aller Flachgläser nach dem Floatverfahren hergestellt [1].

Die industrielle Herstellung von Glas ist ein sensibler und komplexer Prozess. Die Qualität des Endproduktes ist im hohen Maße von der Qualität der Glasschmelze abhängig. Aus diesem Grund erlangten verbesserte Regelungs- und Automatisierungstechniken für die Qualitätssicherung im Schmelzprozess in der Praxis zunehmende Bedeutung. Eine homogene Glasschmelze hängt von dem Zusammenspiel der turbulenten Oberofenprozesse und den langsamen physikalisch-chemischen Transportvorgängen im Glasbad ab. Die wohl wichtigste Prozessgröße ist die Temperatur. Um eine gleichbleibende Produktqualität zu gewährleisten, ist die strenge Einhaltung vorgegebener Temperaturniveaus unabdingbar. Mit der Zeit entwickelten sich verschiedene Herangehensweisen zur Optimierung des Schmelzprozesses. Neben herkömmlichen Temperatur- und Leistungsregelkreisen wurden erweiterte Regelstrategien integriert. Im Fokus wissenschaftlicher Forschungen sind derzeit modellbasierte prädiktive Ansätze (z.B. [2,3]). Ein weiterer Forschungsschwerpunkt ist die Analyse und Optimierung des Herstellungsprozesses anhand numerischer Strömungssimulationen (z.B. [4, 5]). Sogenannte CFD-Modelle (Computational Fluid Dynamics) sollen auf Basis der Erhaltungssätze das Verständnis der inneren physikalischen und chemischen Vorgänge erhöhen.

Das Schmelzen von Glas ist ein langsamer, kontinuierlicher Prozess, der aufgrund der mehrjährigen Ofenlaufzeiten nur wenigen geometrischen und verfahrenstechnischen Änderungen unterworfen ist. Dennoch kommt es immer wieder zu unerwarteten Produktionsschwankungen und Qualitätsmängeln. Die Ursachen liegen am thermochemischen Prozess selbst und an verfahrenstechnischen und produktionsbedingten Problemen. Chemische Prozesse charakterisieren sich gewöhnlich durch nichtlineares, zeitvariantes Verhalten mit verteilten Parametern und Mehrgrößencharakter. Die verfügbaren Stellglieder sind in der Regel ebenfalls nichtlinear. PID-Regelungen kommen aufgrund der Totzeiten und mehrstündigen Zeitverzögerungen an ihre Grenzen. Ein weiteres Problem ist die Neigung des Gemenges zur Schaumbildung. Der isolierend wirkende Schaum kann zu fehlerhaften Stelleingriffen führen. Die verwendeten Altglasscherben spielen ebenfalls eine wichtige Rolle. Deren Art, die Menge und der Zustand haben einen wesentlichen Einfluss auf die Viskosität und somit auf die Strömungsgeschwindigkeiten der Glasschmelze [6].

Neben diesen thermochemischen Problemstellungen gibt es noch eine Reihe an verfahrenstechnischen Hürden. In erster Linie stellt hier die messtechnische Erfassung der qualitätsbestimmenden Parameter eine große Herausforderung dar. Berührungslose Temperaturmessenrichtungen haben besonders im Schmelzbereich durch Verstaubungen und Schaumbildung eine eingeschränkte Genauigkeit. Der Ort der Messung ist ebenfalls von besonderer Bedeutung. Oftmals sind die wenigen Temperaturmessstellen nicht repräsentativ. Aufgrund der geringen Anzahl an möglichen Stelleingriffen können sich Temperaturschwankungen durch den gesamten Herstellungsprozess fortpflanzen. Ein weiteres, bisher wenig beachtetes, produktionsbedingtes Problem sind Beschaffenheitsschwankungen des Brenngases. Die Hüttentechnische Vereinigung der Deutschen Glasindustrie (HVG) hat in einer Umfrage festgestellt, dass bei 10 von 20 angesprochenen Glasherstellern in der Vergangenheit unerwartete Änderungen der Brenngaszusammensetzung zu Problemen bei der Glasherstellung führten [7]. Weitere Störgrößen sind zum Beispiel der im laufenden Betrieb nicht messbare Verschleiß des feuerfesten Materials, Leckagen und dadurch bedingte Falschlufteinbrüche sowie Verschmutzungen und Verunreinigungen des Gemenges.

Die beschriebenen Problemstellungen und deren unterschiedliche Lösungsansätze verdeutlichen die Komplexität des Schmelzprozesses. Die Analyse mittels CFD-Modellen ist ein oft angewandtes Hilfsmittel. Diese Modelle sind jedoch auf konkrete geometrische Rahmen bezogen und erlauben nur kundenspezifische Aussagen. Die Qualität der Ergebnisse hängt im hohen Maße von der Qualität der Randbedingungen ab. Die Modelle erfordern sehr genaue Informationen über den Prozess und geben dennoch nur ein idealisiertes Abbild. Der Aufwand zur Konstruktion der CFD-Gitter und die Rechenzeiten sind zudem nicht zu unterschätzen. Der modellbasierte prädiktive Ansatz ist vielversprechend. Für die MPC-Strategien spielen die verwendeten Streckenmodelle ebenfalls eine besondere Rolle. Die Theorie der modellbasierten prädiktiven Regelung ist für lineare und zeitinvariante Systeme erschlossen. Der Schmelzprozess ist ein interaktiver, nichtlinearer Prozess mit verteilten Parametern. Herkömmliche lineare Prozessmodelle (z.B. auf Basis von Sprungantworten) oder Zustandsmodelle sind auf einen sehr engen Arbeitsbereich begrenzt.

