



# Der optimale Betriebspunkt in der sensorgestützten Sortierung

Karl Friedrich · Roland Pomberger · Gerald Koinig

Angenommen: 13. Oktober 2023 / Online publiziert: 20. November 2023  
© The Author(s) 2023, korrigierte Publikation 2023

**Zusammenfassung** Abhängig von der Verfügbarkeit der Abfallströme werden sensorgestützte Sortiermaschinen derzeit typischerweise nicht am optimalen Betriebspunkt betrieben, sondern entweder über- oder unterfahren. Abhängig von der Durchsatzrate und der Zusammensetzung des Eingangstroms können mathematische Ansätze für vorgegebene Idealmischungen gefunden werden. In diesem Forschungsartikel wird untersucht, ob und unter welchen Umständen diese Methoden bei sensorgestützten Sortiermaschinen eingesetzt werden können. Um Aussagen zu ermöglichen, werden neu gewonnene Daten aus realen Abfällen auf drei sensorgestützten Sortieranlagen mit vorhandenen Daten für selbst erstellte Idealmischungen verglichen. In einer Aufbereitungsanlage für Ersatzbrennstoffe werden für die Versuche in regelmäßigen Abständen fünf Proben von 3D-Kunststoffen gezogen. Mithilfe von Regressionsmodellen, die aus mathematischen Ansätzen erstellt werden, wird der optimale Betriebspunkt ermittelt, um ein bestimmtes sensorgestütztes Sortierergebnis hinsichtlich Reinheit und Ausbeute zu erreichen. Der wich-

tigste Beitrag dieses Forschungsartikels für Anlagenbetreiber besteht darin, dass die Reinheit um 20 % gesteigert werden kann, ohne dass wesentliche Änderungen am Sortiersystem erforderlich sind.

**Schlüsselwörter** Sensorgestützte Sortierung · NIR-Sortierung · Optimaler Betriebspunkt · Durchsatzrate · Stoffstromzusammensetzung · Reinheit · Austrag · Regressionsmodell

## The optimal operation point in sensor-based sorting

**Abstract** Currently, depending on the availability of waste streams, sensor-based sorting machines are typically not operated at the optimal operation point but are rather either overrun or underrun. It is possible to find mathematical approaches for preset ideal mixtures depending on the throughput rate and the composition of the input stream. This research article examines whether these methods can be used with sensor-based sorting machines and under what circumstances. To enable the making of meaningful claims, newly obtained data from real waste on three sensor-based sorting setups will be compared with existing data for preset ideal mixtures. At a processing facility for refuse derived fuels five samples of 3D plastics are sampled on a regular basis for the trials. The optimum operating point to reach a particular sensor-based sorting result in purity and recovery is found using regression models, which are created mathematical approaches. This research article's key contribution for plant operators is the opportunity that purity can be raised by 20% without requiring significant modifications to the sorting system.

**Keywords** Sensor-based sorting · NIR sorting · Optimal operation point · Throughput rate · Input composition · Purity · Recovery · Regression model

## 1 Einleitung

Kunststoffabfälle können mithilfe optischer Sensoren in sensorgestützter Sortierung (SGS), triboelektrostatischer Kräfte oder Dichtetrennung mit Hydrozyklonen sortiert werden (Gundupalli et al. 2017). Die am häufigsten angewandte Technologie zur Sortierung von Post-Consumer-Kunststoffabfällen ist jedoch die Nahinfrarotspektroskopie (NIR) mit hyperspektraler Bildgebung (Workman und Springsteen 1998). Die NIR-Technologie ist eine schnelle, berührungslose und zerstörungsfreie SBS-Methode in der Abfallwirtschaft (Pasquini 2003; Kulcke et al. 2003). Der NIR-Bereich umfasst einen Wellenlängenbereich zwischen 750 und 2500 nm und ermöglicht die Unterscheidung verschiedener Materialien anhand der Schwingung von durch Strahlung angeregten Molekülen. Das emittierte Licht führt zu Schwingungs- und Rotationsbewegungen von Molekülen oder Molekülteilen des Materials. Dadurch können die entsprechenden Absorptionsbanden mit einem optischen Sensor in Form eines Spektrums erfasst werden (Beel 2017). Dieses Spektrum gibt Aufschluss über die chemische Zusammensetzung des Sorterguts und ermöglicht die Erfassung messbarer Trenneigenschaften eines Stoffstroms (Friedrich et al. 2022).

In Abfallaufbereitungsanlagen werden üblicherweise zwei NIR-Sortierkonstruktionen eingesetzt, die sich darin unterscheiden, wie das Abfallmaterial am Sensor vorbeigeführt wird. Die Bewegung basiert entweder auf der Schwerkraft, wenn das Material eine Rutsche hinunterrutscht, oder auf mechanischen Kräften mithilfe eines Förderbands. Während körniges Material üblicherweise über eine Rutsche sortiert wird, erfolgt die Sortierung sperriger Materialien über Förderbandmaschinen (Pretz und Julius 2008).

