

## **Teil II: Eingehende Darstellung**

**Zum Teilvorhaben** Data Mining und KI zur optimierten prozessübergreifenden Steuerung

**Des Verbundprojektes** Digitale Kautschukverarbeitung am Beispiel Extrusion (DIGITRUBBER)

**Laufzeit des Verbundprojektes:** 01.04.2021 – 31.03.2024

### **1. Darstellung der Verwendung der Zuwendung sowie der erzielten Ergebnisse**

Am ITA werden die Arbeitspakete 6.1 (Datenbankaufbau) und 6.2 (Konzeptentwicklung zur online-Optimierung der Kautschukextrusion) bearbeitet. In AP 6.1 liegt der Schwerpunkt zunächst auf der Erstellung von Lasten- und Pflichtenheft, um die Abstimmung mit den Projektpartnern sicherzustellen. Anschließend folgt die Auseinandersetzung mit der Datenaufnahme, wobei sowohl auf bestehende Messtechnik als auch auf neue Messtechnik der Projektpartner zurückgegriffen wird. Letztendlich wird basierend auf den Steuer- und Messgrößen ein Data-Mining-Algorithmus zur Identifikation von prozessimmanenten Wirkzusammenhängen entwickelt. Parallel hierzu finden iterative Versuche zum Test und zur Validierung der Messtechnik und des Data-Mining-Algorithmus statt.

In AP 6.2 wird zunächst ebenfalls ein Lasten- und Pflichtenheft zur KI-basierten Steuerung mit den Projektpartnern entwickelt. Zusätzlich werden Schnittstellen zur Ansteuerung der Extrusionsprozessstrecke integriert. Ebenso findet die Entwicklung und Implementierung der KI statt, die zunächst dezentral in einer simulativen Umgebung trainiert wird. Analog zum Data-Mining-Algorithmus wird die KI-basierte Steuerung iterativ getestet und validiert.

#### **AP 6.1.1: Lasten-/Pflichtenheft**

In diesem Arbeitspaket geht es einerseits um die Festlegung von Zuständigkeiten der am Arbeitspaket 6.1 beteiligten Institute (HsH, ITA und TIB) für die Datenaufnahme, der Strukturierung der Daten und dem Datenbankaufbau. Zusätzlich geht es um die Erfassung der bereitgestellten Messdaten der anderen beteiligten Institute (DIK, IAPG, IFNANO und IMR).

Dabei liegt der Aufgabenschwerpunkt des ITA auf der hardwareseitigen Einbindung der aufgenommenen Daten am Mischer, an der Walze und am Extruder. Hierzu werden auf einem zentralen Industrie-PC alle Messdaten der Bestandsanlagen aber auch alle Messdaten der zu integrierenden Messtechnik der Institute IAPG, IFNANO und IMR mit einem Zeitstempel gespeichert. Anschließend wird mit Hilfe eines Data-Mining-Algorithmus aus den aufgenommen und gespeicherten Daten Zusammenhänge detektiert, sodass eine später zu entwickelnde KI auf diese Zusammenhänge zugreifen und den Prozess so steuern kann, sodass sichergestellt wird, dass ein möglichst hoher Anteil an Gutteilen produziert wird.

#### **AP 6.1.2: Datenaufnahme**

Zu Beginn des Arbeitspaketes werden sämtliche Steuer- und Messgrößen der Prozesse Mischen, Walzen und Extrudieren gesammelt. Dabei dienen die Messgrößen später der KI um Abweichungen von den Soll-Werten zu detektieren. Mittels KI wird frühzeitig auf die Steuergrößen Einfluss genommen, damit die Messwerte nicht aus einem vorher zu definierenden Korridor fallen. Die Zusammenhänge zwischen Mess- und Steuergrößen werden vor dem Einsatz der KI über einen Data-Mining-Algorithmus ermittelt. Dieses Vorgehen wird im AP 6.1.3 näher beschrieben.

Zunächst werden die gesammelten Steuer- und Messgrößen der einzelnen Prozessschritte dargestellt. In Abbildung 1 sind die Steuer- und Messgrößen des Mixers dargestellt. Dabei lässt sich das System über die Mischzeit und die Zugabezeitpunkte der verschiedenen Bestandteile der Kautschukmischung beeinflussen. Ebenso hat der Füllgrad, also die Masse der

zu verarbeitenden Mischung, die eingestellte Temperatur, die Drehzahl als auch der Stempelweg einen Einfluss auf die Mischung. Veränderungen können über die Temperatur der Mischung, den Stempeldruck und das Drehmoment des Mischwerks gemessen werden.

In Abbildung 2 sind die Steuergrößen des Walzwerks angegeben. Das Walzwerk lässt sich über den Walzenspalt, der dem Abstand der beiden fördernden Walzenrollen entspricht, die Mischzeit, die Walzendrehzahl und die Temperierung der Walzen einstellen. Messwerte werden in diesem Prozessschritt nicht aufgenommen. Da auch keine Kontrolle der Mischung nach dem Walzprozess stattfindet kann das Walzwerk auch nicht in der Datenverarbeitung berücksichtigt werden.

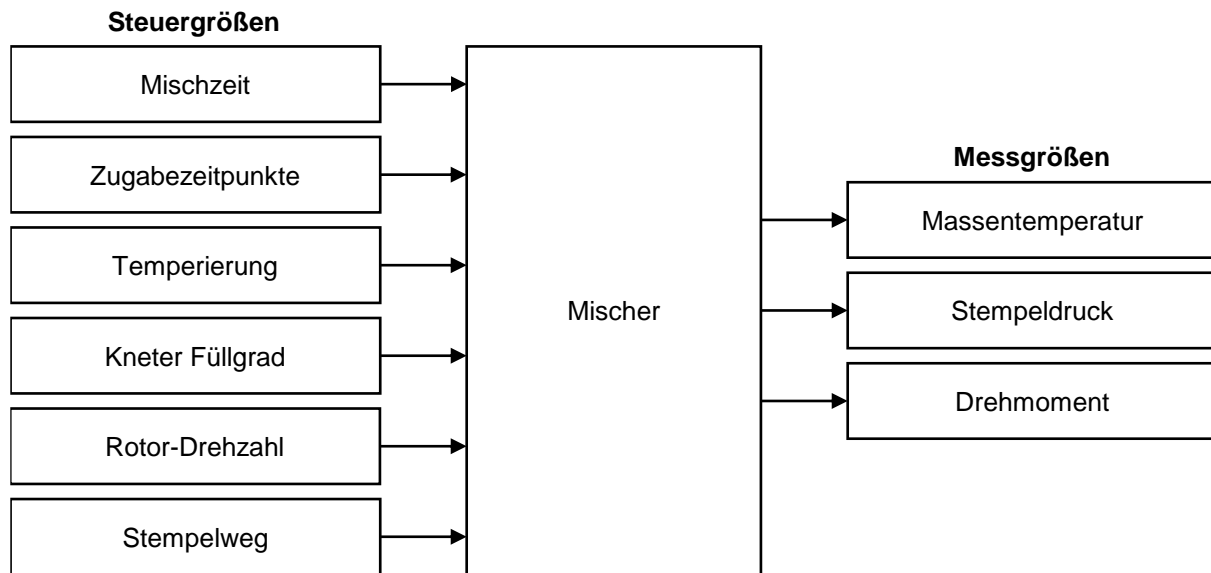


Abbildung 1: Steuer- und Messgrößen des Mischers




Abbildung 2: Steuer- und Messgrößen der Walze

In Abbildung 3 ist die angebrachte Messtechnik am Extruder dargestellt. Am Extruder werden drei Temperaturen (in Verarbeitungsrichtung:  $T_a$ ,  $T_b$  und  $T_{Wz}$ ) aufgenommen. Zusätzlich nimmt im Schneckenkanal ein Messschwert ein radiales Temperaturprofil auf. Wobei sieben Messwerte ( $T_1$  bis  $T_7$ ) in der Kautschukmischung selbst aufgenommen werden und ein Sensor die Temperatur des Werkzeuges ( $T_8$ ) misst. Zusätzlich wird der Werkzeugdruck ( $p_{Wz}$ ) ermittelt. Diese Messgrößen sind auch in Abbildung 4 dargestellt. Des Weiteren wird durch Beteiligung der Institute IAPG, IFNANO und IMR das Extrudat nach dem Austritt aus der Matrize charakterisiert. Hierzu wird die Geometrie des Extrudats sowie dessen Temperatur erfasst. Zusätzlich wird mittels laserinduzierter Plasmaspektroskopie (LIBS) die Verteilungsgüte von Zink im Extrudat ermittelt. So lassen sich Rückschlüsse auf die Homogenität des Extrudats ziehen. Ebenso sind in Abbildung 3 der Einzug des Fütterstreifens und das Transportband zum

Abtransport des Extrudats dargestellt.




Abbildung 3: Messgrößen am Extruder

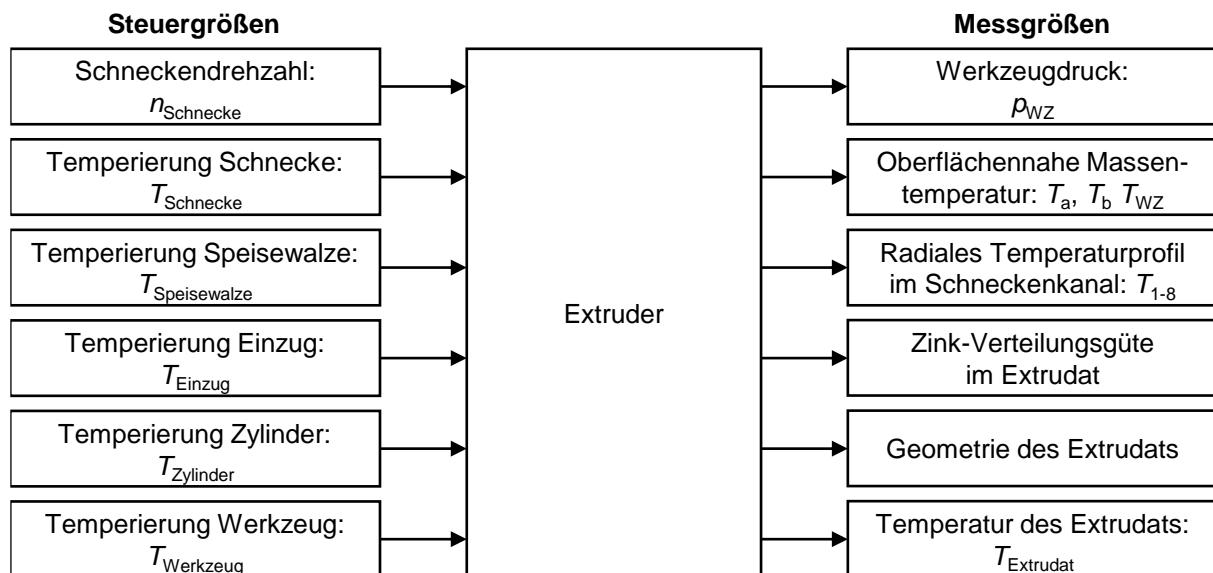


Abbildung 4: Steuer- und Messgrößen des Extruders

Zur Speicherung der aufgenommenen Daten wird ein Industrie-PC mit integrierter Datenbank, in der alle Steuer- und Messwerte mit einem Zeitstempel gespeichert werden, in die Prozesskette implementiert. Dabei wird sich auf die Steuer- und Messwerte des Mixers und des Extruders beschränkt, da keine Messwerte am Walzwerk aufgenommen werden. Die Steuer- und Messwerte können exportiert werden, sodass der Data-Mining-Algorithmus dezentral zur Identifikation von Wirkzusammenhängen eingesetzt und die KI zur Steuerung der Prozesskette dezentral trainiert werden kann. Die Schnittstellen des Industrie-PCs als auch die