Die Tatsache, dass auch heute noch Wannenföhrer manuell in den Herstellungsprozess eingreifen, führte letztlich zu der Idee, ein intelligentes Prozessmodell zu entwickeln, welches auf empirische Erfahrungen zurückgreifen kann. Künstliche neuronale Netze sind für die Prozessmodellierung sehr gut geeignet, denn sie können allein aus Beobachtung des Prozesses dessen Verhalten annehmen. Zusätzlich können neuronale Netze adaptiv trainiert werden, so dass sie sich fortwährend an veränderte Umgebungsbedingungen anpassen. Die Vorteile der neuronalen Prozessidentifikation sollen später mit den Vorteilen einer modellbasierten prädiktiven Regelstrategie kombiniert werden. In diesem Beitrag liegt der Fokus im Entwurf und in der Optimierung einer geeigneten Netzstruktur. Dazu steht ein Datensatz einer Flachglasanlage zur Verfügung.

2. Datenbasis

Beim verfügbaren Datensatz handelt es sich um einen Auszug realer Messdaten einer Flachglasanlage. Der Datensatz erstreckt sich über einen Zeitraum von 23 Stunden und 58 Minuten. Es liegen insgesamt 22 gemessene Größen vor. Die Messungen erfolgten für alle Größen gleichzeitig, jedoch in unterschiedlichen Intervallen. Es wurde in jeder Minute mindestens einmal, maximal dreimal gemessen. Abbildung 2.1 zeigt eine vereinfachte Darstellung der Schmelzwanne und gibt eine Übersicht zur Anordnung der verfügbaren Prozessgrößen, welche in Tabelle 2.1 kurz erläutert werden. Es wurde im laufenden Betrieb gemessen. Die meisten Größen liegen absolut, einige jedoch relativ vor. Bei BATCH handelt es sich um eine prozentuale Geschwindigkeit der Gemengezufuhr. Diese Maßeinheit ist untypisch. Üblicherweise wird diese Größe in Tonnen pro Tag [t/d] angegeben.

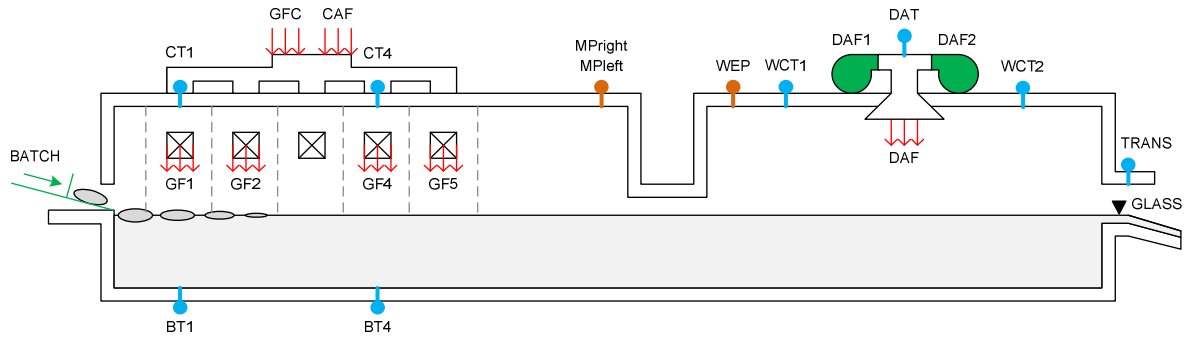


Abbildung 2.1: Vereinfachte Übersicht der Messanordnung

Tabelle 2.1: Auflistung der verfügbaren Messgrößen

Phys. Größe	Name	Bedeutung und Position	Einheit
Temperatur	CT1	Gewölbetemperatur in Brennerzone 1	K
	BT1	Bodentemperatur in Brennerzone 1	K
	CT4	Gewölbetemperatur in Brennerzone 4	K
	BT4	Bodentemperatur in Brennerzone 4	K
	WCT1	Gewölbetemperatur im vorderen Abstehbereich	K
	WCT2	Gewölbetemperatur im hinteren Abstehbereich	K
	TRANS	Gewölbetemperatur am Überlauf (Übergang zum Zinnbad)	K
	DAT	Temperatur der zugeführten Kühlluft	K
Volumenstrom	GFC	Zugeführte Gesamtgasmenge	Nm ³ /h
	GF1	Zugeführte Einzelgasmenge in Brennerzone 1	Nm ³ /h
	GF2	Zugeführte Einzelgasmenge in Brennerzone 2	Nm ³ /h
	GF4	Zugeführte Einzelgasmenge in Brennerzone 4	Nm ³ /h
	GF5	Zugeführte Einzelgasmenge in Brennerzone 5	Nm ³ /h
	CAF	Zugeführte Verbrennungsluftmenge	Nm ³ /h
	DAF	Zugeführte Kühlluftmenge (Abstehwanne)	Nm ³ /h
Druck	WEP	Herdraumdruck im vorderen Abstehbereich	Pa
	MPrignt	Rechter Herdraumdruck im hinteren Schmelzbereich	Pa
	MPleft	Linker Herdraumdruck im hinteren Schmelzbereich	Pa
Geschwindigkeit	DAF1	Prozentuale Geschwindigkeit der Kühlluftzufuhr von Lüfter 1	%
	DAF2	Prozentuale Geschwindigkeit der Kühlluftzufuhr von Lüfter 2	%
	BATCH	Prozentuale Geschwindigkeit der Gemengezufuhr	%
Glasstand	GLASS	Glasstand der Wanne am Ausgang der Abstehwanne	mm