SGS-Anlagen sind anfällig für Veränderungen in der Inputmenge und -qualität (Zusammensetzung), wobei

**Datenverfügbarkeit** Die in diesem Originalbeitrag präsentierten Daten sind auf Anfrage beim Erstautor verfügbar.

DI K. Friedrich (✉)  
Department Mineral Processing,  
Lehrstuhl für Aufbereitung und  
Veredlung, Montanuniversität Leoben,  
Franz-Josef-Straße 18, 8700 Leoben,  
Österreich  
karl.friedrich@unileoben.ac.at

Univ.-Prof. DI Dr. R. Pomberger ·  
DI Dr. G. Koinig  
Department Umwelt- und  
Energieverfahrenstechnik, Lehrstuhl  
für Abfallverwertungstechnik  
und Abfallwirtschaft,  
Montanuniversität Leoben,  
Franz-Josef-Straße 18, 8700 Leoben,  
Österreich

die Oberflächenbeschaffenheit den Sortiererfolg erheblich beeinträchtigt und die Anlagen häufig über- oder unterlastet werden, was die Sortiereffizienz verringert (Küppers et al. 2019, 2021).

Das Finden des optimalen Betriebspunkts für diese SGS-Aggregate ist für den Erfolg und die Rentabilität jeder Abfallverarbeitungsanlage von entscheidender Bedeutung. Empirische Mittelwerte können diese Optimierung ermöglichen und eine akzeptable Näherung liefern, sie ist jedoch zeitaufwendig und die Datengenerierung muss für jedes Einzelgggregat wiederholt werden (Küppers et al. 2021).

Die Entwicklung eines mathematischen Ansatzes zur Optimierung der Durchsatzrate einer bestimmten NIR-Sortieranlage kann wertvolle Zeit sparen und die Rentabilität bestehender Sortieranlagen steigern. Darüber hinaus kann die Energiemenge für den Prozess reduziert werden, indem das System am optimalen Betriebspunkt betrieben wird.

Unter Bezugnahme auf die vorhandenen Erkenntnisse zur Korrelation von Inputzusammensetzung, Durchsatzrate und den SGS-Ergebnissen (Reinheit, Ausbringung, Wertstoffausbringung) von Küppers wissen wir, dass es in mathematischen Ansätzen für Kunststofffraktionen mit definiertem Mischungsverhältnis – ideale Mischungen – einen Zusammenhang zwischen diesen Parametern gibt (Küppers et al. 2021).

Wenn ein mathematischer Ansatz für reale Kunststoffabfälle entwickelt werden kann, stellt sich die Forschungsfrage, welche Präzision für einen mathematischen Ansatz erreicht werden kann, der die Inputzusammensetzung, die Durchsatzrate, die Reinheit, die Ausbringung und die Wertstoffausbringung berücksichtigt und schließlich, für welche Bereiche oder Schwellenwerte für diese Parameter mathematische Ansätze funktionieren können.

Wenn ein mathematischer Ansatz wie oben beschrieben für reale Kunststoffabfälle entwickelt werden kann, kann die Abfallbehandlungsbranche schrittweise verbessert werden, was Friedrich in einer Einschätzung darüber, wie ausgereift die Abfallsortierindustrie bei der Nutzung von Datenanalysen zur Verbesserung ihrer Sortierprozesse ist, positiv hervorhob (Friedrich et al. 2021).

In Abfallsortieranlagen besteht das Ziel darin, einen erforderlichen Mindestschwellenwert für die Reinheit zu

erreichen und die Schwellenwerte für Verunreinigungen zu unterschreiten.

## 2 Material und Methoden

Die Sortiereffizienz wird üblicherweise anhand von Ausbringung (R), Wertstoffausbringung (R<sub>w</sub>) und Reinheit (P<sub>m</sub>) – drei massenspezifischen Indikatoren [m%] – analysiert. Diese wurden von Friedrich wie in den folgenden Absätzen definiert (Friedrich et al. 2022).

Die Ausbringung (R) ist der Quotient aus der Produktmasse oder der Masse des ausgeworfenen Materials (m<sub>eject</sub>) und der Gesamtmasse des Inputs (m<sub>input</sub>) über einen bestimmten Zeitraum. Die Ausbringung gibt das Produkt an, das pro Zeiteinheit oder einer bestimmten Durchsatzrate produziert wird.

$$R = \frac{m_{eject} \left[ \frac{t}{h} \right]}{m_{input} \left[ \frac{t}{h} \right]} * 100\%$$