Datenbank zur Speicherung von weiteren Messwerten sind modular erweiterbar, sodass weitere Messtechnik auch über das Projektende hinaus kontinuierlich in die Datenbank eingepflegt werden kann.

#### **AP 6.1.5: Data-Mining-Algorithmus**

Anhand der aufgenommenen Datensätze werden Zusammenhänge zwischen den Steuer- und Messgrößen mit Hilfe eines Data-Mining-Algorithmus detektiert. Besonders die Korrelationen zwischen Mess- und Steuergrößen sind von Interesse, da im späteren Verlauf des Projektes, Messgrößen mittels der Steuergrößen beeinflusst werden sollen. Zu Beginn wird ein Datensatz aus 3.022 Messsätzen aufgenommen, der nur den Extrusionsprozess betrachtet. Im Projektverlauf wird die Datenbasis kontinuierlich erhöht, bis eine Summe von 14.923 Messsätzen für das Training des Algorithmus erreicht ist. Die Datensätze werden im Sekundentakt aufgenommen.

*Korrelationsanalyse:* Bevor mit der Entwicklung des Algorithmus begonnen wird, erfolgt zunächst eine Korrelationsanalyse. Mit dieser können erste Zusammenhänge zwischen den Steuer- und Messgrößen aufgezeigt werden, um die Auswahlmöglichkeiten innerhalb der Modellarchitekturentwicklung einzugrenzen. Ein Werkzeug um einen linearen Zusammenhang der Daten a priori abschätzen zu können ist die Berechnung des Pearson-Korrelationskoeffizienten. Dieser ist von der Maßeinheit der Messung unabhängig und kann einen Wert zwischen -1 (vollständiger negativer linearer Zusammenhang) und +1 (vollständiger positiver linearer Zusammenhang) annehmen. Bei einem Koeffizienten von 0 sind die Werte nicht linear miteinander korreliert. Die Berechnung der Pearson-Korrelationskoeffizienten ergeben für den Extrusionsdatensatz lediglich moderate Werte. Beispielsweise besteht ein Pearsonkoeffizient von 0,58 zwischen der Drehzahl  $n$  und dem Temperaturwert  $T_3$ , wohingegen die Temperatur  $T_{\text{Werkzeug}}$  einen Pearsonkoeffizienten von 0,68 gegenüber  $T_3$  aufweist. Die verbleibenden Parameter verfügen über vergleichbare Werte. Es ist davon auszugehen, dass auch nichtlineare Zusammenhänge zwischen den Steuer- und Messgrößen bestehen. Nichtsdestotrotz wird zunächst mit der Entwicklung eines linearen Regressionsmodells begonnen, da mit diesem das Abbilden von linearen Zusammenhängen möglich ist und die eventuelle Gegebenheit von Nichtlinearitäten weiterhin eingegrenzt werden kann. Wenn mit dem Regressionsmodell keine hinreichend hohe Prädiktionsgenauigkeit erreicht wird, erfolgt die Entwicklung eines neuronalen Netzes.

*Regressionsmodell:* Aufbauend auf den festgestellten linearen Zusammenhängen wird ein lineares Regressionsmodell zur Vorhersage der Messdaten aufgebaut. Zuerst werden alle Daten, also sowohl Mess- als auch Steuergrößen als Eingangsdaten für das Modell verwendet, um jeweils einen Messwert hervorzusagen. Der jeweils hervorzusagende Messwert wird dabei nicht als Eingangsgröße verwendet, wohingegen die verbleibenden Mess- und Steuergrößen dafür eingesetzt werden. Die Daten werden in 80 % Trainingsdaten und 20 % Test- bzw. Validierungsdaten aufgeteilt. Zum Modellaufbau und Training wird die SCIKIT-Bibliothek unter PYTHON verwendet. Dabei handelt es sich um eine open-source Software-Bibliothek zum maschinellen Lernen. Das lineare Modell besteht aus den zuvor beschriebenen Steuer- und Messgrößen, die einzeln mit ihrem Faktor multipliziert und anschließend addiert die jeweilige Ausgangsgröße ergeben. Zuerst wird das lineare Modell anhand der Trainingsdaten aufgebaut, indem die Faktoren der Eingangsgrößen bestimmt werden, mit denen die jeweilige Ausgangsgröße bestmöglich angenähert wird. Bestmöglich bedeutet in diesem Fall die Minimierung der mittleren quadratischen Abweichung (MSE) zwischen dem durch das lineare Modell vorhergesagten Wert und dem tatsächlichen Wert der gesuchten Größe. Danach wird das lineare Modell auf die Testdaten angewendet, um die gesuchte Messgröße vorherzusagen.

Dieses Vorgehen ist in Abbildungen 5 beispielhaft anhand von  $T_1$ ,  $T_3$ ,  $T_{wz}$  und  $p_{wz}$  dargestellt. Dabei sind in schwarz die tatsächlich aufgenommenen Messwerte, in orange der Trainingsverlauf des aufgebauten linearen Modells und in blau die Test- bzw. Validierungsvorhersage abgebildet. Zu erkennen ist, dass das Modell die Temperaturen des Messschwertes gut vorhersagen kann. Dies ist aufgrund der starken linearen Korrelation der Messwerte des Messschwertes, die durch den Pearson-Korrelationskoeffizient festgestellt wird, zu erwarten.

Schlechter durch das lineare Modell können die Messwerte der Temperatur  $T_{Wz}$  und besonders des Drucks  $p_{Wz}$  vorhergesagt werden. Auffällig ist auch, dass das Modell bei diesen Daten bereits die Trainingsdaten nicht gut annähern kann. Wie in der Abbildung 5 zu sehen, weicht bereits der Trainingsverlauf stark von den tatsächlichen Werten ab. Wobei zumindest qualitative Übereinstimmungen festgestellt werden können. Dies bedeutet, dass das Modell in diesem Fall keine starken linearen Zusammenhänge ausnutzen kann und daher schon der Trainingsverlauf die Wirklichkeit nicht ausreichend genau abbildet. Durch ein angepasstes Modell, das auch nichtlineare Zusammenhänge ausnutzen kann, ist davon auszugehen, dass die Zusammenhänge besser abgebildet und damit auch vorhergesagt werden können.

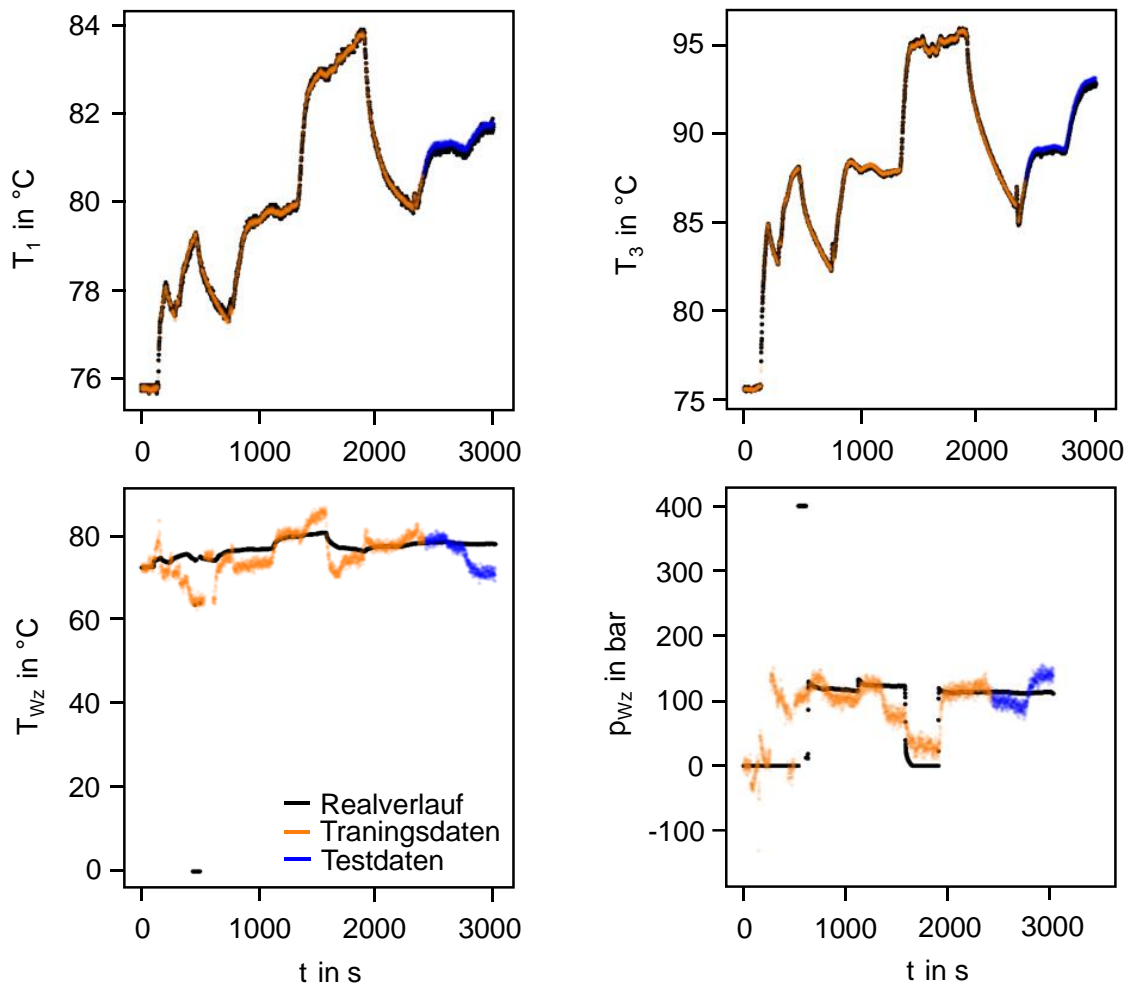


Abbildung 5: Lineares Regressionsmodell: Prädiktion für  $T_1$ ,  $T_3$ ,  $T_{Wz}$ ,  $p_{Wz}$