Der Datensatz wurde aufbereitet und eingehend analysiert, um einen ersten Einblick in den zu identifizierenden Prozess zu gewinnen. Die zeitlichen Verläufe entsprachen nur bedingt den Erwartungen. Belastbare Zusammenhänge der Temperaturen und Gasmengen untereinander sowie der Einfluss des Kühllapparates konnten nicht abgeleitet werden. Eine zusätzliche Analyse mit erweiterten Identifikationstechniken der Software MATLAB (Aufstellen von Übertragungsfunktionen verschiedener Ordnungen, Zustandsmodelle, nichtlineare Modelle) lieferte ebenfalls wenig akzeptable Ergebnisse. Die Prädiktionsfähigkeit neuronaler Netze ist daher ein vielversprechender Ansatz, um ein geeignetes Prozessmodell zu identifizieren.

3. Design von künstlich neuronalen Netzen

Die Programmierung erfolgt mit der Software MATLAB. Für die Prädiktion wird ein NARX-Netz (**N**onlinear **A**uto**R**egressive with **E**Xternal Input) benötigt, welches den aktuellen Ausgangswert $y(t)$ anhand vergangener Ein- und Ausgangswerte berechnet (Abbildung 3.1).

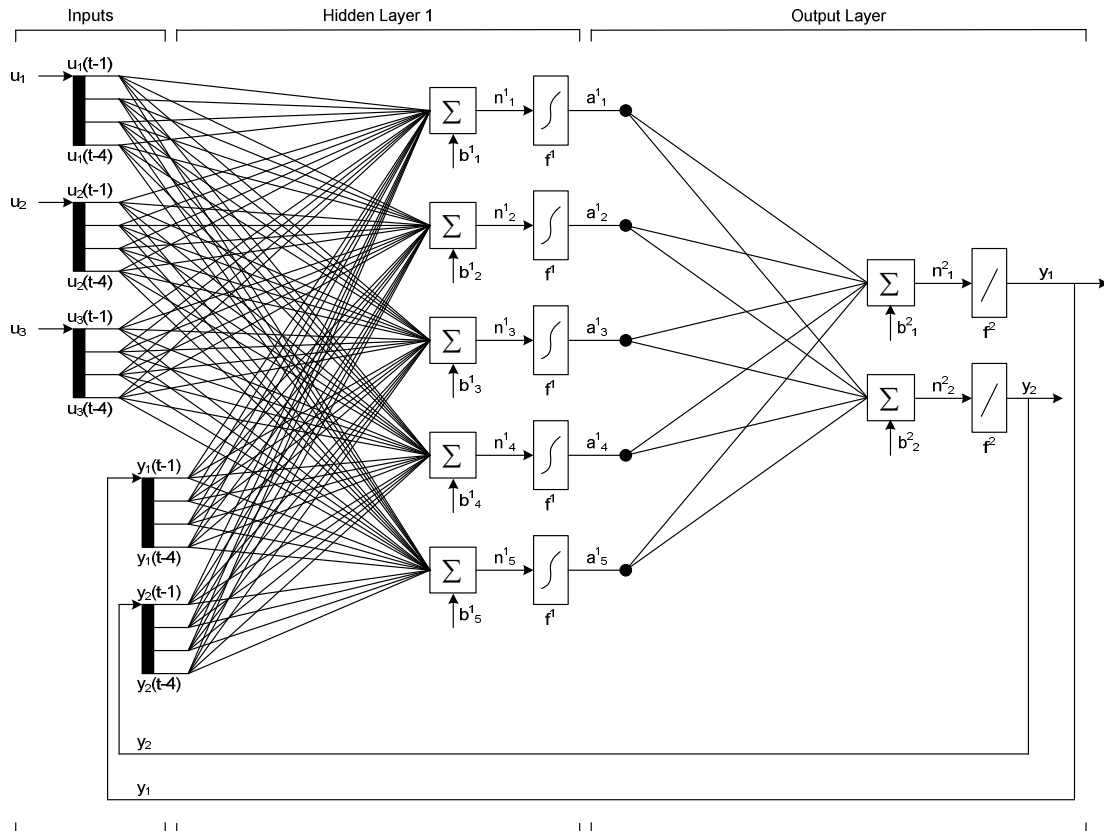


Abbildung 3.1: Signalflussplan eines zweischichtigen NARX-Netzes (3 Eingangsgrößen, 5 verborgene Neuronen, TDL=4, 2 Ausgangsgrößen, closed-loop)