Die Wertstoffausbringung (R<sub>w</sub>) wird durch den Quotienten aus produziertem Produkt im Output (m<sub>eject</sub>\*c<sub>eject</sub>) und Wertstoffen im Input (m<sub>input</sub>\*c<sub>input</sub>) definiert. Mit dem Massenstrom des Outputmaterials (m<sub>eject</sub>) und der berechneten Wertstoffkonzentration in der Outputfraktion (C<sub>eject</sub>) wird die im Output erzeugte Wertstoffmenge berechnet.

$$R_w = \frac{m_{eject} \left[ \frac{t}{h} \right] * c_{eject} [\%]}{m_{input} \left[ \frac{t}{h} \right] * c_{input} [\%]} * 100\%$$

Einen weiteren Qualitätsindikator schlug Feil mit der Berechnung der Reinheit P<sub>m</sub> vor (Feil et al. 2016). Der Prozentsatz des korrekt ausgeworfenen Inputmaterials – Reinheit – wird wie folgt berechnet:

$$P_m = \frac{m_{recyclable\ material} \left[ \frac{t}{h} \right]}{m_{impurity} \left[ \frac{t}{h} \right] + m_{recyclable\ material} \left[ \frac{t}{h} \right]} * 100\%$$

Da es viele verschiedene Kunststoffarten gibt, besteht der erste Schritt darin, einen Kunststoffabfallstrom zu definieren, der den idealen Mischungen, die Küppers verwendet hat, recht ähnlich ist (Küppers et al. 2021). Da es sich um gewaschene und anschließend getrocknete Polyolefin-Kunststoffflakes handelt, wurde beschlossen, 3D-Ersatzbrennstoffe (EBS) zu verwenden, die in einer Abfallbehandlungsanlage entnommen wurden. Es wurden fünf Proben für die Versuchsreihen gezogen, bei welchen im ersten Schritt eine Metallentfrachtung mittels Induktionsleiste am sensorgestützten Versuchstand der Montanuniversität Leoben vorgenommen wurde. Eine weitere Materialaufbereitung für die Versuche wurde nicht durchgeführt. Beispielhaft ist die metallentfrachtete Probe 2 in Abb. 1 ersichtlich.

Die Materialzusammensetzung der fünf Proben wurde mittels NIR-Charakterisierung am sensorgestützten Versuchstand der Montanuniversität Leoben bestimmt. Die Zusammensetzung der fünf Proben ist in Tab. 1 ersichtlich. Es wurden die Materialarten PET,



Abb. 1 Probe 2, um die Korngrößen und die Zusammensetzung der Proben bildlich zu veranschaulichen. (Eigene Aufnahme)

**Tab. 1** Materialzusammensetzung der fünf Proben für die Versuchsdurchführung

Probe	1		2		3		4		5	
Probennahme	17.08.2020		19.08.2020		02.10.2020		06.10.2020		20.10.2020	
Einheit	[kg]	[m%]								
PP	0,94	14,9	0,38	13,3	0,46	11,8	0,46	12,1	0,44	11,5
PET	1,68	26,5	0,73	25,2	0,85	22,0	1,17	30,5	1,23	32,0
PVC	0,25	3,9	0,14	4,9	0,26	6,8	0,17	4,4	0,11	3,0
Rest	3,46	54,7	1,63	56,6	2,31	59,5	2,03	53,0	2,07	53,5
Summe	6,33	100,0	2,88	100,0	3,88	100,0	3,82	100,0	3,86	100,0

PP und PVC gewählt, da diese in großen prozentuellen Anteilen verfügbar waren, weitere Materialien wurden der Materialklasse „Rest“ zugeordnet.

## 2.1 Sensorgestützte Sortieraggregate

Die zu vergleichenden Versuche werden an drei verschiedenen SGS-Aggregaten durchgeführt, dem sensorgestützten Versuchstand an der Montanuniversität Leoben, einer sensorgestützten Rutschensortieranlage und der sensorgestützten Bandsortieranlage, welche in Technika von Maschinenherstellern zum Einsatz kommen. Alle Aggregate sind als Zwei-Wege-Systeme für SGS konzipiert.

Die Software zur statistischen Auswertung des Identifikationsergebnisses funktioniert bei allen SGS-Aggregaten auf die gleiche Weise. Sie erstellen die Pixelstatistik, die Materialstatistik und die Objektstatistik. Diese Werte werden verwendet, um die Reinheit der sortierten Fraktionen zu berechnen, die für die SGS-Versuche verglichen werden.

## 2.2 Methoden

Die Methoden und das experimentelle Design sind in die folgenden vier Phasen gegliedert:

### 2.2.1 Phase

In der ersten Phase wird ein NIR-Sortiermodell entwickelt. Probe 1 dient als Referenzprobe („Sortiermodell-Erstellungsprobe“) zur Aufnahme der einzulernenden Rohspektren und wird nicht in die Versuche einbezogen. Dieses Verfahren wird gewählt, um die Materialklassen der Entstehungsproben als identische Fraktionen für weitere Versuchsreihen auf allen verwendeten sensorbasierten Sortieranlagen zur Vergleichbarkeit zur Verfügung zu haben.