*Vorhersage auf Grundlage der Steuergrößen:* In den bisherigen Anwendungen des Data-Mining-Algorithmus wurde versucht, die Messdaten durch alle übrigen Daten vorherzusagen. Das Ziel ist jedoch die Messdaten allein durch die Steuergrößen vorherzusagen. Somit kann sobald eine Abweichung der Messdaten im Extrusionsprozess festgestellt wird, mittels der Steuergrößen gegengesteuert und so Ausschuss vermieden werden. Die Vorhersage der Messdaten nur durch die Steuergrößen ist exemplarisch für den Messwert  $T_1$  in Abbildung 6 dargestellt. Das Vorgehen zum Aufbau des Modells zur linearen Approximation ist identisch zu dem zuvor. Zu erkennen ist jedoch, dass kein hinreichend genaues lineares Modell aufgebaut werden kann, welches die Messdaten approximiert. Die Approximation der Trainingsdaten weicht sehr stark von den tatsächlichen Werten ab. Dementsprechend schlecht ist auch die Testprädiktion, die als blaue Kurve dargestellt ist. Da die anderen Messwerte ähnlich schlecht approximiert werden, wird auf eine Darstellung der weiteren Messwerte verzichtet. Eine Begründung für die unzureichende Approximation ist die zu geringe Variation der Steuergrößen in den Trainingsdaten. Es liegt lediglich ein Probedatensatz mit 3.022 Messwert-

sätzen vor, was zu gering ist, um den Extrusionsprozess hinreichend genau zu beschreiben. Dies liegt insbesondere auch daran, dass ein Ändern der Steuergrößen sich auf Grund der geringeren Wärmeübertragung im Kautschuk erst zeitverzögert auswirkt. Zukünftig müssen daher umfangreichere Datensätze erzeugt werden, um die Abhängigkeit der Messgrößen von den Steuergrößen zu zeigen. Darüber hinaus ist davon auszugehen, dass nichtlineare Zusammenhänge zwischen den Steuer- und Messgrößen bestehen. Diese können nicht durch ein lineares Regressionsmodell abgebildet werden. Daher wird auf Basis eines umfangreicheren Datensatzes im Folgenden ein neuronales Netz implementiert, mit dem auch nichtlineare Zusammenhänge zwischen Mess- und Steuergrößen zur Vorhersage ausgenutzt werden, um so den Prozess genauer zu modellieren (siehe Abbildung 6, rechts).

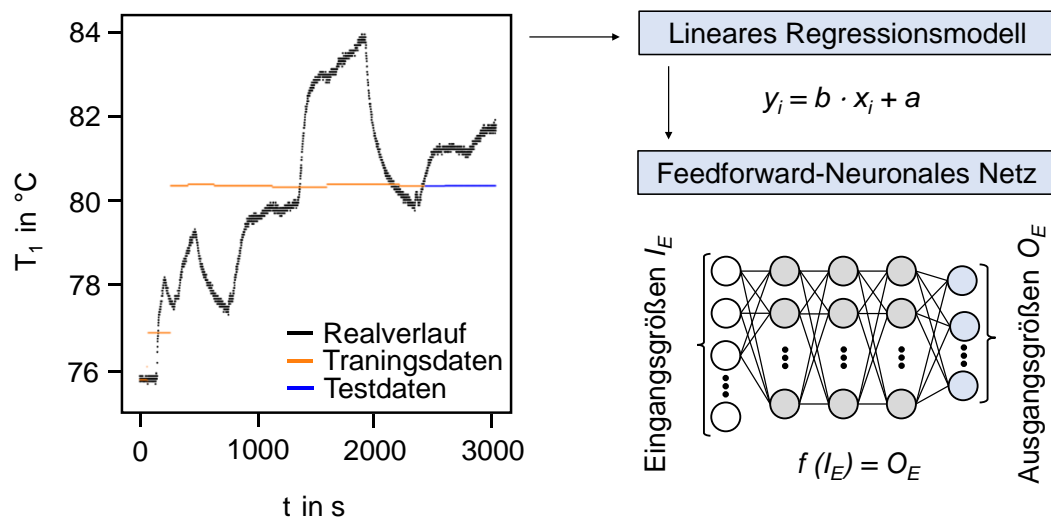


Abbildung 6: Lineares Regressionsmodell: Prädiktion von  $T_1$  auf Grundlage der Steuergrößen (links), Feedforward-Neuronales Netz (rechts)

**Neuronales Netz:** Um die Genauigkeit der Identifikation von Zusammenhängen zwischen den Steuer- und Messgrößen als auch die Performanz des Data-Mining-Algorithmus zu erhöhen, wird ein Feedforward-Neuronales Netzwerk (FNN) entwickelt (siehe Abbildung 6, rechts). FFN zeichnen sich durch unidirektionale Informationsflüsse aus, die in der Lage sind Nichtlinearitäten abzubilden. Es erfolgt ein sukzessives Implementieren von Data-Engineering-Ansätzen und Hyperparametern, um das FFN auf den Extrusionsdatensatz zu optimieren. Der MSE der Testdaten und die Konvergenzrate der Trainingsdaten werden dabei als zu reduzierende Zielgrößen definiert. Basierend auf einer Literaturrecherche werden folgende Architekturkomponenten für das FFN ausgewählt.

Tabelle 1: Architektur des Feedforward-Neuronalen Netzes

Architekturkomponente/Hyperparameter	Implementierung
Modellart	Feedforward
Aktivierungsfunktion	ReLU
Verlustfunktion	MSE, MAPE
Optimierungsfunktion	Adam
Regularisierung	$L_1$ , $L_2$ , Dropout
Neuronenanzahl	Iterative Bestimmung sowie systematische Optimierung mittels des Hyperopt-Frameworks
Layeranzahl	
Lernrate	
Epochs	
Batches	

Im Folgenden werden die Hyperparameter iterativ bestimmt, indem diese zunächst separat voneinander auf den Extrusionsdatensatz angewendet werden. Dafür werden  $T_1$ ,  $T_{Wz}$  und  $p_{Wz}$  als exemplarische Parameter ausgewählt. Der jeweilige MSE bzw. mittlere absolute Fehler

(MAE) des Validierungsdatensatzes wird zwecks Übersichtlichkeit ohne Einheit dargestellt. Anschließend erfolgt eine kollektive Implementierung der optimierten Hyperparameter. Im letzten Schritt werden die Hyperparameter mittels des Hyperopt-Frameworks feinabgestimmt.

*Messinkremente:* Als erster Optimierungsansatz erfolgte im Rahmen des Data-Engineerings eine Reduktion der Messinkremente von 10 °C auf 2 °C, um die Abtaste implizit zu erhöhen und den realen Verlauf der Stellgrößen zu approximieren. Dafür werden neue Versuchsdaten während des Extrusionsprozesses aufgenommen, welche als Trainings- und Testdaten für das Modell eingesetzt werden. In Tabelle 2 werden die Prädiktionsergebnisse des neuronalen Netzes gegenübergestellt.

Tabelle 2: Data-Engineering: Gegenüberstellung der MSE-basierenden Prädiktionsergebnisse

Ausgangsgröße	Ausgangsbasis (unoptimiert)		Angepasste Messinkremente (2 °C)	
	MSE	Konvergenz	MSE	Konvergenz
T <sub>3</sub>	266,7	12 Epoch	58,2	10 Epoch
T <sub>Wz</sub>	383,8	12 Epoch	34,5	10 Epoch
p <sub>Wz</sub>	35,6	17,5 Epoch	213,4	15 Epoch

Aus den Modellierungsergebnissen geht hervor, dass die Anpassung der Messinkremente zu einer signifikanten Reduktion der mittleren quadratischen Abweichung für die Messgrößen T<sub>3</sub> von 266,9 auf 58,2 und T<sub>Wz</sub> von 383,8 auf 34,5 führt. Bei p<sub>Wz</sub> ist hingegen eine signifikante Erhöhung der mittleren quadratischen Abweichung von 35,6 auf 213,4 erkennbar. Diese Abweichung basiert auf dem bei dem Zeitinkrement von etwa 4200 s auftretenden Höhepunkt der Messgröße p<sub>Wz</sub> (ca. 130 bar). In diesem Szenario ist die Modellierung nicht in der Lage, das abweichende Systemverhalten als Sonderzustand zu klassifizieren, wodurch die berechnete Messgrößenprognose ein entsprechendes Delta zum Realverlauf enthält. Unabhängig davon, ob es sich hierbei um einen Messfehler oder einen spontanen Druckanstieg handelt, ist es für die weiterführende Steuerung erforderlich, dass auftretende Sonderzustände als solche klassifiziert werden. Die folgenden Optimierungsansätze basieren auf dem Modellergebnis nach Anpassung der Messinkremente und werden zunächst jeweils unabhängig voneinander betrachtet, um den Methodeneinfluss sukzessiv zu evaluieren.

*Learning-Rate:* Bei dem zweiten Optimierungsansatz handelt es sich um die Learning Rate (L-Rate). Mittels des Hyperparameters ist eine Anpassung der Vektorlänge des vom Algorithmus eingesetzten Gradientenabstiegs möglich, wodurch insbesondere die Konvergenzrate von Machine-Learning-Algorithmen beeinflusst werden kann. Im Rahmen einer iterativen Vorgehensweise werden mit einer Erhöhung der Learning Rate von 0,001 auf 0,01 signifikante Verbesserungen bezüglich der mittleren quadratischen Abweichung und der Konvergenzrate erzielt (siehe Tabelle 3).