Das Netz setzt sich standardmäßig aus einem Netz-Eingangsvektor $u(t)$ und zwei nacheinander folgenden Schichten zusammen. Jede Schicht beinhaltet mindestens einen Schwellvektor b und eine Wichtungsmatrix. Die Ein- und Ausgangsgrößen werden gewichtet, mit den Schwellwerten addiert und zum Schicht-Eingangsvektor $n(t)$ zusammengefasst. In jeder Schicht wird mit dem Eingangsvektor $n(t)$ und einer hinterlegten Aktivierungsfunktion der Ausgangsvektor $a(t)$ berechnet. Es kann definiert werden, wie viele historische Messzeitpunkte in die Berechnung einfließen sollen. Dieser Wert wird TDL genannt (Tapped Delay Lines). Weiterhin kann festgelegt werden, ob das Netz seine eigenen berechneten Ausgangswerte für die Berechnung heranzieht (closed-loop), oder ob es originale Messdaten der Ausgangsgrößen verwenden soll (open-loop). Neuronale Netze werden standardmäßig open-loop trainiert. Der Grund liegt darin, dass speziell beim Training das Prozessverhalten bestmöglich nachgebildet werden soll. Gleichzeitig bedeutet die Verwendung der open-loop-Architektur, dass das Netz nur Ausgangswerte zum unmittelbar nächsten Zeitpunkt berechnen kann (One Step Prediction). Eine Multi Step Prediction ist nur im closed-loop-Modus möglich. Damit lassen sich Vorhersagen über einen definierten Prädiktionshorizont treffen. Beide Netzstrukturen können in verschiedene Regelstrategien implementiert werden. Die Abbildung 3.1 zeigt ein vergleichsweise kleines Netz. Die Anzahl der Neuronen und der verwendeten Ein- und Ausgangsgrößen ist üblicherweise deutlich höher, wodurch der Rechenaufwand steigt. Der Fokus liegt auf folgenden Design-Parametern:

- Anzahl und Auswahl der Ein- und Ausgangsgrößen,
- Anzahl der verborgenen Neuronen,
- Anzahl der historischen Werte (TDL).

Neben diesen strukturellen Konfigurationsmöglichkeiten spielt die generelle Datenbereitstellung zur Prozessidentifikation eine wesentliche Rolle. Welche Daten sollen in welchem Umfang zum Training und Test bereitgestellt werden?

4. Simulationsergebnisse

4.1. Auswahl und Anzahl der Ein- und Ausgangsgrößen

Mit verschiedenen Eingangskombinationen wurden alle Ausgangsgrößen in der Abstehtwanne berechnet. Die Netze wurden stets mit den Daten der ersten 12 Stunden trainiert und anschließend mit den für das Netz unbekanntem Daten der folgenden 12 Stunden open-loop getestet (One Step Prediction). Alle weiteren Einstellungen wurden standardmäßig gewählt. Als Bewertungskriterien dienten statistische Kennzahlen der Fehler zwischen den berechneten und tatsächlichen Ausgangswerten. Die Ergebnisse für den Trainingszeitraum waren durchweg zufriedenstellend. Im Testzeitraum zeigten die trainierten Netze unterschiedliche Resultate. Zwei Netze stellten sich insgesamt als besonders geeignet heraus.

- Netz 1: BATCH, GFC, CAF, DAF → WCT2
- Netz 2: BATCH → GLASS

Abbildung 4.1 zeigt für Netz 1 die tatsächlichen und berechneten Ausgangswerte von WCT2. Selbst für einen Wertebereich außerhalb der Trainingsdaten konnten die Temperaturen erstaunlich genau berechnet werden. Der maximale positive Fehler liegt bei 0,523K. Die Standardabweichung im Testzeitraum beträgt 0,117K. Mit der Gemengezugabe, der Verbrennungsluft- und der Kühlluftmenge sind die wohl wichtigsten Stellgrößen enthalten. Das zweite Netz liefert ebenfalls gute Ergebnisse. Eine zusätzliche Modifikation der Netzstruktur (keine Nutzung der historischen Ausgangswerte) bestätigte einen scheinbar direkten Zusammenhang beider Prozessgrößen.