Um die Vergleichbarkeit zu gewährleisten, wurden im NIR-Sortiermodell für die EBS-Fraktion auf dem sensor-

gestützten Versuchstand die gleichen Rohspektren von PET und PP verwendet, die von Küppers veröffentlicht wurden (Küppers et al. 2021). Weitere Spektren müssen zunächst aufgenommen werden, um im NIR-Sortiermodell hinzugefügt zu werden.

Für die sensorgestützte Rutschensortieranlage und die sensorgestützte Bandsortieranlage ist die Verwendung derselben Rohspektrendateien nicht möglich, da die Software auf den Aufbauten den Import der Dateien des sensorgestützten Versuchstands nicht zulässt. Für diese Aggregate müssen alle Rohspektren neu aufgenommen und neue NIR-Sortiermodelle entwickelt werden.

### 2.2.2 Phase

In der zweiten Phase werden Versuche mit vier EBS-Fraktionen mit mindestens drei verschiedenen Durchsatzraten durchgeführt, um mathematische Ansätze für alle SBS-Aggregate zu erhalten. Insgesamt werden mindestens 108 Versuche durchgeführt. Die Anzahl weiterer Versuche hängt von der zeitlichen Verfügbarkeit der Aggregate und der Plausibilität der erhobenen Daten ab.

### 2.2.3 Phase

Erwartete Ergebnisse werden mit Regressionsalgorithmen beim maschinellen Lernen vorhergesagt. Die Eingabeparameter werden verwendet, um die jeweiligen Ausgabeparameter mittels Regression vorherzusagen. Die Regression hilft dabei, die Beziehung zwischen der vorherzusagenden Zielvariablen und erstellten Datenpunkten zu definieren. Dabei handelt es sich um eine Art überwachtes Lernen beim maschinellen Lernen, das dabei hilft, eine prädiktive Beziehung zwischen Zielwerten und Datenpunkten abzubilden. Die in dieser Studie verwendeten Regressionen sind die Gaussian Process

Regression (GPR) und das Regression Neuronal Network (RNN), um das am besten passende Regressionsmodell als mathematischen Ansatz zu finden. Die Eingabeparameter (Regressoren) sind die Eingabezusammensetzung und die Durchsatzrate, die Ausgabeparameter (Regressanden) sind Reinheit und Ausbringung.

Es wird ein MATLAB-Code entwickelt, um die Versuchsergebnisse in Regressionsmodellen und Hauptkomponentenanalysen auszuwerten und so mathematische Ansätze zu finden. Alle Berechnungen wurden mit MATLAB von MathWorks (Natick, MA, USA) unter Verwendung von „9.13.0.2105380 (R2022b) Update 2“ auf einem Windows-10-Computer durchgeführt, der mit einer Intel® UHD Graphics 630 und einer Intel® Core™ i5-9400H-CPU mit einer Taktung von 2,50 GHz ausgestattet ist.

Es erfolgt eine statistische Auswertung mit RMSE und  $R^2$ , die Regressionsmodelle werden mit GPR und RNN durchgeführt. Die Ergebnisse werden in 3D- und 2D-Diagrammen dargestellt, je nachdem, welches besser zur Visualisierung passt.

Die Modelle GPR und RNN wurden auf einem Trainingssatz trainiert, der 70 % der Daten umfasste. Der Testsatz bestand aus den restlichen 30 % der gesammelten Daten in Übereinstimmung mit den vorhandenen Erkenntnissen, die die ideale Aufteilung zwischen Training und Test abbilden. Die oben genannten statistischen Werte wurden anhand der Leistung des Modells im Testsatz berechnet. Im folgenden Abschnitt wird eine kurze Einführung in die zugrunde liegenden Methoden von GPR und RNN gegeben.

Die vorliegende Aufgabe kann als Regressionsaufgabe definiert werden. Diese erste Unterscheidung ist notwendig, um die möglichen maschinellen Lernwerkzeuge zu bewerten. Regression ist eine Art überwachter maschineller Lernaufgabe, deren Ziel

darin besteht, eine kontinuierliche numerische Ausgabe (eine reelle Zahl) basierend auf Eingabedaten vorherzusagen. Überwachtes maschinelles Lernen impliziert, dass der Vorhersagealgorithmus auf gekennzeichneten Daten trainiert wird, die aus Eingabe-Ausgabe-Paaren ( $X, y$ ) bestehen, wobei  $X$  die Eingabedaten und  $y$  die entsprechenden Ausgabewerte darstellt. Ziel des Modells ist es, zu lernen, die zugrunde liegenden Zusammenhänge zu erfassen.