Tabelle 3: Learning-Rate: Gegenüberstellung der MSE-basierenden Prädiktionsergebnisse

Ausgangsgröße	Ausgangsbasis (unoptimiert)		Angepasste Learning-Rate (0,01)	
	MSE	Konvergenz	MSE	Konvergenz
T <sub>3</sub>	58,2	10 Epoch	9,3	3 Epoch
T <sub>Wz</sub>	34,5	10 Epoch	3,0	3 Epoch
p <sub>Wz</sub>	213,4	15 Epoch	12,7	3 Epoch

Darüber hinaus kann aus den Modellierungsergebnissen entnommen werden, dass durch die Anpassung der Learning Rate das zuvor bestehende Offset im prognostizierten Verlauf von p<sub>Wz</sub> ausgeglichen werden kann. Folglich ist eine erhebliche Reduktion der mittleren quadratischen Abweichung von 213,4 auf 12,7 erkennbar.

*Epochs und Batches:* Im nächsten Optimierungsansatz wird die Bereitstellungslogik der Trainingsdaten mittels der Epoch- bzw. Batch-Sizes angepasst. Der Epoch-Hyperparameter beschreibt die Anzahl der vollständigen Trainingsdatendurchläufe über die gesamte Trainings-

datenmenge, wohingegen mit der Batch-Size die Anzahl an Trainingsdaten in einem Iterationsschritt angepasst werden kann. Nach jeder Iteration wird das Modell entsprechend der erzielten mittleren quadratischen Abweichung angepasst. Wie zuvor wird für die Parameterauswahl der Epoch- und Batch-Sizes eine iterative Vorgehensweise angewendet. Das Anpassen der bereits in dem bestehenden Modell definierte Batch-Size von 64 führt dabei zu keiner Reduktion der mittleren quadratischen Abweichung oder Konvergenzrate. Durch die Erhöhung der Epoch Size von 20 auf 40 werden die Trainingsdatendurchläufe des Algorithmus um 100 % erhöht, wodurch die mittlere quadratische Abweichung der Messgrößen  $T_3$ ,  $T_{Wz}$  und  $p_{Wz}$  signifikant reduziert wird. Auf die Konvergenzrate haben die Änderungen keinen Einfluss (siehe Tabelle 4).

Tabelle 4: Epoch und Batch-Size: Gegenüberstellung der MSE-basierenden Prädiktionsergebnisse

Ausgangsgröße	Ausgangsbasis (unoptimiert)		Angepasste Epochs und Batches	
	MSE	Konvergenz	MSE	Konvergenz
$T_3$	58,2	10 Epoch	8,6	10 Epoch
$T_{Wz}$	34,5	10 Epoch	3,3	10 Epoch
$p_{Wz}$	213,4	15 Epoch	10,6	15 Epoch

Die erzielten Modellierungsergebnisse der Epoch-Size sind hinsichtlich der mittleren quadratischen Abweichung vergleichbar mit der Hyperparameteroptimierung der Learning Rate. Bei der Epoch-Optimierung wird eine geringere Abweichung der Messgrößen  $T_3$  und  $p_{Wz}$  erzielt. Die Anpassung der Learning Rate führt zu einer genaueren Approximation von  $T_{Wz}$ .

*Regularisierung:* Abschließend wird als letzter Optimierungsansatz die  $L_1$ -Regularisierung in den Data-Mining-Algorithmus implementiert. Zielsetzung der  $L_1$ -Regularisierung ist es, der algorithmischen Überanpassung auf die bereitgestellten Trainingsdaten entgegenzuwirken. Die Implementierung erfolgt mittels des additiven Hinzufügens eines Regularisierungsterms, der die Modellkomplexität über die Summe aller Gewichte abbildet. Über den  $L_1$ -Hyperparameter, der mit dem Regularisierungsterm multipliziert wird, kann der Regularisierungsgrad der Verlustfunktion beeinflusst werden. Für die Modellierung wird zunächst ein geringer  $L_1$ -Wert von 0,01 gewählt, der die mittlere quadratische Abweichung und Konvergenzrate nicht signifikant beeinflusst (siehe Tabelle 5).

Tabelle 5: Regularisierung: Gegenüberstellung der MSE-basierenden Prädiktionsergebnisse

Ausgangsgröße	Ausgangsbasis (unoptimiert)		Angepasste Regularisierung ( $L_1 = 0,01$ )	
	MSE	Konvergenz	MSE	Konvergenz
$T_3$	58,2	10 Epoch	58,0	10 Epoch
$T_{Wz}$	34,5	10 Epoch	34,4	10 Epoch
$p_{Wz}$	213,4	15 Epoch	212,9	15 Epoch

Eine weitere Erhöhung des  $L_1$ -Wertes würde zu einer Erhöhung der mittleren quadratischen Abweichung für den untersuchten Datensatz führen, könnte sich jedoch positiv auf die Vorhersagegenauigkeit des Algorithmus für Datensätze unter anderen Rahmenbedingungen auswirken. Um Rahmenbedingungen wie beispielsweise chargenabhängige Materialschwankungen oder Vibrationen aus dem Versuchsfeld durch das Data-Mining-Modell abbilden und entsprechend klassifizieren zu können, ist die Implementierung der Regularisierung unerlässlich. Falls mit der  $L_1$ -Regularisierung bei der Anwendung auf prozessübergreifenden Datensätzen keine hinreichend hohe Prädiktionsgenauigkeit erreicht wird, werden alternative Regularisierungsansätze, wie z. B.  $L_2$ -Regularisierung oder Dropout, implementiert. Für eine iterative Optimierung der Regularisierung-Hyperparameter unter verschiedenen Rahmenbedingungen sind weitere Versuchsdaten erforderlich, die im weiteren Projektverlauf erzeugt und analysiert werden.

*Kollektive Optimierung:* Anschließend werden die zuvor erläuterten Optimierungsansätze in einem kollektiven Data-Mining-Algorithmus implementiert. Aus den Modellierungsergebnissen geht hervor, dass die Optimierungsansätze zu einer signifikanten Reduktion der mittleren

quadratischen Abweichung für alle betrachteten Messgrößen  $T_3$ ,  $T_{Wz}$  und  $p_{Wz}$  führen. Darüber hinaus wird durch die Optimierung eine Reduktion der Konvergenzrate von mehr als 70 % für alle betrachteten Messgrößen erzielt (siehe Tabelle 6).

Tabelle 6: Kollektive Optimierung: Gegenüberstellung der MSE-basierenden Prädiktionsergebnisse

Ausgangsgröße	Ausgangsbasis (unoptimiert)		Nach kollektiver Optimierung	
	MSE	Konvergenz	MSE	Konvergenz
$T_3$	266,7	12 Epoch	8,1	3 Epoch
$T_{Wz}$	383,8	12 Epoch	4,3	3 Epoch
$p_{Wz}$	35,6	17,5 Epoch	6,5	3 Epoch

*Hyperopt-Framework:* Abschließend werden die iterativ ermittelten Hyperparameter mithilfe des Hyperopt Frameworks feinabgestimmt. Hyperopt ist eine Python-Bibliothek für die sequentielle Optimierung von Hyperparametern, mit der die möglichst optimale Parameterkombinationen in einem definierten Suchraum identifiziert werden. Dafür muss für jeden der zu optimierenden Hyperparameter ein Suchraum definiert werden, der sich idealerweise in einem möglichst abgegrenzten Bereich befindet, welcher bereits zu guten Prädiktionsergebnissen führt. Als Ausgangsbasis dafür werden die iterativ ermittelten Hyperparameter ausgewählt und um einen zunächst geringen Betrag in positive und negative Richtung erweitert. Wird der jeweilige Randbereich als ideale Parameterkombination durch den Hyperopt-Algorithmus ausgewählt, wird der Betrag erneut angepasst. Aus Abbildung 7 kann die finale Architektur dieser iterativen Vorgehensweise als auch die Prädiktionsgenauigkeit nach der Optimierung anhand des Beispiels  $T_3$  entnommen werden.

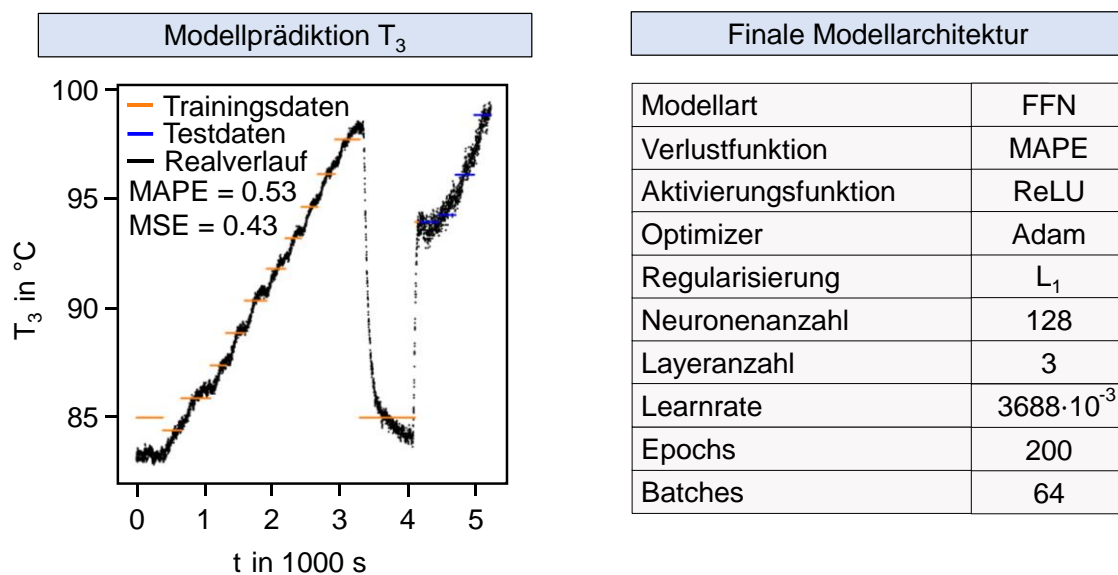


Abbildung 7: Prädiktionsergebnisse des Data-Mining-Algorithmus nach Hyperparameteroptimierung für die Extrusionsmessgrößen

Nach den Anpassungen der Hyperparameter erreicht der Data-Mining-Algorithmus einen MSE von 0,42 für  $T_3$  und einen absoluten prozentualen Fehler (MAPE) von 0,57 %. Diese hohe Genauigkeit ist bei einem durchschnittlichen MSE von 0,76 und einem durchschnittlichem MAPE von 0,77 % für die Prädiktion der gesamten Temperaturparameter gegeben (siehe Tabelle 7).