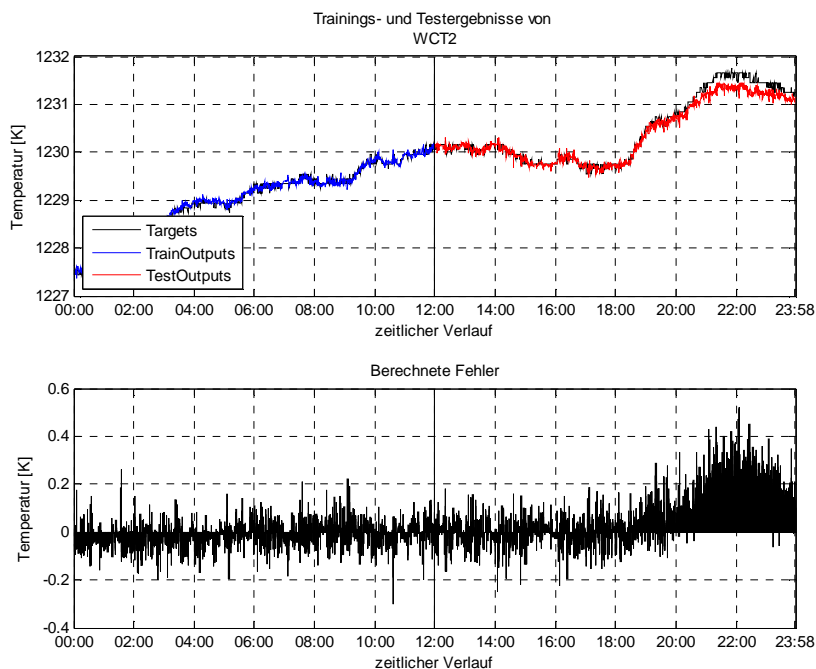


Abbildung 4.1: Trainings- und Testergebnis Netz 1

Die Simulation hat gezeigt, dass die Ergebnisse bei gleichzeitiger Berechnung der Ausgangsgrößen geringfügig schlechter sind als bei einzelner Berechnung. Weiterhin wurde festgestellt, dass mehrere Eingangsgrößen nicht zwangsweise zu einer höheren Genauigkeit des Netzes führen. Vielmehr ist die Auswahl der Eingangsgrößen entscheidend. Die Größen BATCH und DAF zeigten dabei eine besonders positive Wirkung auf die Simulationsergebnisse. Die Gewölbetemperatur TRANS am Überlauf konnte mit keiner Eingangskombination zufriedenstellend berechnet werden. Die Einzelgasmengen hatten keinen erkennbaren Einfluss auf die Simulationsergebnisse.

4.2. Einfluss der verborgenen Neuronen

Der Einfluss der Neuronenanzahl wurde an den zwei evaluierten Netzen untersucht. Ausschlaggebend sind die berechneten Fehler für den Testzeitraum. In Abbildung 4.2 sind die Standardabweichungen für beide Netzausgänge über der Neuronenanzahl aufgetragen.

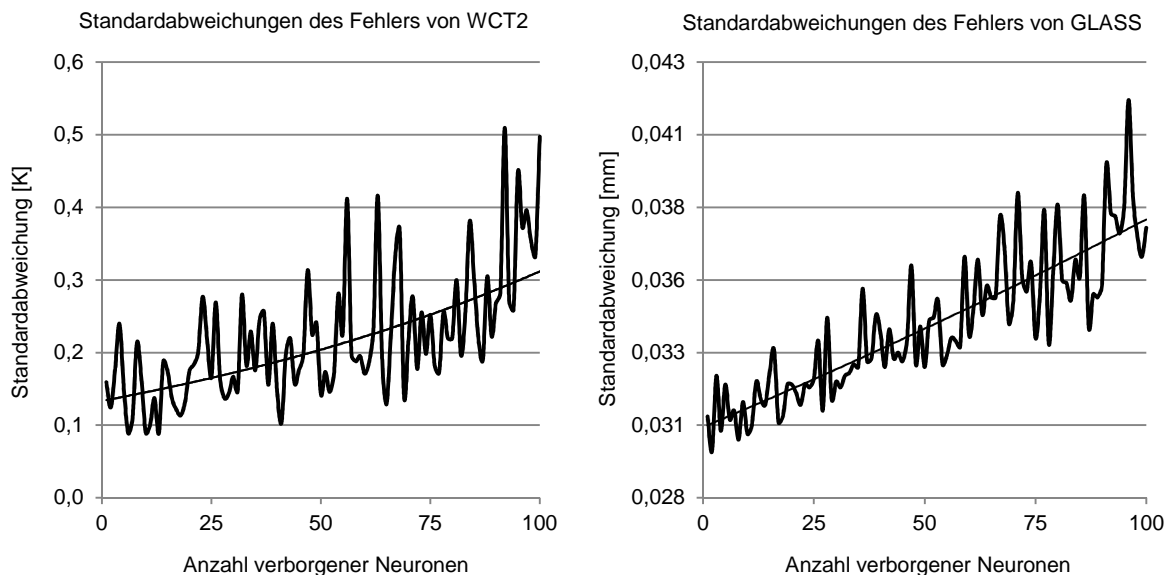


Abbildung 4.2: Standardabweichungen beider Netze in Abhängigkeit der Neuronenanzahl

Die Verläufe ähneln sich und sind repräsentativ für alle weiteren Netzkombinationen. Es ist zu erkennen, dass die Standardabweichungen bei kleinen Änderungen der Neuronenanzahl deutlich schwanken. Eine Wiederholung der Simulation führt nicht unmittelbar zu den gleichen Ergebnissen, der Trend ist jedoch reproduzierbar. Mit steigender Anzahl verborgener Neuronen verringert sich die Genauigkeit der Netze. Weiterhin hat sich gezeigt, dass mehrere Eingangsgrößen die Schwankungen noch verstärken. Der Rechenaufwand steigt mit steigender Neuronenanzahl. Es wird der Bereich zwischen 5 und 20 Neuronen empfohlen. In diesem Bereich sind die Ergebnisse weitestgehend reproduzierbar. Unter 3 Neuronen sind besonders beim Training die Ergebnisse nicht zufriedenstellend.