Ein GPR-Modell ist ein probabilistischer, nicht parametrischer Algorithmus für maschinelles Lernen, der für Regressionsaufgaben verwendet wird. Es ist ein leistungsstarkes Werkzeug zur Modellierung und Vorhersage kontinuierlicher Daten, insbesondere im Umgang mit Unsicherheit. GPR basiert auf den Prinzipien der Gaußschen Prozesse, die eine Möglichkeit zur Wahrscheinlichkeitsverteilung über Funktionen darstellen. GPR eignet sich als nichtparametrisches Modell gut für die zugrunde liegenden Daten, da es keine starken Annahmen über die funktionale Form der Daten trifft. Dies steht im krassen Gegensatz zu parametrischen Modellen wie der linearen Regression, die eine feste Funktionsform (z. B. eine lineare Beziehung) annehmen. Daraus kann GPR ein breites Spektrum an Funktionen erfassen, indem es aus den Daten lernt.

RNNs sind eine Art künstliches neuronales Netzwerk (KNN), das speziell für die Lösung von Regressionsproblemen entwickelt wurde. RNNs sind ein leistungsstarkes Werkzeug zur Modellierung komplexer Beziehungen zwischen Eingabemerkmalen und kontinuierlichen Zielvariablen. RNNs bestehen aus mehreren Schichten miteinander verbundener Neuronen, die in eine Eingabeschicht, eine oder mehrere verborgene Schichten und eine Ausgabeschicht unterteilt sind. Jedem Neuron ist eine Gewichtung und ein Bias zugeordnet, die während des Trainings angepasst werden, um die Vorhersagefähigkeit des Netzwerks zu optimieren.

#### 2.2.4 Phase

Die gefundenen Regressionsmodelle werden hinsichtlich der Ermittlung des optimalen Betriebspunkts eines SGS-Aggregats getestet. Die Modelle sollen dabei unterstützen, den optimalen Betriebspunkt zu finden und diesen mehr oder weniger genau zu beschreiben.

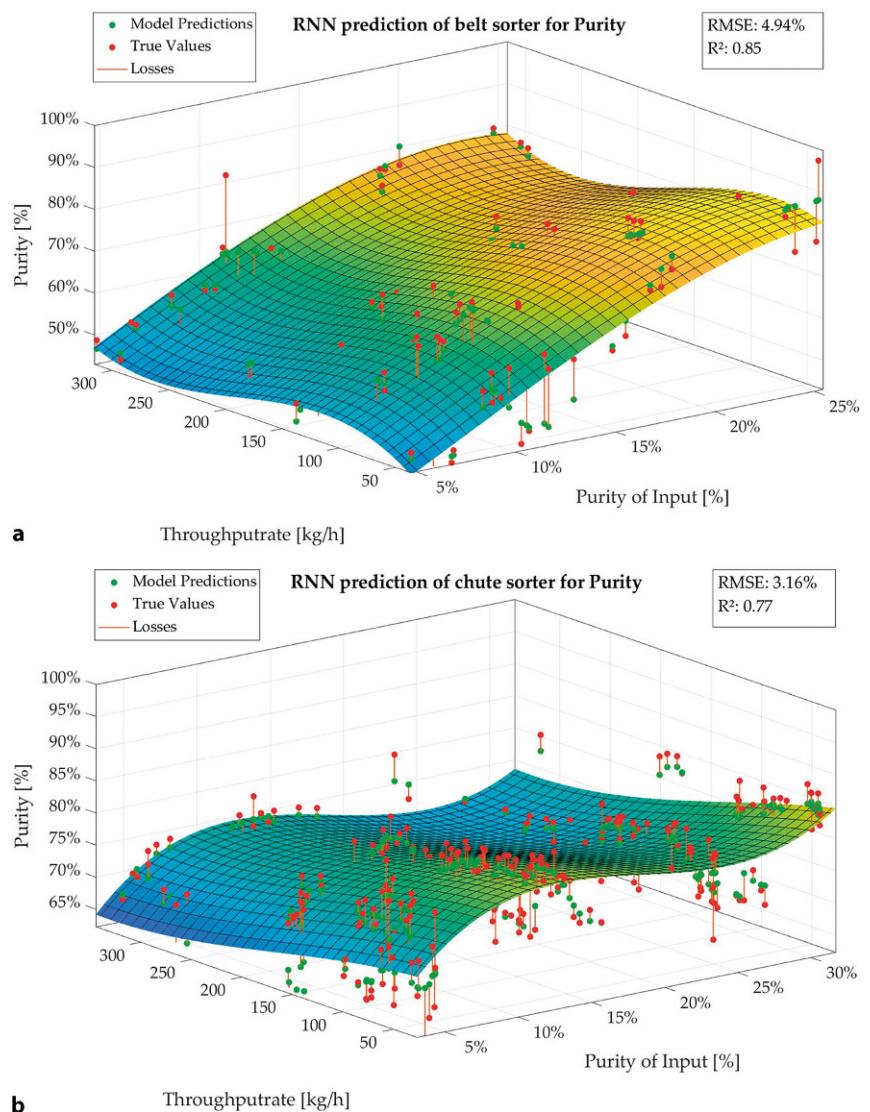
### 3 Ergebnisse und Diskussion

Für die EBS-Versuche mit dem sensorgestützten Versuchstand, der sensorgestützten Rutschensortieranlage und der sensorgestützten Bandsortieranlage entwickelt GPR das bessere Modell.