Damit ist zu jedem Betriebszeitpunkt eine Temperaturabweichung von etwa 1 °C für die Modellvorhersage sichergestellt. Der Druck  $p_{Wz}$  zeigt hingegen mit einem MSE von 39,53 und einem MAPE von 5,33 % eine ungenauere Prädiktion gegenüber den Temperaturen. Dies ist auf den höheren Datenbestand der Temperaturdaten und der höheren Varianz der Druckparameter zurückzuführen. Darüber hinaus wird der Hyperopt-Algorithmus mit der Zielsetzung implementiert, die Prädiktionsgenauigkeit der Temperaturparameter zu erhöhen.

Damit ist ein Data-Mining-Algorithmus entwickelt, der temperaturbedingte Ausgangsgrößen auf Basis der Steuergrößen mit einer durchschnittlichen Genauigkeit von etwa 99 % vorhersagen kann. Die Genauigkeit bezieht sich dabei auf die jeweils betrachteten Datensätze und kann bei unterschiedlichen Prozessbedingungen zu Abweichungen führen. Mit zunehmenden Trainingsdaten werden diese Abweichungen jedoch kontinuierlich reduziert, indem die Generalisierungsfähigkeit des Algorithmus steigt.

Tabelle 7: Prädiktionsgenauigkeit finales Modell: MSE, MAE, MAPE

Ausgangsgröße	MSE	MAE	MAPE in %
T <sub>1</sub>	0,42	0,50	0,58
T <sub>2</sub>	0,22	0,40	0,40
T <sub>3</sub>	0,42	0,55	0,57
T <sub>4</sub>	0,88	0,73	0,81
T <sub>5</sub>	0,57	0,63	0,66
T <sub>6</sub>	0,22	0,38	0,38
T <sub>7</sub>	0,49	0,56	0,67
T <sub>8</sub>	2,32	1,36	1,73
p <sub>wz</sub>	39,53	5,89	5,33
T <sub>b</sub>	0,96	0,76	0,91
T <sub>a</sub>	1,14	0,84	1,01
T <sub>wz</sub>	0,48	0,57	0,70

#### AP 6.1.6: Test & Validierung

Mit dem gewählten Trainings- und Testdatensplit (80/20) als auch der Anwendung auf unterschiedliche Datasets findet bereits der erste Schritt der Validierung des Data-Mining-Algorithmus statt (vgl. AP 6.1.5). Eine weitere Möglichkeit den Data-Mining-Algorithmus zu validieren ist es, diesen prozessübergreifend anzuwenden und so dessen Generalisierungsfähigkeit zu validieren. Dafür wird der bestehende Algorithmus auf die Messdaten des Mischprozesses angewandt, um die Mischtemperatur hervorzusagen (vgl. AP 6.1.2). Der Datensatz des Mischers setzt sich aus einer Rezeptur mit drei unterschiedlichen Chargen und einer zweiten Rezeptur mit einer Charge zusammen. Wie zuvor wird auch hier der Trainings- und Testdatensplit (80/20) angewendet. Davor wird jedoch der gesamte Datensatz nach dem Zufallsprinzip gemischt, sodass sich Daten aus jeder Charge der unterschiedlichen Mischungen im Trainings- als auch Validierungsdatensatz befinden. Im ersten Schritt wird der zuvor entwickelte Data-Mining-Algorithmus ohne jegliche Anpassungen bezüglich der Hidden Layer und der zugehörigen Hyperparameter auf den Mischerdatensatz appliziert (siehe Abbildung 8).

Dafür werden lediglich die In- und Output Layer entsprechend der individuellen Ein- und Ausgangsgrößen des Mischprozesses angepasst. Aus dem Trainings- als auch Testdatenverlauf ist zu erkennen, dass mit dem bestehenden Algorithmus grundlegende Zusammenhänge abgebildet werden können. Ein MAPE von 5,25 % und ein MSE von 24,61 deuten jedoch auf Abweichungen hin, die insbesondere in den Bereichen mit kurzfristigen Temperaturänderungen auftreten. Der Trainingsdatenverlauf lässt erschließen, dass eine höhere Anzahl an Epochs für das Training notwendig ist, um die Zusammenhänge mit einer höheren Genauigkeit abbilden zu können. Dies begründet sich durch den hohen Komplexitätsgrad des Mischprozesses, der aus der höheren Anzahl an unterschiedlichen Eingangsgrößen und der umfangreicheren Datenbasis resultiert.

Entsprechend der zuvor erläuterten Vorgehensweise (siehe AP 6.1.6) wird zunächst die Epochanzahl iterativ erhöht. Bei einer Epochanzahl von 3000 ist mit einem MSE von 7,3 und einem MAPE von 2,22 % eine erheblich höhere Prädiktionsgenauigkeit gegeben. Eine weitere Erhöhung führt aufgrund eines möglichen Overfittings zu einer niedrigeren Prädiktionsgenauigkeit. Durch die zusätzliche iterative Erhöhung des L<sub>1</sub>-Hyperparameter, um die Generalisierungsfähigkeit zwischen den unterschiedlichen Chargen und Rezepturen zu erhöhen, kann für die Prädiktion der Mischtemperatur ein MSE von 4,69 und einen MAPE von 1,68 % erzielt werden. Für den Trainings- als auch Validierungsverlauf ist eine hohe Prädiktionsgenauigkeit zu erkennen (siehe Abbildung 9).




Abbildung 8: Anwendung des Data-Mining-Algorithmus für die Prädiktion der Mischtemperatur

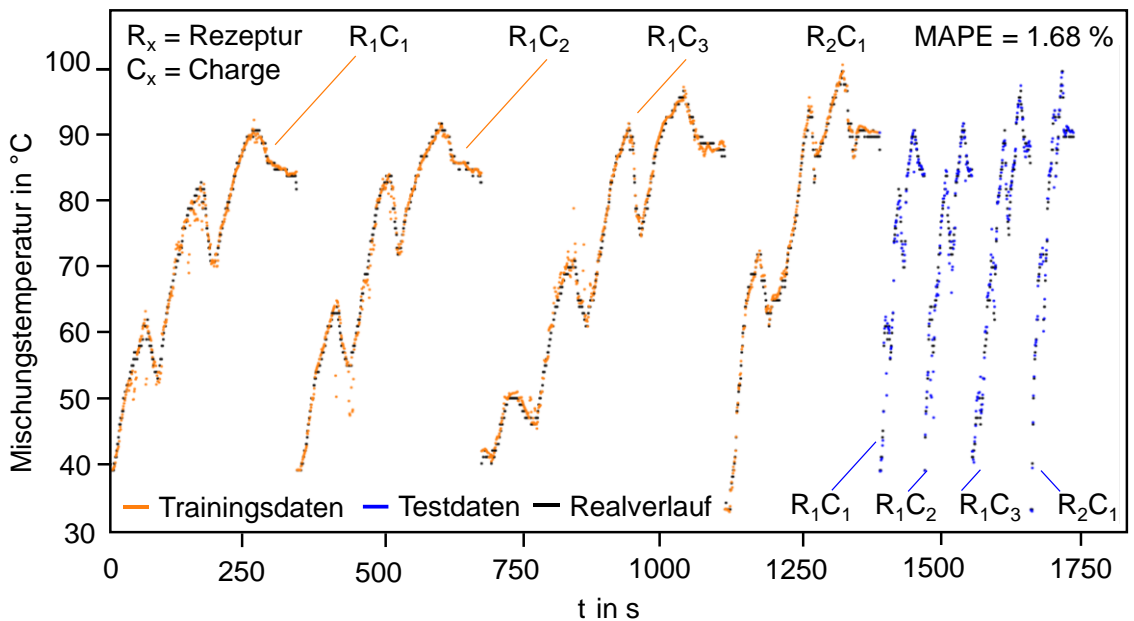


Abbildung 9: Anwendung des Data-Mining-Algorithmus für die Prädiktion der Mischtemperatur mit erhöhter Epochanzahl und  $L_1$ -Regularisierung

Somit wird der bestehende Data-Mining-Algorithmus mit lediglich leichten Anpassungen durch die chargen- als auch rezepturübergreifende Prädiktion der Mischtemperatur auf den Mischprozess generalisiert. Die finale Validierung des Data-Mining-Algorithmus erfolgt gemeinsam mit der KI-basierten Steuerung unter Realbedingungen in AP 6.2.5.

#### AP 6.2.1: Lasten- / Pflichtenheft

In diesem Arbeitspaket geht es zunächst um die Festlegung von Zuständigkeiten der beiden am Arbeitspaket 6.2.2 beteiligten Institute (DIK und ITA) für die Implementierung von Schnittstellen zur Steuerung der Prozesstrecke. Dabei zeigt sich, dass es entscheidend ist, dass die

Prozesskette die digitalen Steuerungsbefehle, die durch die KI erzeugt werden, verarbeiten kann. Daher wird die bestehende Extrusionseinheit durch das DIK und IMR hinsichtlich ihrer Steuereinheit ertüchtigt, damit diese Ansteuerung sichergestellt ist. Die Arbeitspakete 6.2.3 und 6.2.4 werden in der Folge selbstständig vom ITA durchgeführt. Die KI wird zunächst dezentral mit aufgenommenen Datensätzen konfiguriert und trainiert, damit diese bereits einsatzfähig auf dem Industrie-PC hinterlegt werden kann, sodass eine direkte Verarbeitung der aufgenommenen Daten unter Berücksichtigung der identifizierten Wirkzusammenhänge des Data-Mining-Algorithmus online im Prozess möglich ist. Die KI wird wie der Data-Mining-Algorithmus modular erweiterbar sein, sodass frühzeitig ohne die komplette Einbindung der entwickelten Messtechnik eine Validierung der KI möglich ist. Das Training der KI wird zunächst auf dem neu angeschafften Server dezentral an realen Messdaten und unter Berücksichtigung der detektierten Wirkzusammenhänge des Data-Mining-Algorithmus durchgeführt. Anschließend folgt die Validierung der Leistungsfähigkeit der echtzeitfähigen KI-basierten Steuerung an der Extrusionsstrecke.