4.3. Einfluss der historischen Werte

Der TDL-Wert gibt die Anzahl der historischen Messzeitpunkte an, die zur Berechnung des aktuellen Ausgangswertes berücksichtigt werden. Die Trainings- und Testergebnisse von Netz 1 sind in Abbildung 4.3 für zwei verschiedene TDL-Werte dargestellt. Der TDL-Wert 120 entspricht einer Stunde. Die berechneten Outputs haben beim TDL-Wert 120 eine erkennbar größere Schwankungsbreite. Die Standardabweichung von 0,36K im Testzeitraum hat sich im Vergleich zum TDL-Wert 10 verdreifacht (0,12K).

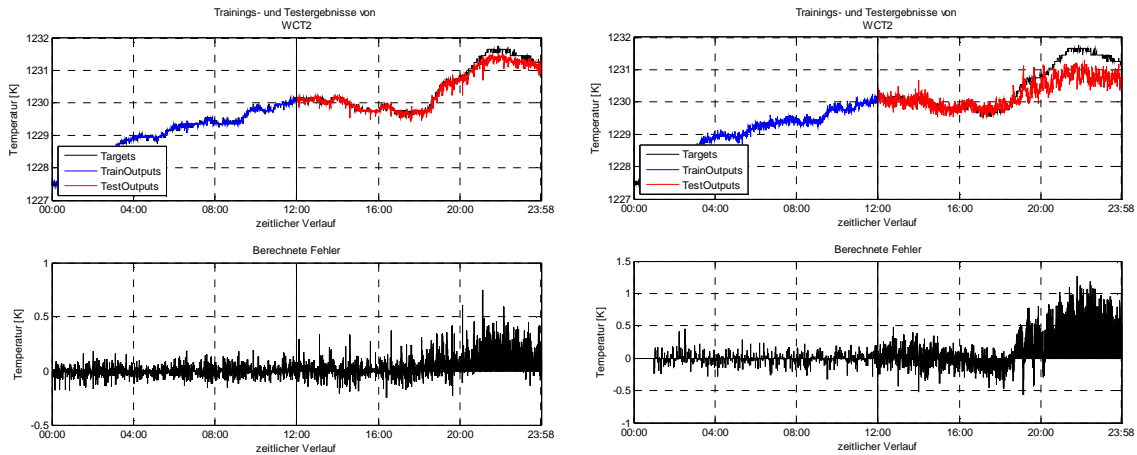


Abbildung 4.3: Vergleich der Simulationsergebnisse (links: TDL = 10, rechts: TDL = 120)

Standardabweichungen des Fehlers von WCT2

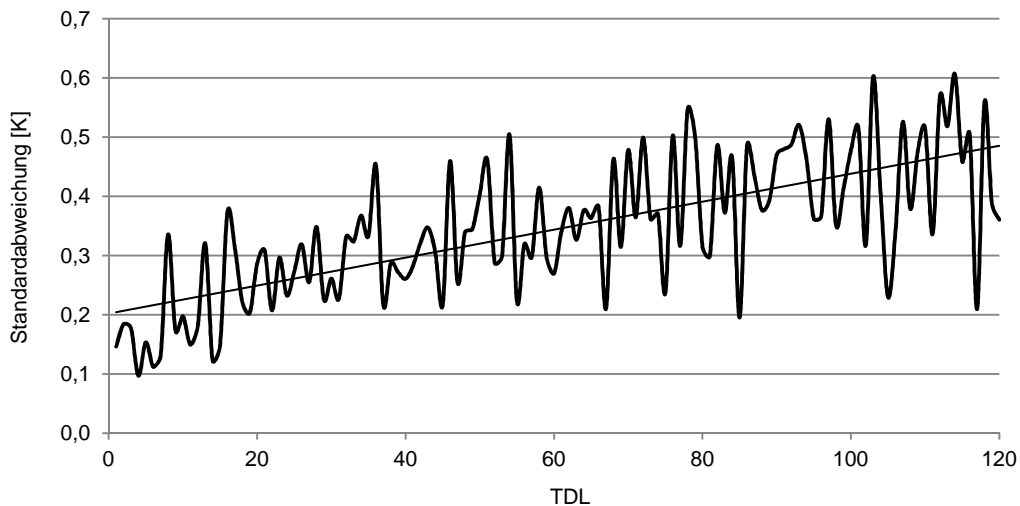


Abbildung 4.4: Berechnete Standardabweichungen von WCT2 im Testzeitraum

Abbildung 4.4 zeigt alle berechneten Standardabweichungen. Es ist erkennbar, dass die Ergebnisse bei kleinen TDL-Änderungen erneut schwanken. Der Trend ist jedoch reproduzierbar und für alle anderen Ausgangsgrößen repräsentativ. Das Ergebnis dieser Untersuchung entspricht nicht den Erwartungen. Mit steigenden TDL-Werten nimmt die Genauigkeit der Netze ab. Es wird ein TDL-Wert zwischen 5 und 20 empfohlen. Für diesen Bereich sind die Ergebnisse konsistent. Besonders bei sehr großen TDL-Werten sind die Ergebnisse nicht vollständig reproduzierbar und großen Schwankungen unterworfen.

4.4. Einfluss der Trainings- und Testzeiträume

Für diese Untersuchung wurden die Trainings- und Testzeiträume variiert. In Abbildung 4.5 sind für Netz 1 die Simulationsergebnisse (Trendlinien) für drei ausgewählte Testzeiträume abgebildet. Mit zunehmender Trainingsdauer nähern sich die Verläufe an, die Standardabweichungen sinken, der Einfluss der Testzeit verringert sich. Bei geringen Trainingszeiten nehmen die Standardabweichungen für längere Testzeiträume allerdings zu. Aus diesem Grund sollte die Trainingsdauer mindestens 6 Stunden betragen (Richtwert). Dieser Wert ist von Ausgangsgröße zu Ausgangsgröße unterschiedlich.