Die Regressionsmodelle der verwendeten SGS-Aggregate für RDF unterscheiden sich von Aggregat zu Aggregat, obwohl das Material ident ist. Dies weist darauf hin, dass bei der Verwendung von Regressionsmodellen zur Beschreibung der Korrelation zwischen den Input- und Outputparametern eines Sortierprozesses diese Modelle für jedes SGS-Aggregat separat erstellt werden müssen.

Abb. 2 visualisiert eine Beispieldarstellung von Modellvorhersagen für Testsätze mit Verlusten, die anhand der Modellvorhersage im Vergleich zum wahren Wert mit einer angepassten 3D-Kurve berechnet wurden. Sie zeigt den Trend der tatsächlichen Daten bezüglich der Reinheit des Inputs und der Durchsatzrate auf der sensorgestützten Bandsortieranlage (Abb. 2a) und der sensorgestützten Rutschensortieranlage (Abb. 2b), einschließlich  $R^2$  und RSME für das zugrunde liegende Vorhersagemodell.

Zur Interpretation der Ergebnisse jedes SBS-Aggregats wird eine statistische Auswertung der Regressionsmodelle



**Abb. 2** Beispieldarstellung von Modellvorhersagen für Testsätze mit Verlusten, die anhand der Modellvorhersage im Vergleich zum wahren Wert mit einer 3D-angepassten Kurve berechnet wurden

**Tab. 2** Statistische Auswertungsergebnisse der Regressionsmodelle mit RMSE und R<sup>2</sup>

SGS-Aggregat Statistischer Parameter	Material	Regressionsmodell	Reinheit	Ausbringung	R <sup>2</sup> [-]
			RMSE [%]		
Sensorgestützter Versuchstand	EBS	GPR	5	0,50306	2
Sensorgestützte Rutschensorientieranlage	EBS	GPR	3	0,75158	2
Sensorgestützte Bandsortieranlage	EBS	GPR	5	0,87458	1

mit RMSE und R<sup>2</sup> durchgeführt. Die Ergebnisse sind in Tab. 2 aufgeführt.

Bezüglich der Reinheit liegen die Werte für R<sup>2</sup> zwischen 0,50306 für GPR mit EBS am sensorgestützten Versuchstand und 0,87458 für GPR mit EBS in der sensorgestützten Bandsortieranlage, ein Unterschied, der keine allgemeine Aussage zulässt. Zu berücksichtigen ist, dass der sensorgestützte Versuchstand auf die Analyse und Sortierung von Flakes ausgelegt ist, was zu einer stärkeren Streuung der Ausgabedaten führte und das Regressionsmodell verschlechterte. Der RMSE liegt zwischen 3 % für GPR mit EBS am sensorgestützten Rutschensorientierer.

Der R<sup>2</sup> für die Ausbringungs-Regressionsmodelle variiert zwischen 0,92686 für GPR mit EBS am sensorgestützten Rutschensorientierer und 0,96956 für GPR mit EBS am sensorgestützten Versuchstand. RMSE liegt zwischen 1 % für GPR mit EBS am sensorgestützten Bandsortierer. Das bedeutet, dass die mittlere Variation gering ist und die Regressionsmodelle gut zur Beschreibung des Erholungsergebnisses geeignet sind.

Beim Vergleich der Regressionsmodelle, mit Ausnahme des sensorgestützten Versuchstands mit EBS, beschreiben die Modelle das Verhalten der Sortierergebnisse in Bezug auf die Eingangsparameter (Eingangszusammensetzung, Durchsatzrate) ausreichend, um ein SGS-Aggregat zu regulieren, wenn ein spezifisches Sortierergebnis in Bezug auf Reinheit und Ausbeute erzielt werden soll.

#### 4 Industrielle Relevanz

Die Regressionsmodelle für Reinheit und Ausbringung ermöglichen es, mit der Kenntnis der Inputzusammensetzung und Durchsatzrate mit der berechneten Abweichungsspanne ein Sortierergebnis vorherzusagen. Umgekehrt bedeutet dies: Wenn das Sortierergebnis eine bestimmte erwartete Reinheit aufweisen soll, liefern die Regressionsmodelle die maximal mögliche Durchsatzrate (innerhalb des Modellabweichungsbereichs), um die postulierte Reinheit zu erreichen.