### **AP 6.2.2: Schnittstellen Online-Daten (Output)**

Die KI wird auf dem Industrie-PC, wie im AP 6.2.1 beschrieben, implementiert. Die aktuellen Messwerte werden im Sekundentakt aus der InfluxDB gelesen und kontinuierlich durch die KI hinsichtlich der Toleranzgrenzen abgeglichen. Bei Erreichen der Toleranzgrenzen werden die berechneten Eingangsgrößen über einen MQTT-Broker an die Hardwareschnittstelle mithilfe eines Arduino Open-Source-Mikrocontrollers übertragen. Dabei werden softwareseitig durch die KI-basierte Steuerung bereits alle Eingangsgrößen an den Arduino übermittelt. Aufgrund von Hardwarerestriktionen ist aktuell jedoch nur ein automatisches Setzen der Drehzahl möglich. Folglich werden in der inline Testserie die Eingangstemperaturen manuell in Abhängigkeit der KI-berechneten Werte gesetzt. Zukünftig wird das vollautomatische Setzen aller Eingangstemperaturen durch weitere Hardware-Komponenten ermöglicht.

### **AP 6.2.3: Implementierung KI**

Zielsetzung der KI ist es, benutzerdefinierte Toleranzgrenzen durch die Anpassung von Steuergrößen auf Basis des Data-Mining-Algorithmus einzuhalten. Dafür wird eine Systemarchitektur entwickelt, die sich aus der Benutzereingabe, dem inversen Modell, dem Data-Mining-Modell und der Hardware-Schnittstelle zusammensetzt (siehe Abbildung 10). Im Folgenden werden die einzelnen Komponenten erläutert.

*Benutzereingabe:* Der Steuerungsprozess beginnt mit der Eingabe der Eingabeparameter ( $X_n$ ) sowie der oberen ( $Y_+$ ) und unteren ( $Y_-$ ) Toleranzgrenze über eine grafische Benutzeroberfläche (GUI). Zusätzlich berechnet das System sowohl die oberen ( $Y_{+p}$ ) als auch unteren ( $Y_{-p}$ ) Zielwerte basierend auf den Toleranzgrenzen, welche bei einer Toleranzüberschreitung angesteuert werden. Der Benutzer hat die Möglichkeit, diese Werte nach Bedarf anzupassen. Mit dem Erreichen der Toleranzgrenzen wird das inverse Modell innerhalb des Anpassungsprozesses angesprochen (siehe unten). Die Erfassung der Messvariablen ( $Y_n$ ) erfolgt kontinuierlich in Sekundenabständen durch die InfluxDB (siehe AP 6.2.2).

*Inverses Modell:* Bei Überschreitung der festgelegten Toleranzgrenzen wird ein Anpassungsvorgang durch den inversen Algorithmus ausgelöst. Dieser besteht aus 11 einzelnen Modellen, die jeweils einer spezifischen Ausgangsgröße zugeordnet sind. Das inverse Modell entspricht dem Data-Mining-Modell, ist jedoch hinsichtlich der Ein- und Ausgangsgrößen invertiert, um die erforderlichen Eingangsparameter zu berechnen. Die Modelle werden in die Steuerung implementiert, indem die Trainingsgewichte aus der .h5-Datei und die Architektur aus der .json-Datei geladen werden. In Abhängigkeit der Benutzerauswahl wird automatisch das passende Modell ( $T_1, T_2, \dots$ ) eingesetzt, um die benötigten Eingabevariablen ( $X_{IM,1}, X_{IEM,2}, X_{IEM,n}$ ) für das Erreichen des angestrebten Zielwerts ( $Y_{+p}/Y_{-p}$ ) zu berechnen. Dieser Prozess ermöglicht es dem System, adaptiv auf Veränderungen zu reagieren, indem eine zusätzliche Validierungsebene in Verbindung mit dem Data-Mining-Modell geschaffen wird.

**Data-Mining-Modell:** In der darauffolgenden Phase findet ein Abgleich der berechneten Eingabewerte ( $X_{IM,1}, X_{IM,2}, X_{IM,n}$ ) unter Einsatz des Data-Mining-Algorithmus statt. Dieser prognostiziert die erwarteten Ausgabewerte ( $Y_{DM}$ ) und vergleicht die Vorhersagegenauigkeit mit den festgelegten Zielwerten ( $Y_{+p}/Y_{-p}$ ). Der Validierungsprozess umfasst eine iterative Schleife, in der ein Multiplikator schrittweise so angepasst wird, dass die Differenz zwischen den prognostizierten ( $Y_{DM}$ ) und den angestrebten Werten ( $Y_{+p}/Y_{-p}$ ) minimiert wird. Diese Schleife setzt sich fort bis die Prädiktions- und Zielwerte innerhalb einer definierten Genauigkeitsgrenze ( $< 1\%$ ) konvergieren.

**Hardware-Schnittstelle:** Sobald die zuvor definierte Genauigkeitsgrenze erreicht ist, erfolgt die Übertragung der berechneten Eingabewerte an die Hardware-Schnittstelle. Dies geschieht über einen MQTT-Broker unter Verwendung des Open-Source-Mikrocontrollers Arduino (siehe AP 6.2.2).

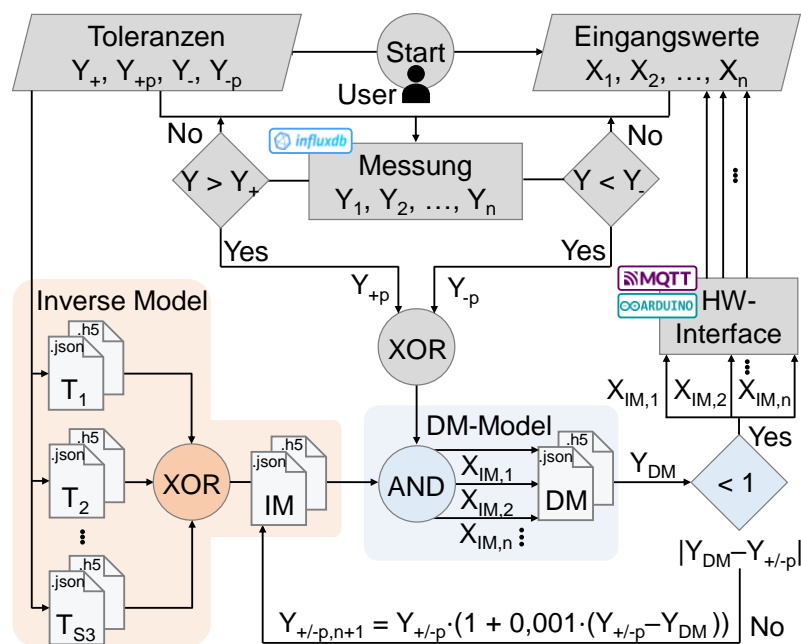


Abbildung 10: Systemarchitektur der KI-basierten Steuerung

#### AP 6.2.4: Entwicklung einer Simulationsumgebung und Training der KI

Die Validierung der KI-basierten Steuerung erfolgt zunächst simulativ und anschließend durch die Implementierung an der realen Extrusionslinie. Um das Systemverhalten der Extrusionslinie zu simulieren werden die aufgenommenen Datensätze aus verschiedenen Testreihen dem Steuerungssystem entsprechend der InfluxDB in 1-Sekunden-Intervallen zur Verfügung gestellt. Anschließend wird die entwickelte Steuerungslogik, wie in AP 6.2.3 erläutert, angewendet, welche das inverse und ursprüngliche Data-Mining-Modelle umfasst. Statt die Hardware-Schnittstelle zu nutzen, werden die berechneten Ausgabewerte durch die Ausgabe mittels der GUI validiert. Es folgt ein Beispiel für die simulative Steuerung der Temperatur  $T_3$ , bei der die obere Toleranzgrenze  $T_{+}$  auf  $89\text{ °C}$  und der vordefinierte Zielwert  $T_{+p}$  auf  $86\text{ °C}$  festgelegt ist:

```

01 ...
02 Zeit [s] = 641   T3 = 88.25   T3 < T+
03 Zeit [s] = 642   T3 = 88.44   T3 < T+
04 Zeit [s] = 643   T3 = 88.56   T3 < T+
05 Zeit [s] = 645   T3 = 88.81   T3 < T+
06 Zeit [s] = 646   T3 = 88.94   T3 < T+
07 Zeit [s] = 647   T3 = 89.00   T3 >= T+, Algorithmus startet Anpassungsprozess
08
09 Substitution von T3 mit dem vordefinierten Zielwert T+p,1
10 [73.6, 87.7, 86.0, 82.7, 89.1, 89.2, 73.1, 69.1, 76.8, 75.5, 71.6, 137.8]

```

Während des Validierungsprozesses wird jeder Testdatenpunkt mit den entsprechenden Toleranzgrenzen abgeglichen. Zum Zeitpunkt  $t = 647$  s wird die vordefinierte Toleranzgrenze überschritten und der Anpassungsprozess initiiert, mit der Zielsetzung einen Zielwert von  $86\text{ °C}$  zu erreichen:

```

11 Anpassungsiteration: 1
12 Vorheriger Offset = 3.25
13 Multiplikator = 1
14
15 Inverser Algorithmus: Eingangsgrößenberechnung um T3 auf den Zielwert T+p,1 einzustellen
16 [[16.7      68.9      68.9      68.9      69.0      49.2]]
17
18 Data-Mining-Algorithmus Validierung: Berechnung der Ausgangsgrößen
19 [[ 73.6  83.5  84.4  79.5  84.3  84.5  73.3  70.2  74.4  74.2  71.2  120.4]]
20 Resultierende Genauigkeit: 1.6 (> 1.0, daher Starten der nächsten Anpassungsiteration)

```

Die erste Anpassungsiteration erzielt eine prognostizierte Abweichung von  $1,6\text{ °C}$ , was zur Anpassung des Multiplikators gemäß der Systemlogik führt (siehe AP 6.2.3). Dieser iterative Anpassungsprozess wird fortgesetzt, bis die zu steuernde Temperatur  $T_3$  weniger als  $1\text{ °C}$  vom Zielwert abweicht. Für diesen Anwendungsfall sind hier vier Iterationsschritte erforderlich:

```

21 Anpassungsiteration: 4
22 Vorheriger Offset = 1.07
23 Multiplikator = 1.004
24
25 Inverser Algorithmus: Eingangsgrößenberechnung um T3 auf den Zielwert T+p,4 einzustellen
26 [[16.9      69.5      69.5      69.5      69.2      49.4]]
27
28 Data-Mining-Algorithmus Validierung: Berechnung der Ausgangsgrößen
29 [[ 74.3  84.3  85.1  80.4  85.0  85.2  74.0  70.9  75.2  75.0  71.9  120.9]]
30 Resultierende Genauigkeit: 0.9 (< 1.0, daher Unterberechnung der Anpassungsiteration)

```

Mit dem simulativen Testprozess wird die Anpassungslogik des KI-basierten Steuerungssystems erfolgreich validiert. Für eine Validierung unter Realbedingungen, wird im Folgenden das KI-basierten Steuerungssystems in die Extrusionslinie implementiert.