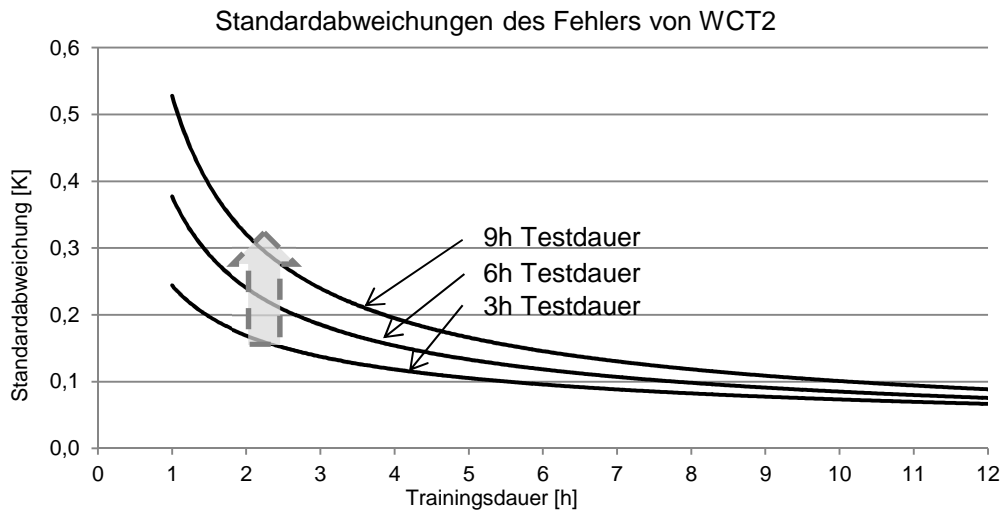


Abbildung 4.5: Standardabweichungen von WCT in Abhängigkeit der Trainingsdauer

4.5. Multi Step Prediction

Mit der Multi Step Prediction können die Netze zusätzlich auf Genauigkeit untersucht werden. Die Netze wurden open-loop trainiert und im Anschluss in closed-loop-Netze umgewandelt. Die Simulation zum Einfluss der verborgenen Neuronen führte zu einem überraschenden Ergebnis. Die Neuronenanzahl hat keinen Einfluss auf die Prädiktionsergebnisse. Der Einfluss der Tapped Delay Lines hat sich im Vergleich zum open-loop-Test ebenfalls verändert (Abbildung 4.6). Die Abbildung zeigt prinzipiell sehr gute Prädiktionsergebnisse. Je größer die TDL-Werte sind, umso besser kann die Charakteristik des tatsächlichen Signals (Targets) angenommen werden. Jedoch sind die Ergebnisse für hohe TDL-Werte nicht immer reproduzierbar. Grund sind vermutlich numerische Ungenauigkeiten aufgrund des deutlich höheren Rechenaufwandes. Vereinzelt kamen auch unrealistische Prädiktionsergebnisse heraus. Es wird daher ein TDL-Wert zwischen 10 und 60 empfohlen. Außerhalb dieses Bereiches sind die Ergebnisse inkonsistent.