Eine weitere Möglichkeit, die Regressionsmodelle zu nutzen, besteht darin, den Kreislaufbetrieb in Sortieranlagen oder die schrittweise Sortierung mit mehreren SGS-Aggregaten zu simulieren. Die Idee besteht darin, in einem ersten Sortierschritt Konzentrate einer bestimmten Kunststoffart anzureichern und diese in einem zweiten oder dritten Sortierschritt zu Rezyklaten zu sortieren. Beispielsweise würde der erste Sortierschritt erfolgen, um eine Reinheit von 75 % zu erreichen. Beim zweiten Sortierschritt beginnt die Konzentration des Zielmaterials bei 75 %, sodass bei gleicher Durchsatzleistung eine höhere Reinheit erreicht werden kann. Dieses Prinzip kann insbesondere in kleinen Sortieranlagen eingesetzt werden, die die Möglichkeit zum Kreislaufbetrieb haben, oder in größeren Sortieranlagen, die entweder die Möglichkeit zum Kreislaufbetrieb haben oder über mehrere Sortiermaschinen verfügen, die schrittweise hintereinander laufen.

Mithilfe dieser Erkenntnisse kann eine Sortieranlage die Reinheit steigern, indem sie die Anlage im optimalen Betriebspunkt betreibt, ohne die Anlage wesentlich anzupassen. Die einzige Anforderung besteht darin, Regressionsmodelle mit aufgezeichneten Produktionsdaten zu erstellen, um den optimalen Betriebspunkt für verschiedene Abfallzusammensetzungen des Sortierprozesses zu finden. Eingangszusammensetzungen können leicht erfasst werden, indem vor dem SGS-Aggregat eine NIR-Eingangscharakterisierung installiert wird, wobei das gleiche NIR-Sortiermodell auf dem SGS-Aggregat ausgewählt werden muss.

#### 5 Zusammenfassung

Sortieranlagenbetreiber möchten bestimmte Rezyklatqualitäten in Reinheit erreichen, sodass eine Recyclinganlage ihre produzierte sortierte Abfallfraktion aufkauft, jedoch mit dem größtmöglichen Durchsatz, um innerhalb eines Jahres die größtmögliche Abfallmenge behandelt und verkauft zu haben. Dies führt zu einem Interesse daran, den optimalen Betriebspunkt zum Erreichen

eines bestimmten SGS-Ergebnisses in Bezug auf die Zusammensetzung des Eingangsstroms, die Durchsatzrate, die Reinheit und die Ausbringung zu finden.

Die Forschungsaufgabe dieser Studie besteht darin, mathematische Ansätze in Regressionsmodellen zu finden, die die Inputzusammensetzung, die Durchsatzrate, die SGS-Ergebnisse in Reinheit und Ausbringung abdecken und schließlich aufzeigen, in welchen Bereichen bzw. Schwellenwerten diese Parameter verwendet werden können. Für die Findung der mathematischen Ansätze wurden 108 Versuche an drei sensorgestützten Sortieraggregaten mit fünf EBS-Proben durchgeführt.

Regressionsmodelle beschreiben das Sortierergebnisverhalten hinsichtlich der Eingangsparameter (Eingangszusammensetzung, Durchsatzrate), die im Umfang der verwendeten Daten ausreichend sind, um ein SGS-Aggregat zu regeln, wenn ein bestimmtes Sortierergebnis in Bezug auf Reinheit erreicht werden soll. Darüber hinaus beeinflusst die Abfallvorbehandlung oder der Zustand vor dem SGS-Aggregat das Sortierergebnis. Als Hauptergebnis dieses wissenschaftlichen Artikels ermöglichen es Regressionsmodelle mit ausreichend vielen Versuchen, eine akzeptable Vorhersagegenauigkeit in RMSE und R<sup>2</sup> zu erreichen, sodass eine Sortieranlage ihren Durchsatz automatisch regeln könnte, um eine bestimmte Reinheit im Sortierprozess zu erreichen – mit dem optimalen Betriebspunkt, um ein festgelegtes Sortierergebnis zu erzielen.

Dies würde zu einem automatisch optimierten Anlagenbetrieb führen und die in der Anlage sortierte Masse mit der erwarteten Reinheit maximieren. Die einzige Voraussetzung besteht darin, vor dem SGS-Aggregat eine NIR-Eingangscharakterisierung zu installieren, um die Eingangszusammensetzung zu kennen und die Produktionsdaten aufzuzeichnen. Darüber hinaus können die Regressionsmodelle auch den Kreislaufbetrieb in Sortieranlagen oder die kaskadische Stufensortierung mit mehreren SGS-Maschinen simulieren. Nach

dem ersten Sortierschritt zur Anreicherung von Konzentraten einer bestimmten Kunststoffart werden die Rezyklate in einem zweiten oder dritten Sortierschritt sortiert.