### AP 6.2.5: Test und Validierung

Im Rahmen dieses Arbeitspakets wird die KI-basierte Steuerung an der Extrusionslinie im Realbetrieb getestet. Zielsetzung der Testreihe ist es, die Temperatur  $T_3$  im Bereich von  $69\text{ °C}$  bis  $91\text{ °C}$  zu halten. Dafür wird die vom Benutzer festgelegte obere und untere Toleranzgrenze auf  $70\text{ °C}$  ( $Y_-$ ) und  $90\text{ °C}$  ( $Y_+$ ) gesetzt, um einen Sicherheitspuffer von  $1\text{ °C}$  zu berücksichtigen, der im Hinblick auf die Trägheit des Extrusionssystems implementiert wird. Als Zielwert, der nach einer Toleranzüberschreitung angesteuert werden soll, wird vom Benutzer  $80\text{ °C}$  ( $Y_{+p/p}$ ) eingestellt.

Die Testserie beginnt mit einer Aufwärmphase, bei der die Temperaturen  $T_{\text{Schnecke}}$ ,  $T_{\text{Stiftzone}}$  und  $T_{\text{Werkzeug}}$  auf  $75\text{ °C}$  eingestellt werden, während  $T_{\text{Speisewalze}}$  und  $T_{\text{Einzug}}$  konstant bei  $50$  bzw.  $70\text{ °C}$  bleiben (siehe Abb. 11). Die Schneckendrehzahl wird zu Beginn auf  $18\text{ rpm}$  eingestellt.

Nachdem sich die Ausgangstemperaturen bei etwa 200 s stabilisieren, wird eine manuelle Erhöhung der Temperaturen  $T_{\text{Schnecke}}$ ,  $T_{\text{Stiftzone}}$  und  $T_{\text{Werkzeug}}$  auf 88 °C vorgenommen. Nach ca. 800 s erfolgt ein erneuter manueller Eingriff bei dem die Temperaturen  $T_{\text{Schnecke}}$ ,  $T_{\text{Stiftzone}}$  und  $T_{\text{Werkzeug}}$  auf 95 °C und die Schneckendrehzahl auf 22 rpm gesetzt werden, wodurch die Ausgangstemperaturen aufgrund erhöhter Scherkräfte ansteigen und sich der oberen Toleranzgrenze nähern. Bei ca. 1300 s wird die obere Toleranzgrenze erreicht, was zum Eingreifen des KI-basierten Steuerungssystems führt.  $T_{\text{Schnecke}}$ ,  $T_{\text{Stiftzone}}$  und  $T_{\text{Werkzeug}}$  werden auf 73 °C eingestellt und die Schneckendrehzahl gleichzeitig auf 13 rpm reduziert. Wie erwartet überschreitet  $T_3$  aufgrund der hohen Trägheit des Extrusionssystems die Toleranzgrenze und erreichte einen Maximalwert von 90,4 °C, bleibt jedoch konstant unter der Obergrenze von 91 °C. Bei etwa 1600 s wird der Zielwert von 80 °C erreicht und in den darauffolgenden Sekunden leicht unterschritten. Auch dies lässt sich durch die hohe Systemträgheit begründen. Nichtsdestotrotz handelt es sich hier lediglich um eine marginale Abweichung und somit einem erfolgreichen Einsatz des Data-Mining-Modells bzw. der KI-basierten Steuerung.

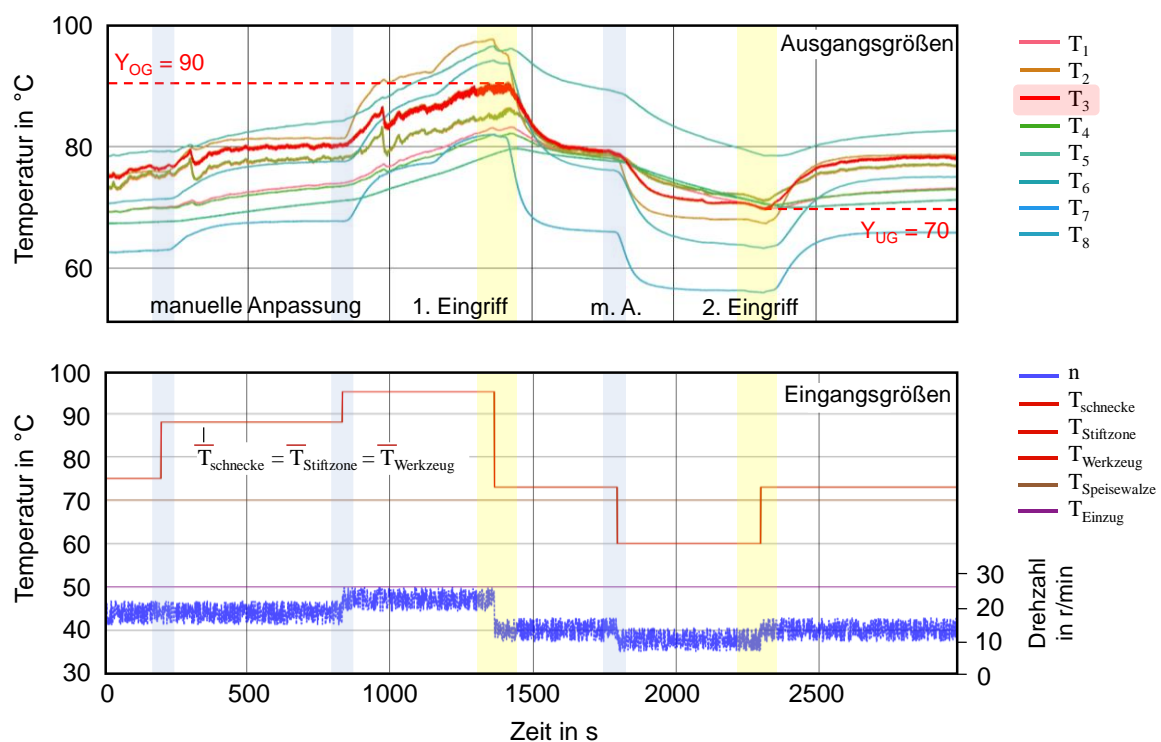


Abbildung 11: KI-basierte Steuerung: Anwendung in der realen Extrusionslinie

Die darauffolgende Abkühlphase erfolgt durch eine manuelle Reduzierung der Temperaturen  $T_{\text{Schnecke}}$ ,  $T_{\text{Stiftzone}}$  und  $T_{\text{Werkzeug}}$  auf 60 °C und Schneckendrehzahl auf 10 U/min bei ca. 1700 s, um sich der unteren Toleranzgrenze zu nähern. Diese Anpassung führt bei etwa 2300 s zu einem weiteren Eingreifen des KI-basierten Steuerungssystems, bei dem  $T_{\text{Schnecke}}$ ,  $T_{\text{Stiftzone}}$  und  $T_{\text{Werkzeug}}$  auf 73 °C und die Schneckendrehzahl auf 13 rpm erhöht werden. Während dieser Phase unterschreitet  $T_3$  die Toleranzgrenze wie erwartet mit einem Minimalwert von 69,7 °C, während die Untergrenze von 69 °C zu keinem Zeitpunkt unterschritten wird.

Mit der simulativen als auch inline Testserie ist die Funktionalität der KI-basierten Steuerung und des Data-Mining-Modells unter Realbedingungen validiert worden. Mit dem System werden benutzerdefinierte Toleranzgrenzen erfolgreich eingehalten und berechnete Eingangsgrößen automatisiert übergeben.

## 2. Wichtigste Positionen des zahlenmäßigen Nachweises

Sämtliche Umfänge der Positionen konnten im Projektverlauf eingehalten werden. Die größte Position mit über 230.000 € stellen dabei die Personalkosten dar. Dabei fallen fast 200.000 €

auf die Kosten für einen wissenschaftlichen Mitarbeiter an. Zur Bearbeitung dieses Projekts in Vollzeit über drei Jahre, waren diese Projektmittel notwendig. Die restlichen Personalmittel wurden für studentische Hilfskräfte verwendet, die insbesondere im Rahmen von Programmiertätigkeiten und der experimentellen Unterstützung bei Misch- und Extrusionsversuchen am Forschungsprojekt beteiligt waren. Durch die enge Einbindung der studentischen Hilfskräfte in das Forschungsprojekt konnte die Ausbildung wissenschaftlichen Nachwuchses in einem hochrelevanten Forschungsbereich ermöglicht werden, sodass sich diese nach ihrem Studium sowohl in einem wissenschaftlichen als auch wirtschaftlichen KI-Kontext grundlegend einbringen können.

Zusätzlich wurde für ca. 20.000 € ein Server zum Training der KI beschafft. Als letzter Posten standen knapp 5.000 € Reisemittel zur Verfügung. Hierdurch war es möglich an sämtlichen Projekttreffen, Vollversammlungen, aber insbesondere nationalen und internationalen Konferenzen, wie dem „Wissenschaftliche Gesellschaft für Produktionstechnik“ (WGP)-Jahreskongress 2023 in Freudenstadt und der „International Elastomer Conference“ (IEC) 2023 in Cleveland (USA) teilzunehmen, um die erzielten Projektergebnisse einem breitem Fachpublikum vorstellen zu können.