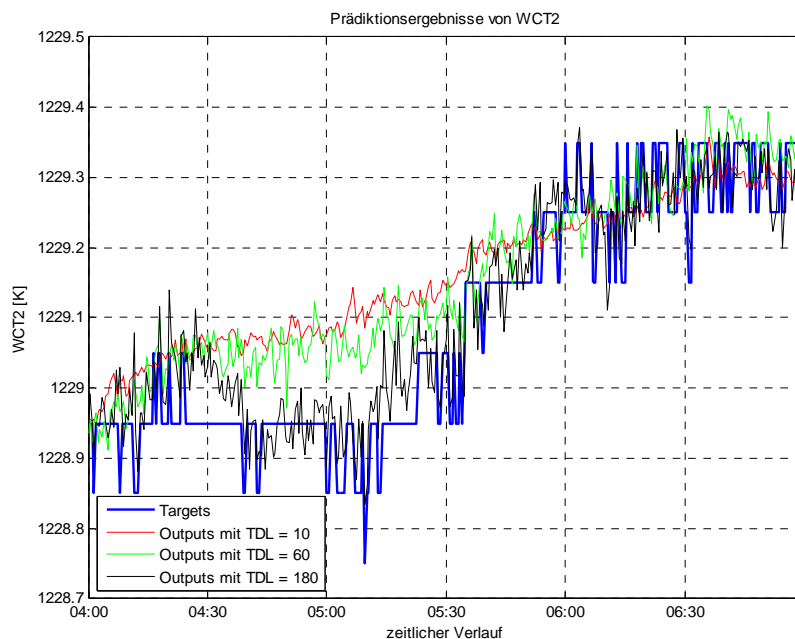


Abbildung 4.6: Prädiktionsergebnisse von WCT2 bei verschiedenen TDL-Werten

Grundsätzlich lässt sich sagen, dass die Prädiktionsergebnisse, insbesondere für WCT2, durchaus vielversprechend sind. Ein wichtiger Faktor zur Bewertung der Simulationsergebnisse ist auch der ausgewählte Prädiktionszeitraum. Je länger dieser Zeitraum ist, desto größer werden die Abweichungen (Fehlerfortpflanzung). Abbildung 4.7 zeigt das Prädiktionsergebnis von WCT2 für den unmittelbar nach dem Training folgenden Zeitraum. Die Temperatur konnte über mehrere Stunden hinreichend genau vorausberechnet werden. Die Simulationsergebnisse für andere Ausgangsgrößen waren weniger zufriedenstellend. Obendrein müssen die Ergebnisse differenziert betrachtet werden. Der zeitliche Verlauf der tatsächlichen Ausgangsgröße im Prädiktionszeitraum sollte bei der Auswertung berücksichtigt werden.




Abbildung 4.7: Prädiktionsergebnis von WCT2 über 6 Stunden

5. Zusammenfassung und Ausblick

Es wurde gezeigt, dass unter bestimmten Voraussetzungen neuronale Netze ausgewählte Prozessgrößen hinreichend genau berechnen können. Dabei wurden sehr genaue open-loop-Modelle aufgestellt. Für die Multi Step Prediction eignete sich besonders Netz 1. Die Simulationsergebnisse widersprachen teilweise den Erwartungen. Mehr Informationen, sei es in Form mehrerer Eingangsgrößen oder mehrerer historischer Messzeitpunkte, führen nicht zwangsläufig zu einer höheren Genauigkeit des Netzes. Vielmehr haben die Auswahl der Ein- und Ausgangsgrößen und die ausgewählten Trainings- und Testzeiträume besonderen Einfluss. Die Simulationsergebnisse sind unter den empfohlenen Bedingungen stets reproduzierbar. Neben den vorgestellten Einflussparametern gibt es noch eine Reihe weiterer Faktoren, die die Genauigkeit des Netzes beeinflussen. Darunter zählen vor allem die definierten Aktivierungsfunktionen und Trainingsmethoden. Weiterhin kann untersucht werden, ob sich die relevanten Temperaturen durch andere Temperaturen berechnen lassen. Diese Möglichkeiten sind Bestandteil aktueller Untersuchungen.

Geeignete neuronale Prozessmodelle können in eine modellbasierte prädiktive Regelung eingebettet werden. Das Netz berechnet mit möglichen Stellgrößen die jeweiligen Ausgangswerte für einen bestimmten Prädiktionshorizont. Anschließend erfolgt durch Minimierung einer definierten Gütefunktion eine Optimierung, bei der die beste Stellgröße an den eigentlichen Prozess ausgegeben wird. Für die programmiertechnische Realisierung ist ebenfalls noch weiterer Entwicklungsaufwand erforderlich.

Zusammenfassend kann festgestellt werden, dass neuronale Netze zur Prozessidentifikation in Schmelzwannen herangezogen werden können. Die Konfigurationsmöglichkeiten sind sehr vielfältig und vom jeweiligen Anwendungsfall abhängig. "Essentially all models are wrong, but some models are useful" (George Edward Pelham Box, britischer Statistiker, 1919-2013).

Ein besonderer Dank gilt der STG Combustion Control GmbH & Co KG (Cottbus) für die Bereitstellung der Daten.

Literatur

- [1] Boehm, Petra: Herstellungsprozesse für Flachglas; Vortrag im Rahmen des HVG-Seminars "Industrielle Glasherstellung - Von den Rohstoffen zum Qualitätsprodukt"; Offenbach 12.05.2015.
- [2] Chmelar, Josef; Muysenberg, Erik; Bodi, Robert: Supervisory advanced control of glass melters and forehearth by the GS expert system; *Glastech. Ber. Glass Sci. Technol.* 73 (2000) 9, S. 276-284.
- [3] N.N.: ACSI's Model-Based Controller Maximizes Performance in Glass Forehearths: unter <http://www.acsitoledo.com/FH%20Model%20Based%20Control.pdf> (abgerufen am 10.04.2013).
- [4] Beerkens, Ruud: Heutige Möglichkeiten zur Modellierung von Glasschmelzöfen – Voraussagen zur Qualität des Glasschmelzprozesses; *Glastech. Ber. Glass Sci. Technol.* 71 (1998) 4, S. N35-N47.
- [5] Schobben, R. R. J. J.: Identification & CFD Model Based Control of a Glass Furnace. Diss. Master's thesis, Eindhoven University of technology, 2009.
- [6] Hrsg. VDMA, Frankfurt a.M. und Messe Düsseldorf: Beitrag aus GLASS Glasherstellung - Veredelung, Prozesse und Technologie; "Viskosität als Prozess- und Regelgröße"; Firma SiliTec GmbH; Edition 2; Woeste Druck + Verlag GmbH & Co.KG, Essen, 2002, S. 42-51.
- [7] Fleischmann, Bernhard: Einfluss von Gasbeschaffenheitsänderungen auf den Glasherstellungsprozess - Teil 1: „Aktuelle Situation“; HVG-Mitteilung Nr. 2160; Hüttentechnische Vereinigung der Deutschen Glasindustrie e.V., Offenbach, 2013.