Abschließend lässt sich festhalten, dass das Ergebnis dieses wissenschaftlichen Artikels es einer Sortieranlage ermöglicht, die Reinheit zu steigern, indem die Anlage im optimalen Betriebspunkt betrieben wird. Übergeordnet betrachtet trägt dies dazu bei, die Menge an recyceltem Kunststoff zu erhöhen, sodass weniger Kunststoffabfälle thermisch behandelt werden müssen, ohne dass wesentliche Eingriffe in bestehende Anlagendesigns erforderlich sind.

**Förderung** Die Forschung wurde gefördert durch die Österreichische Forschungsförderungsgesellschaft (FFG), Projekt „Throughput Rate“, Fördervertragsnummer 884559. Die Open-Ac-

cess-Publikationskosten dieses Beitrags wurden durch die Montanuniversität Leoben gefördert.

**Funding** Open access funding provided by Montanuniversität Leoben.

### Interessenkonflikt

K. Friedrich, R. Pomberger und G. Koinig geben an, dass kein Interessenkonflikt besteht.

**Open Access** Dieser Artikel wird unter der Creative Commons Namensnennung 4.0 International Lizenz veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und

angeben, ob Änderungen vorgenommen wurden.

Die in diesem Artikel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.

Weitere Details zur Lizenz entnehmen Sie bitte der Lizenzinformation auf <http://creativecommons.org/licenses/by/4.0/deed.de>. ■

## Literatur

- Beel, H. (2017):** Sortierung von schwarzen Kunststoffen nach ihrer Polymerklasse mit Hyperspectral-Imaging-Technologie (Sorting of black plastics to their polymer types with hyperspectral-imaging-technology), In: Recycling und Rohstoffe Band 10, Proceedings of Recycling und Rohstoffe, Neuruppin, Germany, TK-Verlag, pp. 175–191, ISBN: 978-3-944310-34-3.
- Feil, A., Thoden van Velzen, E. U., Jansen, M., Vitz, P., Go, N., Pretz, T. (2016):** Technical assessment of processing plants as exemplified by the sorting of beverage cartons from lightweight packaging wastes. *Waste Management*, Vol. 48, pp. 95–105. <https://doi.org/10.1016/j.wasman.2015.10.023>.
- Friedrich, K., Fritz, T., Koinig, G., Pomberger, R., Vollprecht, D. (2021):** Assessment of technological developments in data analytics for sensor-based and robot sorting plants based on maturity levels to improve Austrian waste sorting plants. *Sustainability*, 13, 9472, <https://doi.org/10.3390/su13169472>.
- Friedrich, K., Koinig, G., Pomberger, R., Vollprecht, D. (2022):** Qualitative analysis of post-consumer and post-industrial waste via near-infrared, visual and induction identification with experimental sensor-based sorting setup, *MethodsX*, Vol. 9, 101686, <https://doi.org/10.1016/j.mex.2022.101686>.
- Gundupalli, S.P., Hait, S., Thakur, A. (2017):** A review on automated sorting of source separated municipal solid waste for recycling. *Waste Management*, Vol. 60, pp. 56–74. <https://doi.org/10.1016/j.wasman.2016.09.015>.
- Kulcke, A., Gurschler, C., Spöck, G., Leitner, R., Kraft, M. (2003):** On-line classification of synthetic polymers using near infrared spectral imaging. *Journal of Near Infrared Spectroscopy*, 11 (1), pp. 71–81, <https://doi.org/10.1255/jnirs.355>.
- Küppers, B., Chen, X., Seidler, I., Friedrich, K., Raulf, K., Pretz, T., Feil, A., Pomberger, R., Vollprecht, D. (2019):** Influences and consequences of mechanical delabelling on PET recycling. *De-tritus*, Volume 06-2019, pp. 39–46, <https://doi.org/10.31025/2611-4135/2019.1381>.
- Küppers, B., Schlägl, S., Friedrich, K., Lederle, L., Pichler, C., Freil, J., Pomberger, R., Vollprecht, D. (2021):** Influence of material alterations machine impairment on throughput related sensor-based sorting performance. *Was-*te Management & Research, 39 (1), pp. 122–129, <https://doi.org/10.1177/0734242X20936745>.
- Pasquini, C. (2003):** Near Infrared Spectroscopy: fundamentals, practical aspects and analytical applications, *Journal of the Brazilian Chemical Society*, 14(2), pp. 198–219, <https://doi.org/10.1590/S0103-50532003000200006>.
- Pretz, T., Julius, J. (2008):** Stand der Technik und Entwicklung bei der berührungslosen Sortierung von Abfällen (State-of-the-Art and development in contactless sorting of waste). *Österr Wasser- und Abfallwirtschaft* 60, ÖWAV: Vienna, Austria, pp 105–112.
- Workman, J., Springsteen, A.W. (1998):** Applied Spectroscopy: A Compact Reference for Practitioners, ISBN: 978-0-12-764070-9.

**Hinweis des Verlags** Der Verlag bleibt in Hinblick auf geografische Zuordnungen und Gebietsbezeichnungen in veröffentlichten Karten und Institutsadressen neutral.