### **3. Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten**

Zur Realisierung einer völlig neuartigen KI-basierten Prozesssteuerung wurden drei Teilziele abgeleitet und aufeinander aufbauend bearbeitet. Zunächst war die digitale Ertüchtigung der Bestandsanlagen, Mischer und Extruder, notwendig. Hierzu wurden im ersten Schritt sämtliche Steuergrößen der Anlagen und die bestehende Messtechnik erfasst und evaluiert. Während sämtliche Bestandsmesstechnik ein digitales Ausgangssignal lieferte, basierte die Steuerung ausschließlich auf analogen Eingängen. Die Messtechnik konnte mit den Verbundpartnern um weitere Messapparaturen erweitert werden, die ebenfalls digitale Ausgangssignale liefern. Die Steuergrößen konnten teilweise digitalisiert werden. Eine vollständige Digitalisierung der Eingangsgrößen ist nach Projektende beziehungsweise im Rahmen eines Folgeprojekts vorgesehen. Sämtliche aufgenommen Messgrößen werden zentral mithilfe eines neu beschafften Industrierechners in einer Zeitreihendatenbank im Sekundentakt gespeichert. Diese Datenbank ist bei der Einbindung weiterer Messtechnik modular erweiterbar.

Anhand der aufgenommenen Daten konnten dezentral mittels Data-Mining-Algorithmen Wirkzusammenhänge detektiert werden. Hierbei überzeugte ein Algorithmus, der auf künstlichen neuronalen Netzen basiert. Dieser Algorithmus kann mit etwa einem Prozent Abweichung Temperaturmessgrößen aus den Steuergrößen vorhersagen. Ebenso ist dieser Algorithmus, der ursprünglich für die Extrusion entwickelt wurde, auf den Mischprozess übertragbar, wodurch seine Generalisierungsfähigkeit belegt ist.

Als drittes Teilziel wurde für den Extruder auf den detektierten Wirkzusammenhängen eine KI-basierte Steuerung, die den Data-Mining-Algorithmus invertiert und somit aus den Messgrößen Steuergrößen vorhersagt, entwickelt und validiert. Abhängig von den Messgrößen, wenn diese vorgegebene Toleranzgrenzen unter- oder überschreiten, werden die Steuergrößen angepasst und autonom an die Extrudersteuerung übertragen. Wobei nur ein Teil der Steuergrößen digitalisiert ist und so direkt durch den Algorithmus angepasst werden können. Bei den verbleibenden Steuergrößen, müssen die vorhergesagten Steuergrößen manuell durch einen Anlagenbediener eingestellt werden.

Anhand der Bearbeitung dieser drei Teilziele wird deutlich wie komplex die durchgeführten Arbeiten waren. Als besonders herausfordernd war einerseits die enge Abstimmung mit den Verbundpartnern, die ebenfalls innovative Ansätze im Bereich der Messtechnik und Ontologie beisteuerten, die in der entwickelten KI-basierten Steuerung fortlaufend berücksichtigt werden mussten. Andererseits bildet der inverse KI-Ansatz zur Steuerung der Extrusionsanlage einen hoch innovativen und herausfordernden Ansatz zur Einbindung einer KI zur Prozesssteuerung. Insbesondere der Einsatz dieser Technologie in einer Bestandsanlage aus den 1980er-Jahren kann als Blaupause für den Einsatz von KI-basierten Steuerungen in Bestandsanlagen von KMU dienen und verdeutlicht so die Notwendigkeit und Angemessenheit der geleisteten Projektarbeit.

#### **4. Voraussichtlicher Nutzen und Fortschreibung des Verwertungsplans**

Die KI-basierte Steuerung der Kautschukextrusionsanlage bietet die Möglichkeit, dass in den Verarbeitungsprozess frühzeitig eingegriffen werden kann, bevor es zu Fehlern kommt, die zu Ausschuss führen. Gerade in einer Zeit in der es um nachhaltige und ressourcenschonende Produktion geht, ist diese Thematik von hoher Wichtigkeit für den Wirtschaftsstandort Deutschland. Neben dem Nachhaltigkeitsaspekt führt ein verminderter Ausschuss auch direkt zur Verringerung der Produktionskosten, die ebenfalls für ein Hochlohnland wie Deutschland essenziell sind.

Extrusionsverfahren werden nicht nur in der Kautschukindustrie, sondern auch in der Kunststoff-, Metall-, Lebensmittel- und Arzneimittelindustrie eingesetzt. Da sich diese Prozesse also grundlegend ähneln, ist zu erwarten, dass sich die entwickelte Steuerung auch auf andere Werkstoffe übertragen lässt.

Im Projekt wurde darüber hinaus schon gezeigt, dass sich der Data-Mining-Ansatz auch auf den Mischprozess nach einer geringfügigen Konfektionierung des Algorithmus übertragen lässt. Somit bietet sich für die Kautschukindustrie die Möglichkeit auch weitere Prozesse wie das Spritzgießen, Pressen oder auch die additive Fertigung durch KI-basierte Steuerungskonzepte zu optimieren.

Da sich das ITA auch an der dritten Förderperiode von MaterialDigital beteiligt, existiert direkt ein wissenschaftlicher Anknüpfungspunkt. Im Rahmen des Projektes wird es darum gehen den kompletten Lebenszyklus vom Rohstoff bis zum Recyclat zu digitalisieren. Dabei soll der holistische Produktionsprozess durch einen KI-Algorithmus prozessübergreifend gesteuert werden. Ebenso soll eine CO<sub>2</sub>-Bilanzierung des Produktlebenszyklus durch die Digitalisierung ermöglicht werden. Durch die industriellen Verbundpartner werden die Erkenntnisse dieses Vorhabens direkt auf industrielle Anlagen übertragen.

#### **5. Darstellung des während der Durchführung des Vorhabens dem Anwendungsempfänger bekannt gewordenen Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen**

Parallel zu der Bearbeitung dieses Vorhabens wurde weltweit an KI-Einsätzen im industriellen Umfeld geforscht. Im Folgenden werden exemplarisch zwei Forschungsgebiete vorgestellt, die sich mit dem KI-Einsatz in der Kautschuktechnologie auseinandersetzen. TAKADA ET AL. veranschaulichen das Potential von Random-Forest-Algorithmen zur Verbesserung des Mischprozesses von Polyphenylensulfid mit Elastomeren unter Verwendung von Doppelschneckenextrudern [1]. KOPAL ET AL. stellen ein verallgemeinertes neuronales Regressionsnetzwerkmodell zur Vorhersage der Vulkanisationseigenschaften von rußgefüllten Kautschukmischungen vor und zeigen, dass es auch bei kleinen Datensätzen wirksam ist [2]. Die parallel stattfindende Forschung konzentriert sich jedoch in erster Linie auf die Vorhersage von Werten zur Unterstützung des menschlichen Bedieners und untersucht nicht das Potential der Implementierung eines ANN-basierten Systems für die Steuerung des Kautschukextrusionsprozesses in Echtzeit. Diese Forschungsprojekte beeinflussen das eigene Vorhaben nicht, ebenso sind keine Patente Dritter bekannt, die die Verwertung der erzielten Ergebnisse negativ beeinflussen.

[1] TAKADA, S.; SUZUKI, T.; TAKEBAYASHI, Y.; ONO, T.; YODA, S.: Machine learning assisted optimization of blending process of polyphenylene sulfide with elastomer using high speed twin screw extruder, Nature - Scientific reports, 2021.

[2] KOPAL, I.; LABAJ, I.; VRŠKOVÁ, J.; HARNIČÁROVÁ, M.; VALIČEK, J.; ONDRUŠOVÁ, D.; KRMELA, J.; PALKOVÁ, Z.: A Generalized Regression Neural Network Model for Predicting the Curing Characteristics of Carbon Black-Filled Rubber Blends, Polymers, 2022.

#### **6. Erfolgte oder geplante Veröffentlichungen des Ergebnisses nach Nr. 5 der NABF/NKBF**

LEINWEBER, S.; KRUPS, T.; OVERMEYER L.: Forschungsverbund DIGIT RUBBER gestartet, phi – Produktionstechnik Hannover informiert, Newsletter Nr. 31, 2021.

LUKAS, M.; LEINWEBER, S.; OVERMEYER, L.: Künstliche Intelligenz und Data-Mining in der Kautschukextrusion, phi – Produktionstechnik Hannover informiert, Newsletter Nr. 39, 2023.

LUKAS, M.; LEINWEBER, S.; REITZ, B.; OVERMEYER, L.; ASCHEMANN, A.; KLIE, B.; GIESE, U.: Data Mining-Enabled Temperature Control for Sustainable Production in Rubber Extrusion Lines: An Artificial Neural Network-Based Approach, In: BAUERNHANSL, T., VERL, A., LIEWALD, M., MÖHRING, HC. (eds) Production at the Leading Edge of Technology. WGP 2023. Lecture Notes in Production Engineering. Springer, Cham., 2023.

LUKAS, M.; LEINWEBER, S.; REITZ, B.; OVERMEYER, L.; ASCHEMANN, A.; KLIE, B.; GIESE, U.: Minimizing Temperature Deviations in Rubber Extrusion Lines using Artificial Neural Network based Process Control, 204th Technical Meeting Rubber Division, ACS International Elastomer Conference, Cleveland, Ohio, 2023.

LUKAS, M.; LEINWEBER, S.; REITZ, B.; OVERMEYER, L.; ASCHEMANN, A.; KLIE, B.; GIESE, U.: Minimizing Temperature Deviations in Rubber Mixing Process using Artificial Neural Networks, Rubber Chemistry and Technology, 2024.

LUKAS, M.; LEINWEBER, S.; REITZ, B.; OVERMEYER, L.: Real-time temperature control in rubber extrusion lines: a neural network approach, The International Journal of Advanced Manufacturing technology, 2024

ASCHEMANN, A.; LUKAS, M.; LEINWEBER, S.; REITZ, B.; OVERMEYER, L.; U. W.: Digitalization in rubber extrusion: New measurement method approaches and integration of AI-based process control, Advanced Engineering Materials (akzeptiert)

SCHAARSCHMIDT, J.; LUKAS, M.; LEINWEBER, S.; REITZ, B.; OVERMEYER, L.; U. W.: Advancing Digital Transformation in Material Science: The Role of Workflows within the MaterialDigital Initiative, Advanced Engineering Materials (eingereicht)

LUKAS, M.: Maschinensteuerung durch Künstliche Neuronale Netzwerke zur Minimierung der Temperaturabweichung von Kautschukextrusionsanlagen im Schneckenkanal, Dissertation, TEWISS Verlag, Garbsen (geplant)